Makine Öğrenmesi Algoritmaları

Dr. Cahit Karakuş

“Balbiti”

İçindekiler

Giriş

İçinde bilgisayar sistemi bulunan makinelerin minimum insan müdahalesi ile bir görevi öğrenmesi için verilere, algoritmalara ve matematiksel programlamaya odaklanan yapay zeka dalına Makine öğrenimi denir. Makine öğrenimi, veri yığınından öğrendiği deneyim ile otonom olarak öğrenmek ve performansını geliştirmek için algoritma ve matematiksel programlama geliştirme ile ilgilenen bir bilgisayar bilimi dalıdır.

Yapay zeka, bilgisayarların insan zekası gibi davranış geliştirmesini sağlayan matematik ve mühendislik alanıdır. Yapay zekanın alt disiplini olan derin öğrenme modeli, verinin yapısına göre filtreleme yapmak amacıyla hangi parametrelere ne ağırlık verileceğini kendisinin keşfetmesidir. Her derin öğrenme algoritması bir makine öğrenmesi algoritmasıdır çünkü verilerden öğrenme gerçekleştirmektedir. Ancak her makine öğrenmesi algoritması derin öğrenme algoritması değildir; nitekim derin öğrenme, makine öğrenmesinin spesifik bir türüdür. Derin öğrenme, Yüksek bilgi işleme gücü ve büyük veri kümeleriyle birlikte katmanlı yapay sinir ağlarının güçlü matematiksel modelleri oluşturabildiği bir makine öğrenimi alt kümesidir.

Makine öğreniminin yaptığı şey, kedi mi yoksa köpek mi olduğunu belirlemede hangi özelliğin daha etkin olduğunu veri yığınından bulmaktır. O halde sonuca etkisi olan özelliğin paremetrelerden en etkin olanların belirlenmesi gerekmektedir. Bu nedenle, çok sayıdaki paremetre arasından daha az parametre ile daha yüksek bir doğruluk sağlanmaya çalışılır. Makine Öğrenimi, ilişkilendirme kuralı ile öğrenme ve çıkarımlar yapan, büyük veri tabanlarındaki değişkenler arasındaki ilişkileri keşfeden bir öğrenme yöntemidir.

Kural tabanlı öğrenme algoritmasının belirleyici özelliği, yakalanan ilişkileri topluca temsil eden bir dizi ilişkisel kuralın tanımlanması ve kullanılmasıdır. Bilgisayarlara otonom olarak görevlerini nasıl gerçekleştireceklerini öğreten makine öğrenmesi algoritmaları ve matematiksel modelleri geliştirmede kullanılan yörünge denklemleri geniş bir uygulama alanı bulmaktadır.

Makine öğrenmesinin omurgasını oluşturan disiplinler:

- İstatistiksel hesaplama ile yakından ilgilidir.
- Matematiksel simülasyon, optimizasyon çalışması,
- Veri madenciliği, denetimsiz öğrenim yoluyla keşifsel veri analizine odaklanan ilgili bir çalışma alanıdır.
- Uygulamalı matematik
- Bilgisayar sistemleri ve yazılımlar

1. Makine Öğrenmesi Temel Bileşenleri

1.1. Makine Öğrenmesinde Öğrenme

Makine öğrenmesi türleri, veri yığını özeelliklerine ve problemin çözümüne göre farklılık gösterirler.

- Denetimli Öğrenme (Supervised Learning)
- Denetimsiz Öğrenme (Unsupervised Learning)
- Yarı denetimli Öğrenme
- Takviyeli Öğrenme

Genellikle, makine öğreniminde veri yığınından dört adım işlev gerçekleştirilir:

1) Veri tabanı yönetimi
2) Veri hazırlama: eksik, hatalı, normlara ve standartlara uymayan
3) Eğitim modeli: Verilerin bir koleksiyonundan öğrenilir. Eğitim veri yığınından sınıflandırma, matematiksel ifadenin katsayaları (regresyon), kümeleme
4) Uygulama modeli: Yeni test verileri hakkında kararlar almak için kullanılır.

Makine öğrenimi türlerinden bazıları şunlardır:

- Eğitim verilerinin doğru yanıtlarla etiketlendiği denetimli öğrenim. En yaygın iki denetimli öğrenme türü, sınıflandırma ve regresyondur. Sınıflandırma, bir sandık dolusu meyvelerin her birinin özelliği etiketlendikten sonra giriş yapan bir meyvenin hangi sınıfa dahil olduğunun belirlenmesidir.
- Analiz etmek ve keşfetmek istediğimiz kalıpları, etiketlenmemiş verilerden oluşan bir koleksiyondan öğrenen denetimsiz öğrenme. En önemli iki örnek, boyut küçültme ve kümelenmedir. Bir sandık meyvenin benzerlik özelliklerine göre sınıflandırılmanın etiketleme olmadan yapılması.
- Robot veya kontrolör gibi bir temsilcinin geçmişteki eylemlerin sonuçlarına dayalı olarak uygun eylemleri öğrenmeye çalıştığı pekiştirmeli öğrenme.
- Eğitim verilerinin yalnızca bir alt kümesinin etiketlendiği yarı denetimli öğrenme.
- Mali piyasalarda olduğu gibi zaman serisi tahmini
- Fabrikalarda ve gözetimde arıza tespiti için kullanılanlar gibi anormallik tespiti.
- Verilerin elde edilmesinin pahalı olduğu aktif öğrenme

Bu nedenle bir algoritmanın hangi eğitim verilerinden elde edileceğinin belirlenmesi tecrübeye dayanmaktadır.

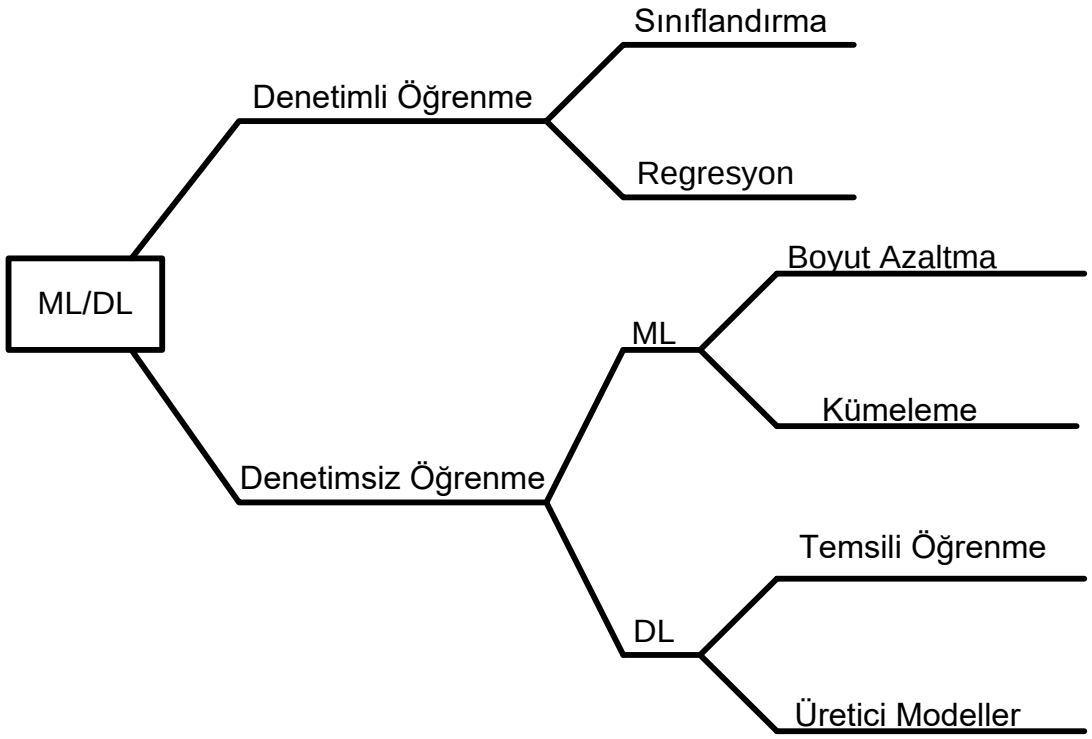

1.2. Özellik (Öznitelik) Vektörleri

Makine öğrenmesinde, özellik vektörleri, bir veri yığınının özellikler adı verilen sayısal veya sembolik özelliklerini matematiksel olarak, kolayca analiz edilebilir bir şekilde temsil etmek için kullanılır. Özellik vektörleri makine öğreniminin ve kalıp işlemenin birçok farklı alanı için önemlidir. Makine öğrenimi algoritmaları, algoritmaların işleme ve istatistiksel analiz yapabilmesi için tipik olarak nesnelerin sayısal bir temsilini gerektirir. Özellik vektörleri, doğrusal regresyon gibi istatistiksel prosedürlerde kullanılan açıklayıcı değişkenlerin vektörlerinin eşdeğeridir.

Aşina olabileceğiniz bir özellik vektörüne örnek RGB (kırmızı-yeşil-mavi) renk açıklamalarıdır. Bir renk, içinde ne kadar kırmızı, mavi ve yeşil olduğu ile tanımlanabilir. Bunun için bir özellik vektörü, renk = [R, G, B] olacaktır.

Bir vektör, tek sütunlu ancak çok satırlı bir matris gibi, genellikle uzamsal olarak temsil edilebilen bir sayı dizisidir. Bir özellik, bir nesnenin bir yönünün sayısal veya sembolik bir özelliğidir. Özellik vektörü, bir nesne hakkında birden çok öğe içeren bir vektördür. Veri yığını için özellik vektörlerini bir araya getirerek bir özellik alanı oluşturulabilir.

Özellikler, bir bütün olarak, yalnızca bir piksel veya bütün bir görüntüyü temsil edebilir. Ayrıntı düzeyi, bir kişinin nesne hakkında ne öğrenmeye veya temsil etmeye çalıştığına

bağlıdır. 3 boyutlu bir şekli, yüksekliğini, genişliğini, derinliğini vb. Gösteren bir özellik vektörüyle tanımlayabilirsiniz.

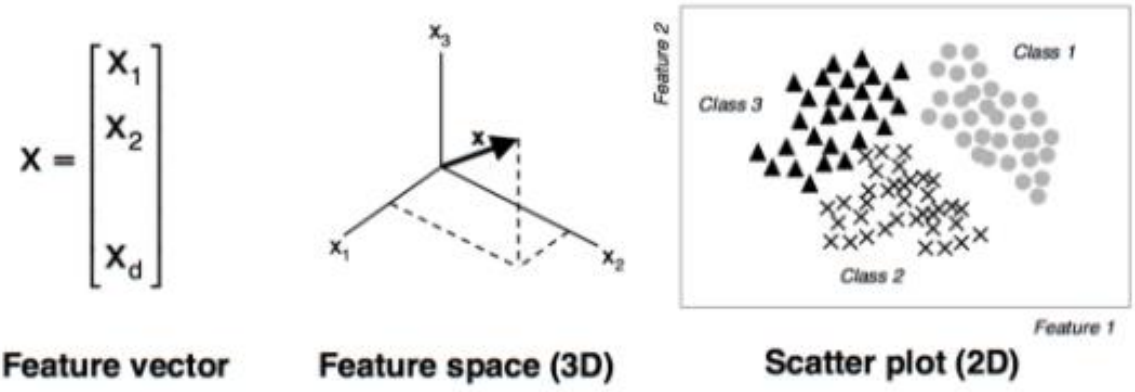

Özellik vektörleri, birçok analiz türüne yardımcı olmak için nesneleri sayısal bir şekilde temsil etmenin etkinliği ve pratikliği nedeniyle makine öğreniminde yaygın olarak kullanılmaktadır. Analiz için iyidirler çünkü öznitelik vektörlerini karşılaştırmak için birçok teknik vardır. İki nesnenin özellik vektörlerini karşılaştırmanın basit bir yolu Öklid mesafesini almaktır.

Görüntü işlemede, özellikler gradyan büyüklüğü, renk, gri tonlama yoğunluğu, kenarlar, alanlar ve daha fazlası olabilir. Özellik vektörleri, bir görüntü hakkındaki özniteliklerin, listelenen örnekler gibi, öznitelik vektörlerine yerleştirildikten sonra sayısal olarak karşılaştırılabilmesinin uygun yolu nedeniyle özellikle görüntü işlemedeki analizler için popülerdir.

Konuşma tanımada özellikler ses uzunlukları, gürültü seviyesi, gürültü oranları ve daha fazlası olabilir.

İstenmeyen e-postayla mücadele girişimlerinde özellikler bol miktarda bulunur. IP konumu, metin yapısı, belirli kelimelerin sıklığı veya belirli e-posta başlıkları olabilir.

Özellik vektörleri, makine öğrenmesinde sınıflandırma problemlerinde, yapay sinir ağlarında ve k en yakın komşu algoritmalarında kullanılır.

Örüntü tanıma süreçlerinde, özellik vektörleri, veri toplama ve verileri anlamlandırma arasında kullanılan araçlardır:

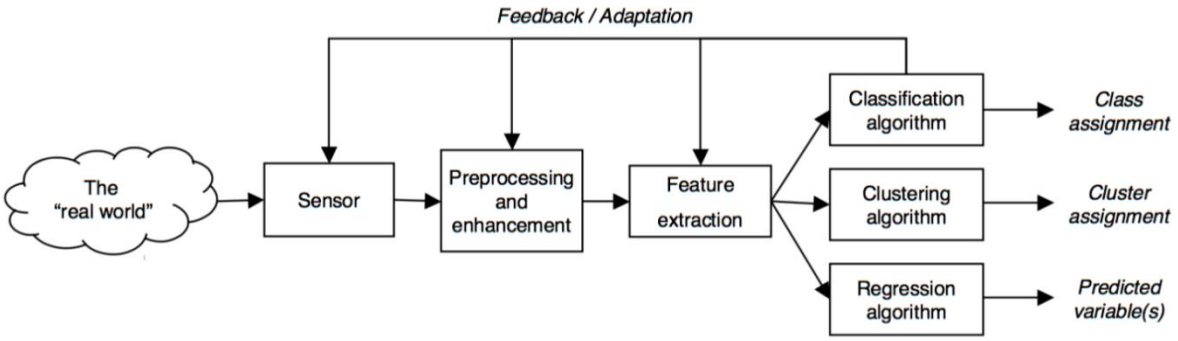

1.3. Parametreler ve Hiperparametreler

ML/DL'de bir model, model parametreleri tarafından tanımlanır veya temsil edilir. Bununla birlikte, bir modeli eğitme süreci, girdi özelliklerini (bağımsız değişkenler) etiketlere veya hedeflere (bağımlı değişken) doğru şekilde eşleyen optimal parametreleri öğrenmek için öğrenme algoritmasının kullanacağı optimal hiperparametreleri seçmeyi içerir.

Hiperparametreler, öğrenme sürecini kontrol eden ve bir öğrenme algoritmasının öğrenmesiyle sonuçlanan model parametrelerinin değerlerini belirleyen parametrelerdir. 'Hyper_' öneki, bunların öğrenme sürecini ve bundan kaynaklanan model parametrelerini kontrol eden 'üst düzey' parametreler olduğunu gösterir.

Bir öğrenme modelini tasarlayan bir makine öğrenimi mühendisi olarak, daha modelin eğitimi başlamadan önce öğrenme algoritmanızın kullanacağı hiperparametre değerlerini seçer ve ayarlarsınız. Bu bağlamda, model öğrenme/eğitim sırasında değerlerini değiştiremediği için hiperparametreler modelin dışında olduğu söylenir.

Hiperparametreler, öğrenme algoritması tarafından öğrenirken kullanılır, ancak bunlar ortaya çıkan modelin bir parçası değildir. Öğrenme sürecinin sonunda, model olarak adlandırdığımız etkin bir şekilde eğitilmiş model parametrelerine sahibiz. Eğitim sırasında kullanılan hiperparametreler bu modelin parçası değildir. Örneğin, modelin kendisinden bir modeli eğitmek için hangi hiperparametre değerlerinin kullanıldığını bilemeyiz, sadece öğrenilen model parametrelerini biliyoruz.

Temel olarak, makine öğrenimi ve derin öğrenmede, eğitim başlamadan önce değerlerine karar verdiğiniz veya yapılandırmalarını seçtiğiniz ve eğitim bittiğinde değerleri veya yapılandırması aynı kalacak olan her şey bir hiper parametredir.

Yaygın hiperparemetre örnekleri:

- Eğitim testi bölme oranı
- Optimizasyon algoritmalarında öğrenme oranı (örn. gradyan inişi)
- Optimizasyon algoritması seçimi (örneğin, gradyan inişi, stokastik gradyan inişi)
- Bir sinir ağı (NN) katmanında etkinleştirme işlevi seçimi (örn. Sigmoid, ReLU, Tanh)
- Modelin kullanacağı maliyet veya kayıp fonksiyonu seçimi
- Bir NN'deki gizli katmanların sayısı
- Her katmandaki etkinleştirme birimi sayısı
- NN cinsinden bırakma oranı (bırakma olasılığı)
- Bir NN eğitimindeki yineleme (dönem) sayısı
- Bir kümeleme görevindeki küme sayısı
- Evrişimli katmanlarda çekirdek veya filtre boyutu
- Havuzlama boyutu
- Parti boyutu

Parametreler:

Öte yandan parametreler modelin içindedir. Yani, kullanılan algoritma girdi özellikleri ile etiketler veya hedefler arasındaki eşlemeyi öğrenmeye çalıştığından, eğitim sırasında tamamen verilerden öğrenilir veya tahmin edilirler.

Model eğitimi tipik olarak bazı değerlere (rastgele değerlere veya sıfırlara ayarlanmış) başlatılan parametrelerle başlar. Eğitim/öğrenme ilerledikçe, ilk değerler bir optimizasyon algoritması (örneğin gradyan inişi) kullanılarak güncellenir. Öğrenme algoritması, öğrenme ilerledikçe parametre değerlerini sürekli olarak günceller, ancak model tasarımcısı tarafından ayarlanan hiperparametre değerleri değişmeden kalır. Öğrenme sürecinin sonunda, model parametreleri, modelin kendisini oluşturan şeydir.

Parametre örnekleri:

- Doğrusal ve lojistik regresyon modellerinin katsayıları (veya ağırlıkları).
- Bir NN'nin ağırlıkları ve yanlılık, meyinlenme, eğilim
- Kümelemedeki küme merkezleri

Basitçe söylemek gerekirse, makine öğrenimi ve derin öğrenmedeki parametreler, öğrenme algoritmanızın öğrenirken bağımsız olarak değiştirebileceği değerlerdir ve bu değerler, sağladığınız hiperparametrelerin seçiminden etkilenir. Böylece eğitim başlamadan önce hiperparametreleri ayarlarsınız ve öğrenme algoritması parametreleri öğrenmek için bunları kullanır. Eğitim sahnesinin arkasında parametreler sürekli olarak güncellenir ve eğitim sonundaki son olanlar modelinizi oluşturur.

Bu nedenle, doğru hiperparametre değerlerinin ayarlanması çok önemlidir çünkü model eğitimi sırasında bunların kullanılmasından kaynaklanacak modelin performansını doğrudan

etkiler. Modeliniz için en iyi hiperparametreleri seçme sürecine hiperparametre ayarlama denir.

Makine Öğrenimi Modellerinde Hiperparametre Optimizasyonu:
Öğretici, bir makine öğrenimi modelinde bir parametrenin ve bir hiper parametrenin ne olduğunu ve modelinizin performansını artırmak için neden hayati olduğunu açıklar.

Makine öğrenimi, verileri tahmin etmeyi ve sınıflandırmayı içerir ve bunu yapmak için veri kümesine göre çeşitli makine öğrenimi modelleri kullanırsınız. Makine öğrenimi modelleri, davranışlarının belirli bir soruna göre ayarlanabilmesi için parametrelendirilir. Bu modeller birçok parametreye sahip olabilir ve en iyi parametre kombinasyonunu bulmak bir arama problemi olarak ele alınabilir. Ancak, uygulamalı makine öğreniminde yeniyseniz, parametre adı verilen bu terim size yabancı gelebilir. Ama endişelenme! Bu blogun ilk etapta bunu öğreneceksiniz ve ayrıca bir makine öğrenimi modelinin bir parametresi ile bir hiperparametresi arasındaki farkın ne olduğunu keşfedeceksiniz. Bu blog aşağıdaki bölümlerden oluşmaktadır:

- Bir makine öğrenimi modelinde parametre ve hiper parametre nedir?
- Modelinizin performansını artırmak için hiperparametre optimizasyonu/ayarlaması neden hayati önem taşıyor?
- Hiperparametreleri optimize etmek/ayarlamak için iki basit strateji
- Python'da iki stratejiyle basit bir vaka çalışması

Bir makine öğrenimi öğrenme modelinde parametre nedir?
Model parametresi, modele dahil olan ve değeri verilen verilerden tahmin edilebilen bir konfigürasyon değişkenidir.

- Tahminler yapılırken model tarafından gereklidirler.
- Değerleri, modelin probleminiz üzerindeki becerisini tanımlar.
- Tahmin edilirler veya verilerden öğrenilirler.
- Genellikle uygulayıcı tarafından manuel olarak ayarlanmazlar.
- Genellikle öğrenilen modelin bir parçası olarak kaydedilirler.

Bu nedenle, yukarıdaki noktalardan ana çıkarımınız, makine öğrenme algoritmaları için çok önemli olan parametreler olmalıdır. Ayrıca, geçmiş eğitim verilerinden öğrenilen modelin bir parçasıdırlar. Hadi biraz daha derine inelim. Genel olarak programlama yaparken kullandığınız fonksiyon parametrelerini düşünün. Bir fonksiyona bir parametre iletebilirsiniz. Bu durumda parametre, bir dizi değerden birine sahip olabilen bir işlev argümanıdır. Makine öğreniminde, kullandığınız belirli model işlevdir ve yeni veriler üzerinde bir tahminde bulunmak için parametreler gerektirir. Bir modelin sabit veya değişken sayıda parametreye sahip olup olmadığı, “parametrik” veya “parametrik olmayan” olarak adlandırılıp adlandırılamayacağını belirler.
Model parametrelerinin bazı örnekleri şunları içerir:

- Bir yapay sinir ağındaki ağırlıklar.
- Bir destek vektör makinesindeki destek vektörleri.
- Doğrusal bir regresyon veya lojistik regresyondaki katsayılar.

Bir makine öğrenimi öğrenme modelinde hiper parametre nedir?
Model hiperparametresi, modelin dışında olan ve değeri verilerden tahmin edilemeyen bir konfigürasyondur.

- Model parametrelerini tahmin etmeye yardımcı olmak için genellikle süreçlerde kullanılırlar.
- Genellikle pratisyen tarafından belirtilirler.
- Genellikle buluşsal yöntemler kullanılarak ayarlanabilirler.
- Genellikle belirli bir tahmine dayalı modelleme problemi için ayarlanırlar.

Belirli bir problemde bir model hiperparametresi için en iyi değeri bilemezsiniz. Pratik kuralları kullanabilir, diğer konularda kullanılan değerleri kopyalayabilir veya deneme yanılma yoluyla en iyi değeri arayabilirsiniz. Bir makine öğrenimi algoritması belirli bir problem için ayarlandığında, esasen, en yetenekli tahminlerle sonuçlanan modelin parametrelerini keşfetmek için modelin hiper parametrelerini ayarlarsınız.

“Applied Predictive Modelling” adlı çok popüler bir kitaba göre - “Birçok model, verilerden doğrudan tahmin edilemeyen önemli parametrelere sahiptir. Örneğin, K-en yakın komşu sınıflandırma modelinde… Uygun bir değeri hesaplamak için analitik bir formül bulunmadığından, bu tür model parametresi bir ayar parametresi olarak anılır.”

Model hiperparametreleri, genellikle işleri kafa karıştırıcı hale getirebilecek model parametreleri olarak adlandırılır. Bu karışıklığın üstesinden gelmek için iyi bir kural şudur: “Bir model parametresini manuel olarak belirtmeniz gerekiyorsa, bu muhtemelen bir model hiperparametresidir. ” Bazı model hiperparametre örnekleri şunları içerir:

- Bir sinir ağını eğitmek için öğrenme oranı.
- Destek vektör makineleri için C ve sigma hiperparametreleri.
- k'deki k-en yakın komşular.

Bir makine öğrenimi modelinde doğru hiper parametre değerlerinin önemi:
Hiperparametreler hakkında düşünmenin en iyi yolu, tıpkı bir AM radyonun düğmelerini net bir sinyal almak için çevirebildiğiniz gibi, performansı optimize etmek için ayarlanabilen bir algoritmanın ayarları gibidir. Bir makine öğrenimi modeli oluştururken, model mimarinizi nasıl tanımlayacağınıza ilişkin tasarım seçenekleri sunulur. Çoğu zaman, belirli bir model için en uygun model mimarisinin ne olması gerektiğini hemen bilemezsiniz ve bu nedenle bir dizi olasılığı keşfetmek istersiniz. Gerçek bir makine öğrenimi tarzında, ideal olarak makineden bu keşfi gerçekleştirmesini ve en uygun model mimarisini otomatik olarak seçmesini isteyeceksiniz.

Örnek olay bölümünde, doğru hiperparametre değerleri seçiminin bir makine öğrenimi modelinin performansını nasıl etkilediğini göreceksiniz. Bu bağlamda, doğru değer kümesinin seçilmesi tipik olarak "Hiperparametre optimizasyonu" veya "Hiperparametre ayarı" olarak bilinir.

Hiperparametreleri optimize etmek/ayarlamak için iki basit strateji:
Modeller birçok hiperparametreye sahip olabilir ve en iyi parametre kombinasyonunu bulmak bir arama problemi olarak ele alınabilir.

Şu anda birçok hiperparametre optimizasyonu/ayar algoritması olmasına rağmen, bu gönderi iki basit stratejiyi tartışıyor: 1. grid araması ve 2. Rastgele Arama.

Hiperparametrelerin grid araması:
Grid araması, bir gridda belirtilen algoritma parametrelerinin her bir kombinasyonu için metodik olarak bir model oluşturacak ve değerlendirecek olan hiperparametre ayarlamaya yönelik bir yaklaşımdır.

Aşağıdaki örneği ele alalım:
Bir makine öğrenimi modeli X'in a1, a2 ve a3 hiper parametrelerini aldığını varsayalım. Grid aramada, önce a1, a2 ve a3 hiperparametrelerinin her biri için değer aralığını tanımlarsınız. Bunu, hiperparametrelerin her biri için bir dizi değer olarak düşünebilirsiniz. Şimdi grid arama tekniği, ilk başta tanımladığınız tüm olası hiperparametre (a1, a2 ve a3) değerleri kombinasyonlarıyla X'in birçok versiyonunu oluşturacaktır. Bu hiperparametre değerleri aralığına grid adı verilir.

Grid şu şekilde tanımladığınızı varsayalım:
a1 = [0,1,2,3,4,5]
a2 = [10,20,30,40,5,60]
a3 = [105,105,110,115,120,125]

Hiperparametreler için tanımladığınız değerler dizisinin, hiperparametre yalnızca Tamsayı değerleri alıyorsa diziye Kayan tip değerleri sağlayamayacağınız bir anlamda meşru olması gerektiğini unutmayın.

Şimdi, grid araması, az önce tanımladığınız grid ile X'in birkaç sürümünü oluşturma sürecine başlayacaktır.

[0,10,105] kombinasyonu ile başlayacak ve [5,60,125] ile bitecek. Bu ikisi arasındaki tüm ara kombinasyonlardan geçecek ve bu da grid aramasını hesaplama açısından çok pahalı hale getiriyor.

Hiperparametrelerin rastgele aranması:
İstatistikte, dağılımla, esasen, gözlemlenen veya teorik oluşum sıklığını gösteren bir değişkenin değerlerinin düzenlenmesi kastedilmektedir. Öte yandan, Örnekleme istatistikte kullanılan bir terimdir. Bir bütün olarak popülasyon hakkında bir şeyler anlamak için hedef popülasyondan temsili bir örnek seçme ve bu örnekten veri toplama sürecidir.

Her hiperparametre için bir örnekleme dağılımı tanımlayacaksınız. Optimum modeli ararken kaç yineleme oluşturmak istediğinizi de tanımlayabilirsiniz. Her yineleme için, modelin hiperparametre değerleri, tanımlanan dağılımların örneklenmesiyle belirlenecektir. Grid araması yerine rastgele arama kullanımını motive eden birincil teorik desteklerden biri, çoğu durumda hiperparametrelerin eşit derecede önemli olmadığı gerçeğidir. Çoğu veri kümesi için hiper parametrelerden yalnızca birkaçı gerçekten önemlidir, ancak farklı veri kümelerinde farklı hiper parametreler önemlidir. Bu fenomen, grid aramasını yeni veri kümeleri için algoritmaları yapılandırmak için kötü bir seçim haline getiriyor."

Bir hiperparametrenin model puanını optimize etme üzerinde önemli ölçüde daha fazla etkiye sahip olduğu bir hiperparametre alanı üzerinde arama yapıyoruz - her eksende gösterilen dağılımlar modelin puanını temsil ediyor. Her durumda, 9 farklı modeli değerlendiriyoruz. Şebeke arama stratejisi, optimal modeli açıkça gözden kaçırır ve önemsiz parametreyi keşfetmek için fazladan zaman harcar. Bu grid araması sırasında, her bir hiperparametreyi izole ettik ve diğer tüm hiperparametreleri sabit tutarken mümkün olan en iyi değeri aradık. İncelenmekte olan hiperparametrenin elde edilen model puanı üzerinde çok az etkisi olduğu durumlarda bu, boşa harcanan çabayla sonuçlanır. Tersine, rastgele arama çok daha gelişmiş keşif gücüne sahiptir ve kritik hiperparametre için en uygun değeri bulmaya odaklanabilir.

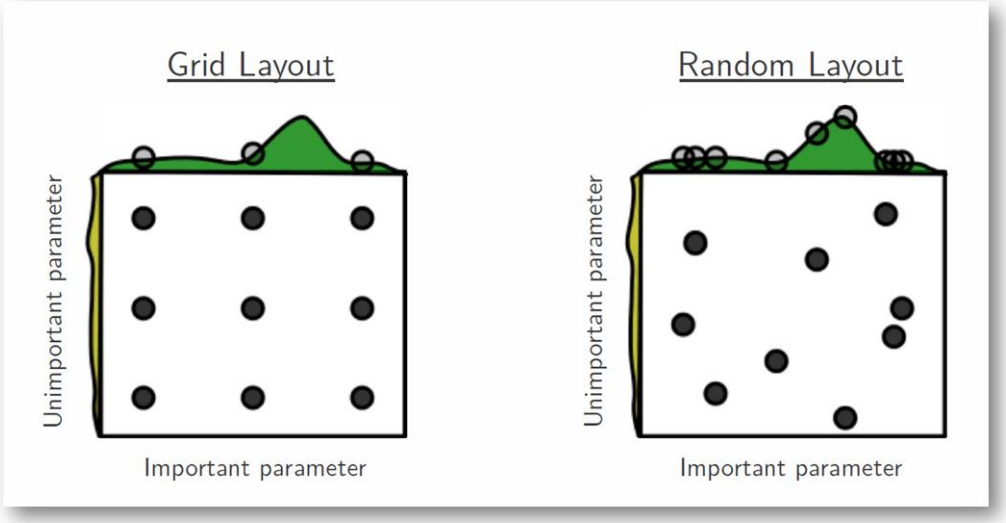

1.4. Metrikler

- Model ne kadar iyi gidiyor? Kullanışlı bir model mi?
- Modeli daha fazla veri üzerinde eğitmek performansını iyileştirecek mi?
- Daha fazla özellik eklenmesi gerekiyor mu?

Eğitim / Test / Onaylama ayrımı

Modeli doğru bir şekilde değerlendirmek için yapabileceğiniz en önemli şey, modeli tüm veri kümesi üzerinde eğitmemektir. Tekrar ediyorum: modeli tüm veri kümesi üzerinde eğitmeyin. Tipik bir eğitim/test ayrımı, verilerin %70'inin eğitim için ve %30'unun test için kullanılması olacaktır.

Eğitim setine fazla uyma olasılığını önlemek için model değerlendirirken yeni verileri kullanmak önemlidir. Bununla birlikte, bazen bir modelin en iyi parametrelerini bulmak için inşa ederken modeli değerlendirmek faydalı olabilir - ancak bu değerlendirme için test setini kullanamayız, aksi takdirde en iyi performansı gösteren parametreleri seçeriz. Belki de en iyi genelleştiren parametreler değil. Modeli oluşturmaya ve ayarlamaya devam ederken modeli değerlendirmek için, doğrulama kümesi olarak bilinen verilerin üçüncü bir alt kümesi oluşturulur. Tipik bir eğitim/test/doğrulama ayrımı, eğitim için verilerin %60'ını, doğrulama için verilerin %20'sini ve test için verilerin %20'sini kullanmak olacaktır.

Ayrıca, bu bölmeleri yapmadan önce verileri karıştırmanın çok önemli olduğunu, böylece her bölmenin veri kümesini doğru bir şekilde temsil etmesi sağlanacaktır.

Metrikler

Sınıflandırma metrikleri:

Sınıflandırma tahminleri gerçekleştirirken ortaya çıkabilecek dört tür sonuç vardır.

- Gerçek pozitifler, bir gözlemin bir sınıfa ait olduğunu ve aslında o sınıfa ait olduğunu tahmin ettiğiniz zamandır.
- Gerçek olumsuzluklar, bir gözlemin bir sınıfa ait olmadığını ve aslında o sınıfa ait olmadığını tahmin ettiğiniz zamandır.
- Bir gözlemin gerçekte öyle olmadığı halde bir sınıfa ait olduğunu tahmin ettiğinizde yanlış pozitifler meydana gelir.
- Yanlış negatifler, bir gözlemin bir sınıfa ait olmadığı halde aslında öyle olduğunu tahmin ettiğinizde ortaya çıkar.

Bu dört sonuç genellikle bir karışıklık matrisi üzerinde çizilir. Aşağıdaki karışıklık matrisi, ikili sınıflandırma durumuna bir örnektir. Bu matrisi, test verileriniz üzerinde tahminler yaptıktan ve ardından her bir tahmini yukarıda açıklanan dört olası sonuçtan biri olarak tanımladıktan sonra oluşturursunuz.

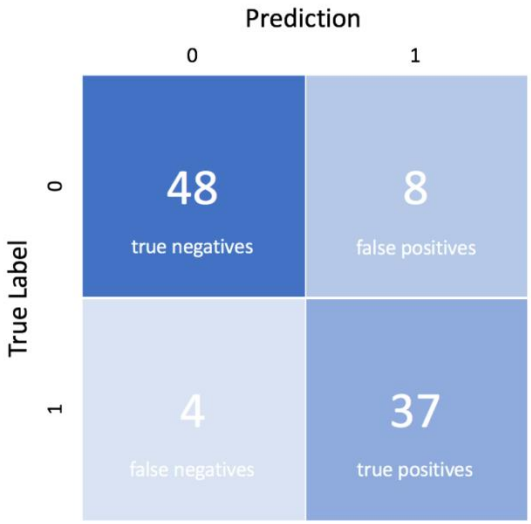

Bir sınıflandırma modelini değerlendirmek için kullanılan üç ana metrik doğruluk, kesinlik ve hatırlamadır.

Doğruluk, test verileri için doğru tahminlerin yüzdesi olarak tanımlanır. Doğru tahmin sayısı toplam tahmin sayısına bölünerek kolayca hesaplanabilir.
doğruluk=doğru tahminler /tüm tahminlerdoğruluk=doğru tahminler/tüm tahminler

Kesinlik, belirli bir sınıfa ait olduğu tahmin edilen tüm örnekler arasında ilgili örneklerin (gerçek pozitiflerin) oranı olarak tanımlanır.
kesinlik=doğru pozitifler / yanlış pozitifler
kesinlik=gerçek pozitifler / yanlış pozitifler

Geri çağırma, bir sınıfa ait olduğu tahmin edilen örneklerin, gerçekten sınıfa ait olan tüm örneklere göre oranı olarak tanımlanır.
geri çağırma=gerçek pozitifler / yanlış negatifler

Aşağıdaki grafik, kesinlik ve geri çağırma arasındaki farkı görselleştiren olağanüstü bir iş çıkarıyor.

Bir kişinin kanser olduğunu yanlış tahmin eden bir model istemezsiniz (kişi sahip olmadığı bir hastalık için acı verici ve pahalı bir tedavi sürecine girer) ama aynı zamanda bir kişiyi yanlış tahmin etmek istemezsiniz. Bu nedenle, bir modelin hem kesinliğini hem de geri çağrılmasını değerlendirmek önemlidir.

Kesinlik ve hatırlama arasındaki dengeyi açıklamak için başka örnekler ararken, intiharı tahmin etmek için makine öğrenimini kullanmayı tartışan aşağıdaki makaleye rastladım. Bu durumda, modelin kesinliğinden çok geri çağrılmasına daha fazla odaklanmak isteriz. Aslında intiharı düşünmeyen birine müdahale etmek, intiharı düşünen birini kaçırmaktan çok daha

az zararlı olacaktır. Bununla birlikte, kesinlik yine de önemlidir, çünkü modelinizin yanlış pozitifleri öngördüğü çok fazla örnek istemezsiniz.

Regresyon metrikleri

Regresyon modelleri için değerlendirme ölçüleri, sınıflandırma modelleri için tartıştığımız yukarıdaki ölçülerden oldukça farklıdır çünkü artık ayrık sayıda sınıf yerine sürekli bir aralıkta tahmin yapıyoruz. Regresyon modeliniz bir evin fiyatını 400 bin dolar olarak öngörüyorsa ve 405 bin dolara satıyorsa, bu oldukça iyi bir tahmindir. Ancak sınıflandırma örneklerinde sadece bir tahminin doğru mu yanlış mı olduğu ile ilgilendik, bir tahminin "oldukça iyi" olduğunu söyleme yeteneği yoktu. Bu nedenle, regresyon modelleri için farklı bir dizi değerlendirme ölçütüne sahibiz.

Açıklanan varyans, beklenen sonuçlar içindeki varyansı karşılaştırır ve bunu modelimizin hatasındaki varyansla karşılaştırır. Bu metrik esas olarak, modelimizin açıklayabildiği orijinal veri kümesindeki varyasyon miktarını temsil eder.

Ortalama kare hatası, tahmin edilen çıktı ile gerçek çıktı arasındaki kare farklarının ortalaması olarak basitçe tanımlanır. Kare hatası yaygın olarak kullanılır, çünkü tahminin çok yüksek veya çok düşük olup olmadığı konusunda agnostiktir, sadece tahminin yanlış olduğunu bildirir.

1.5. Makine Öğrenmesi Algoritmaları

Makine Öğrenmesi algoritması çalıştırılırken,

- Hesaplamalar için gerekli veri kütüphaneleri transfer edilir. Veritabanı dosyaları okunur.
- Etiketli verilerin ağırlıklı ortalama, standart sapma gibi istatistiksel analiz özellikleri belirlenir, grafikler çizilir ve yorumlanır.
- Değerler tahmin edilirken dikkate almak istenilen özellikler, parametreler ve katsayılar seçilir.
- Bir modelin doğruluğunu kontrol etmek için, veriler eğitim ve test veri setlerine ayrılır.
- Eğitim veri setinden model oluşturulur. Oluşturulan model test veri seti kullanılarak modelin doğruluğu test edilir.
-

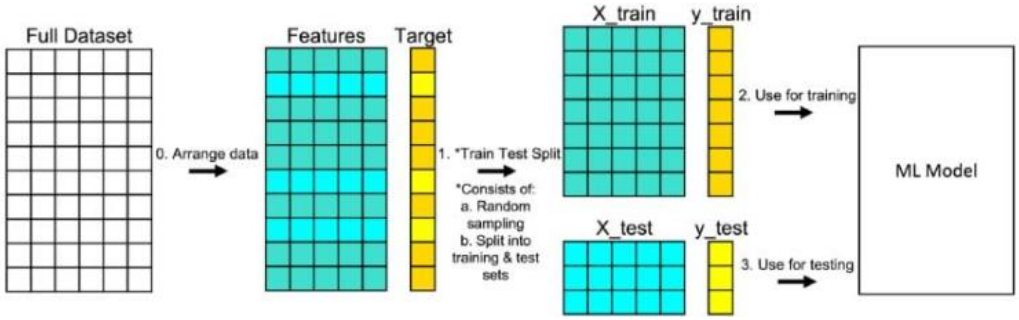

1- Regresyon (Tahmin)

Dizi, vektör, matris gibi sayısal değerlerden model elde etmek ve bu modeli kullanarak tahminler ve kestirim yapmak ve yorumlamak için regresyon algoritmaları kullanılır.
Regresyon algoritmaları:

- Doğrusal Regresyon
- Polinom Regresyon
- Üstel Regresyon
- Lojistik regresyon
- Logaritmik Regresyon

2-Sınıflandırma

Bir veri yığınının sınıfını veya kategorisini tahmin etmek için sınıflandırma algoritmaları kullanılır. Sınıflandırma algoritmaları:

- K-En Yakın Komşular
- Karar ağaçları
- Rastgele Orman
- Destek Vektör Makinesi

- Naive Bayes

3- Kümeleme

Veri yığının boyutunu indirmek, özetlemek, özelliklerini belirleme veya verileri yapılandırmak için kümeleme algoritmaları kullanılır. Kümeleme algoritmaları:

- K-means
- DBSCAN
- Mean Shift
- Hierarchical

4- İlişkilendirme

Birlikte meydana gelen öğeleri veya olayları ilişkilendirmek için ilişkilendirme algoritmaları kullanılır. İlişkilendirme algoritmaları:

- Apriori

5- Anomali (Sapma) Algılama:

Olağandışı anormal etkinlikleri keşfetmek için anormallik algılama kullanılır. Anormallik tespitinde algılayıcılar ve ölçerlerden toplanan veri yığınından anormal durumların belirlenmesi gerekmektedir. Veri madenciliğinde, aykırı tespit olarak da bilinen anomali tespiti, verilerin çoğundan önemli ölçüde farklılık göstererek şüphe uyandıran nadir olayların veya gözlemlerin tanımlanmasıdır. Tipik olarak, anormal durumlar banka sahtekarlığı, işletmlerde yapısal kusur, tıbbi sorunlar veya bir metindeki hatalar gibi bir konuları temsil eder.

Üç geniş anomali tespit tekniği kategorisi bulunmaktadır:

- Gözetimsiz anomali tespit teknikleri, veri kümesindeki örneklerin çoğunun normal olduğu varsayımıyla etiketlenmemiş bir test veri kümesindeki anormallikleri, veri kümesinin geri kalan kısmına en az uyan görünen örnekleri arayarak tespit eder.
- Denetimli anomali algılama teknikleri, "normal" ve "anormal" olarak etiketlenmiş ve bir sınıflandırıcıyı (diğer birçok istatistiksel sınıflandırma problemi için temel fark, aykırı algılamanın doğasında dengesiz doğasıdır) içeren bir veri seti gerektirir.
- Yarı denetimli anomali tespit teknikleri, belirli bir normal eğitim veri setinden normal davranışı temsil eden bir model oluşturur ve daha sonra model tarafından bir test örneğinin üretilme olasılığını test eder.

6- Sıra Desen Madenciliği

Örüntü – Pattern, bir nesnenin ya da olayın iki veya üç boyutlu, uzaysal ve geometriksel davranışının matematiksel ifadesdir. Diğer bir ifadeyle , nesnenin davranışı ile ilgili uzayda gözlenebilir veya ölçülebilir geometrik bilgilerdir. Tersinden desen madenciliği, örüntü hazırlanır, veri yığını içersinde gezinir, benzerlik bulduğunda uyarı verir.

7- Boyut Küçültme (Dimensionality reduction)

Makine Öğrenimi ve istatistikte boyut küçültme, dikkate alınan rastgele değişkenlerin sayısını azaltma işlemidir ve özellik seçimi ve özellik çıkarımı olarak ikiye ayrılabilir. Bir veri kümesinden yalnızca yararlı özellikleri çıkarmak için verilerin boyutunu küçültmek için boyut azaltma kullanılır. Boyut azaltma, denetimsiz bir öğrenme tekniğidir.

Veri biliminde, boyut indirgeme, bir verinin yüksek boyutlu bir uzaydan, düşük boyutlu bir uzaya, anlamını kaybetmeyecek şekilde dönüştürülmesidir. Yüksek boyutlu bir veriyi işlemek daha fazla işlem yükü gerektirir. Bu yüzden, yüksek sayıda gözlemin ve değişkenin incelendiği sinyal işleme, konuşma tanıma, nöroinformatik, biyoinformatik gibi alanlarda boyut indiremesi sıkça kullanılır.

8- Önerilerden eğilim ya da yön bulma

Öneri motorları oluşturmak için öneri algoritmalarını kullanılır. Örnekler:

- Netflix öneri sistemi.
- Bir kitap tavsiye sistemi.
- Amazon'da bir ürün öneri sistemi.

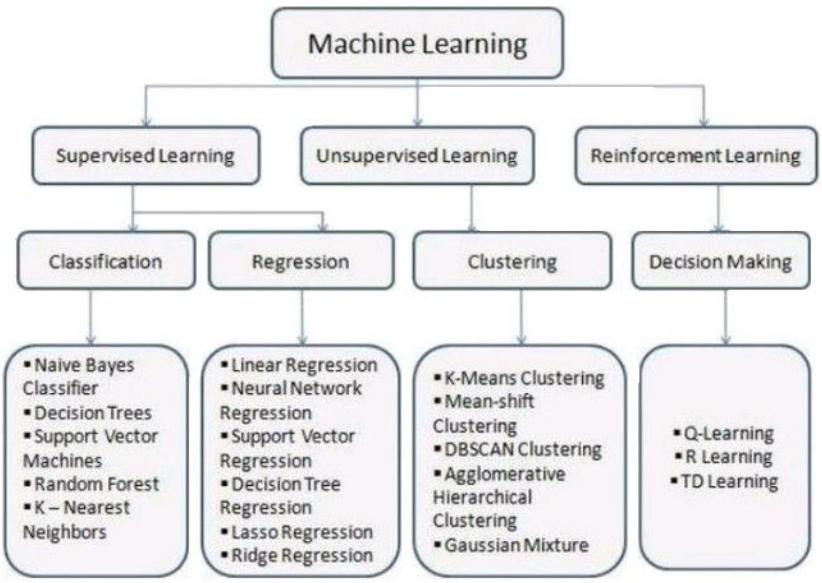

1.6. Makine Öğreniminde Performans

Makine öğreniminde veri yığınından elde edilen modellerinin doğru ve güvenilir tahminler sunması beklenir. Tahminlerine güvenmek için makine öğrenimi modellerinin test verilerini nasıl genellediğini değerlendirmek önemlidir.

Model performanslarının test edilmesi:

1) Performansı değerlendirme ihtiyacı
2) Model değerlendirme teknikleri
3) Sınıflandırma modeli değerlendirme ölçütleri
4) Regresyon modeli değerlendirme metrikleri

Makine öğreniminde hata, bir algoritmanın önceden bilinmeyen veri kümesi için ne kadar doğru tahminlerde bulunabileceğinin bir ölçüsüdür. Bu hatalar temelinde, belirli veri kümesinde en iyi performansı gösterebilecek makine öğrenimi modeli seçilir.

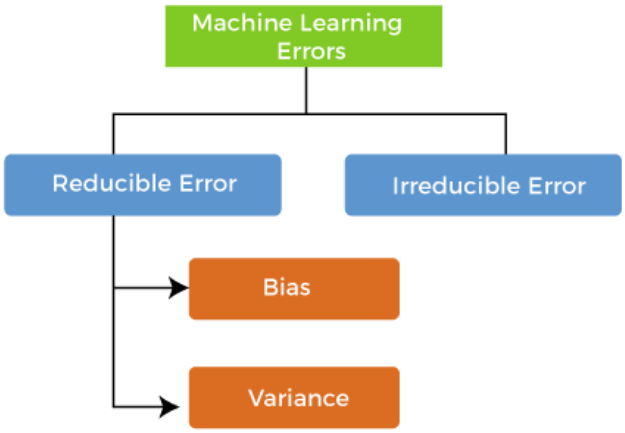

Makine öğreniminde başlıca iki tür hata vardır: İndirgenebilir hatalar, indirgenemez hatalar. İndirgenebilir hatalar, modelin doğruluğunu iyileştirmek için hataların azaltılmasına odaklanılır. Bu tür hatalar ayrıca önyargı ve varyans olarak adlandırılır. İndirgenemez hatalar, modelde her zaman mevcut olacaktır. Hangi algoritmanın kullanıldığına bakılmaksızın bu hataların nedeni, değeri düşürülemeyen bilinmeyen değişkenlerdir.

Veri kümesi, eğitim veri kümesi ve doğrulamaya yönelik test veri kümesi olarak iki türlü sınıflandırılır. Eğitim kümesi, tahmine dayalı modeller oluşturmak için kullanılan bir veri kümesinden özelliklerin çıkarılmasına yönelik parametrelerin belirlenmesi ve bir modeli eğitmek için kullanılan bir dizi girdi örneği içerir. Doğrulama veri seti, eğitim aşamasında oluşturulan modelin performansını değerlendirmek olan bir veri kümesinin alt kümesidir. Bir modeli periyodik olarak değerlendirir ve model parametrelerinin ince ayarına izin verir. Tüm modelleme algoritmaları bir doğrulama kümesine ihtiyaç duymayabilirler. Doğrulamaya yönelik test kümesi, aynı zamanda görünmeyen veriler olarak da bilinir. Bir modelin eğitim aşamasından sonra geçirdiği son değerlendirmedir. Bir test kümesi, bir modelin gelecekteki

olası performansını değerlendirmek için kullanılan bir veri kümesinin alt kümesi olarak tanımlanır.

Performans testinde aşırı uyum, yanlılık ve varyans kritik öneme sahiptir. Aşırı uyum, bir modelin veri kümesi tarafından açıklanabilecek olandan daha fazla parametre içerdiği anlamına gelir. Gürültülü veriler bozunmaya katkıda bulunur. Bu modellerin genelleştirilmesi, model veri kümesinden kastedilenden daha fazlasını öğrendiği için güvenilir değildir. Her zaman bir modelin görünmeyen veriler üzerinde nasıl genellendiği test edilecektir..

Makine öğrenimi modeli doğru değilse tahmin hataları yapabilir ve bu tahmin hataları genellikle yanlılık ve varyans olarak bilinir. Makine öğreniminde, model tahminleri ile gerçek tahminler arasında her zaman bir fark olduğu için indirgenebilir hatalar her zaman mevcut olacaktır. Makine öğrenimi ya da veri bilimi analistlerinin temel amacı, daha doğru sonuçlar elde etmek için bu hataları azaltmaktır.

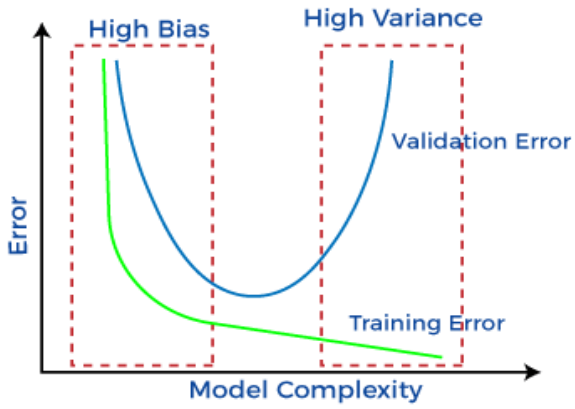

denetimsiz öğrenme	Bir veri seti verildiğinde, kümeleme gibi teknikleri kullanarak verideki benzer eğilimleri ve ilişkileri bulmaya çalışır.
Özellik	Özellik, modelin eğitilmesi için girdi olarak kullanılan bir niteliktir. Diğer adlar, boyut veya sütun içerir.
Bias	Eğilim, sapma, meyil, Önyargı, verilerinize mükemmel şekilde uyan bir modelin parametreleri ile algoritmanızın öğrendiği parametreler arasındaki beklenen farktır. Karar Ağaçları, K-En Yakın Komşular ve Destek Vektör Makineleri gibi düşük sapmalı algoritmalar, yüksek sapmalı algoritmalardan daha karmaşık desenler bulma eğilimindedir.
Variance	Varyans, algoritmanın eğitim verilerinden ne kadar etkilendiği ve yeni eğitim verileriyle parametrelerin ne kadar değiştiğidir. Doğrusal

	Regresyon, Lojistik Regresyon ve Naive Bayes gibi düşük varyanslı algoritmalar, yüksek varyanslı algoritmalardan daha az karmaşık modeller bulma eğilimindedir.
Underfitting	Model, veri içindeki kalıpları yakalamak için çok basittir. Model, eğitildiği verilerde ve görünmeyen verilerde düşük performans gösteriyor. Yüksek önyargı, düşük varyans. Yüksek eğitim hatası ve yüksek test hatası.
Overfitting	Model çok karmaşık veya çok spesifik, genellemeyen eğilimleri yakalıyor. Model, üzerinde eğitildiği verileri doğru bir şekilde tahmin eder, ancak görünmeyen verileri doğru bir şekilde tahmin etmez. Düşük önyargı, yüksek varyans. Düşük eğitim hatası ve yüksek test hatası.
Bias-Variance Trade-off	Bias-Varyance Trade-off, hem tren hem de test hatasını en aza indirerek doğru karmaşıklığa sahip bir model bulma anlamına gelir.

1.6.1. Yanlılık / Önyargı (Bias / Varyans)

Genel olarak, bir makine öğrenimi modeli verileri analiz eder, içindeki kalıpları ya da parametreleri bulur ve tahminler yapar. Model, eğitim sırasında veri kümesindeki bu kalıpları öğrenir ve bunları tahmin için test verilerine uygular. Öngörü yapılırken, model tarafından yapılan tahmin değerleri ile gerçek değerler/beklenen değerler arasında bir fark oluşur ve bu fark, yanlılık hataları veya önyargıdan kaynaklanan hatalar olarak bilinir. Doğrusal Regresyon gibi makine öğrenimi algoritmalarının veri noktaları arasındaki gerçek ilişkiyi yakalayamaması yanlılık olarak tanımlanabilir. Her algoritma bir miktar yanlılıkla başlar, çünkü yanlılık modeldeki varsayımlardan kaynaklanır ve bu da hedef işlevin öğrenilmesini kolaylaştırır.

Eğitim modeli aşağıdaki hatalara sahip olabilir:

- Düşük Sapma: Düşük sapma modeli, hedef fonksiyonun biçimi hakkında daha az varsayımda bulunacaktır.
- **Yüksek Sapma:** Yüksek sapmaya sahip bir model, daha fazla varsayımda bulunur ve model, veri kümemizin önemli özelliklerini yakalayamaz hale gelir. Yüksek sapmalı bir model, yeni veriler üzerinde de iyi performans gösteremez.

Genel olarak, doğrusal bir algoritma, hızlı öğrenmelerini sağladığı için yüksek yanlılığa (önyargıya) sahiptir. Algoritma ne kadar basitse, tanıtılması muhtemel önyargı o kadar yüksek olur. Oysa doğrusal olmayan bir algoritma genellikle düşük önyargıya sahiptir.

Karar Ağaçları, k-En Yakın Komşular ve Destek Vektör Makineleri, düşük önyargılı makine öğrenimi algoritmalarına bazı örneklerdir. Aynı zamanda yüksek yanlılığa sahip bir algoritma Lineer Regresyon, Lineer Diskriminant Analizi ve Lojistik Regresyon'dur.

Bir makine öğrenimi yönteminin gerçek ilişkiyi yakalayamamasına yanlılık denir. İstatistiksel tanımın aksine, varyans, verilerin yayılması değil, bir modelin doğruluğunun farklı veri kümelerine göre nasıl değiştiği anlamına gelir. Veri kümeleri arasındaki uyum farklarına varyans denir.
Varyans: Modelin tahmin ettiği verilerin, gerçek verilerin etrafında nasıl (ne kadar) saçıldığını ölçer.

Öyargı, yanlılık (Bias):
Yanlılık terimi, modelin örneklerle aynı çizgide olan bir eğriyi oluşturmadaki başarısızlığının derecesidir. Bir makine öğrenimi yönteminin gerçek ilişkiyi yakalayamamasına yanlılık denir.

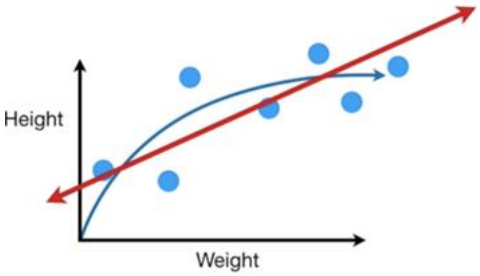

Yanlılık, ML modelinin tahmin edilen değerleri ile gerçek değeri arasındaki fark olarak tanımlanır. Yanlılık, hem eğitim hem de test verilerinde önemli bir yanlışlığa neden olur. Bir algoritmanın her zaman düşük yanlı olması tavsiye edilir.

Öngörülen veriler, önemli sapma nedeniyle düz bir çizgi biçimindedir ve bu nedenle veri kümesine tam olarak uymaz. Verilerin eksik takılması, bu tür bir uydurma için kullanılan terimdir. Bu, teori çok basit veya doğrusal olduğunda ortaya çıkar. Aşağıdaki grafiği bunun gibi bir duruma örnek olarak düşünün.

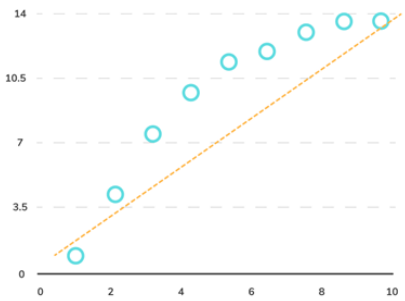

Varyans (değişim):

İstatistiksel tanımın aksine, varyans, verilerin yayılması değil, bir modelin doğruluğunun farklı veri kümelerine göre nasıl değiştiği anlamına gelir. Veri kümeleri arasındaki uyum farklarına varyans denir.

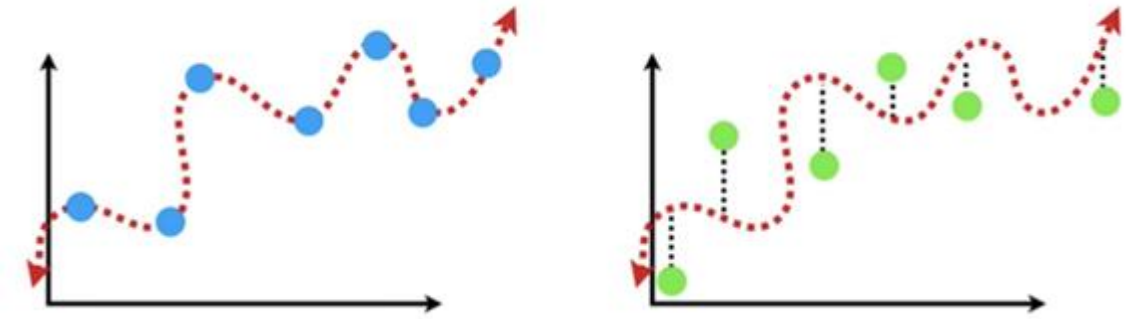

Önceki görüntüdeki dalgalı çizgi, diğer veri kümelerinde kökten farklı bir performans sergiliyor. Bu nedenle, yüksek bir varyansa sahip olduğunu söylüyoruz. Öte yandan, farklı veri kümeleri için karelerin toplamı benzer olduğu için düz çizgi nispeten düşük varyansa sahiptir.

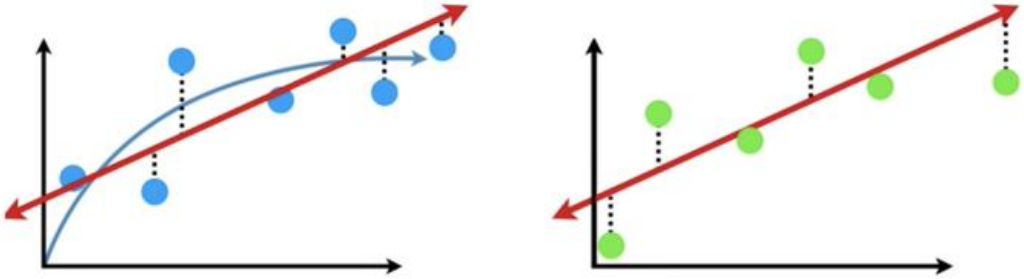

Modelin varyansı, verilerimizin dağılımı hakkında bize bilgi veren belirli bir veri noktası için model tahmininin değişkenliğidir. Doğrulama hatası ile eğitim hatası arasındaki farktır. Yüksek varyansa sahip model, eğitim verilerine çok karmaşık bir uyum sağlar ve bu nedenle yeni verilere tam olarak uymaz. Sonuç olarak, bu tür modeller eğitim verileri üzerinde iyi performans gösterirken, verileri test ederken yüksek hata oranlarına sahiptir.

Bir modelin varyansı aşırı olduğunda, Verilerin Fazla Uyulması olarak adlandırılır. Karmaşık bir eğri ve yüksek mertebeden bir hipotez kullanarak eğitim setini doğru bir şekilde uydurmayı içeren fazla uydurma, bilinmeyen verilerle ilgili hata önemli olduğundan geçerli bir seçenek değildir.

Bir veri modeli eğitilirken varyans minimumda tutulmalıdır.

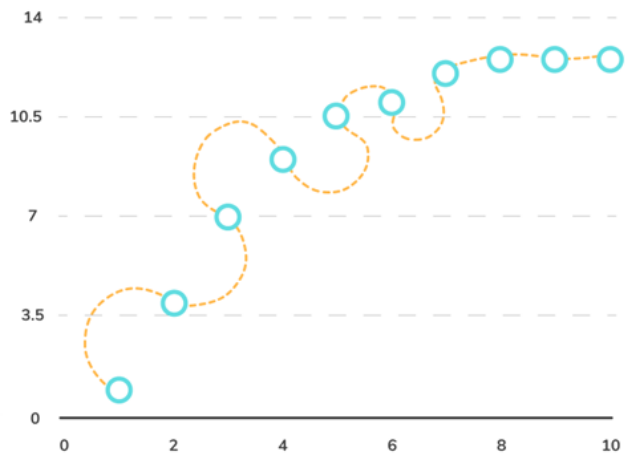

Model, iki hata arasında en iyi dengeyi sağlamak için her zaman düşük bir sapma ve düşük bir varyansı hedeflemelidir.

Makine Öğreniminde Önyargı ve Varyans:

Makine öğrenimi, makinelerin veri analizi yapmasına ve tahminler yapmasına olanak tanıyan bir Yapay Zeka dalıdır. Ancak makine öğrenme modeli doğru değilse tahmin hataları yapabilir ve bu tahmin hataları genellikle Yanlılık ve Varyans olarak bilinir. Makine öğreniminde, model tahminleri ile gerçek tahminler arasında her zaman küçük bir fark olduğu için bu hatalar her zaman mevcut olacaktır. Makine öğrenimi/veri bilimi analistlerinin temel amacı, daha doğru sonuçlar elde etmek için bu hataları azaltmaktır. Bu başlıkta, önyargı ve varyans, Bias-varyans değiş tokuşu, Eksik Uyum ve Fazla Uyum tartışacağız. Ancak başlamadan önce, Makine öğrenimindeki hataların neler olduğunu anlayalım.

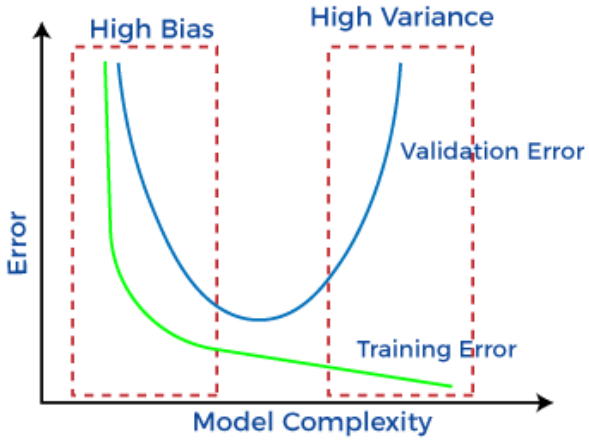

Önyargı (Sapma) nedir?

Genel olarak, bir makine öğrenimi modeli verileri analiz eder, içindeki kalıpları bulur ve tahminlerde bulunur. Eğitim sırasında model, veri kümesindeki bu kalıpları öğrenir ve bunları tahmin için test verilerine uygular. Tahminler yapılırken, model tarafından yapılan tahmin değerleri ile gerçek değerler/beklenen değerler arasında bir fark oluşur ve bu fark bias hataları veya bias kaynaklı hatalar olarak bilinir. Doğrusal Regresyon gibi makine öğrenme algoritmalarının veri noktaları arasındaki gerçek ilişkiyi yakalayamaması olarak tanımlanabilir. Her algoritma bir miktar sapma ile başlar, çünkü modeldeki varsayımlardan sapma oluşur, bu da hedef fonksiyonun öğrenilmesini kolaylaştırır. Bir modelde şunlar bulunur:

- **Düşük Sapma:** Düşük sapma modeli, hedef fonksiyonun biçimi hakkında daha az varsayımda bulunacaktır.
- **Yüksek Önyargı:** Yüksek önyargılı bir model daha fazla varsayımda bulunur ve model, veri setimizin önemli özelliklerini yakalayamaz hale gelir. Yüksek önyargılı bir model de yeni veriler üzerinde iyi performans gösteremez.

Genel olarak, doğrusal bir algoritma, hızlı öğrenmelerini sağladığı için yüksek bir önyargıya sahiptir. Algoritma ne kadar basit olursa, tanıtılması muhtemel önyargı o kadar yüksek olur. Oysa doğrusal olmayan bir algoritma genellikle düşük önyargıya sahiptir.

Düşük önyargılı makine öğrenimi algoritmalarının bazı örnekleri, Karar Ağaçları, k-En Yakın Komşular ve Destek Vektör Makineleridir. Aynı zamanda yüksek yanlılığa sahip bir algoritma Lineer Regresyon, Lineer Diskriminant Analizi ve Lojistik Regresyondur.

Yüksek Önyargıyı Azaltmanın Yolları:

Yüksek yanlılık esas olarak çok basit bir model nedeniyle oluşur. Aşağıda yüksek yanlılığı azaltmanın bazı yolları verilmiştir:

- Model eksik olduğundan girdi özelliklerini artırın.
- Düzenlileştirme süresini azaltın.
- Bazı polinom özelliklerini dahil etmek gibi daha karmaşık modeller kullanın.

Varyans Hatası nedir?

Varyans, farklı eğitim verilerinin kullanılması durumunda tahmindeki varyasyon miktarını belirtecektir. Basit bir deyişle, varyans, rastgele bir değişkenin beklenen değerinden ne kadar farklı olduğunu söyler. İdeal olarak, bir model bir eğitim veri kümesinden diğerine çok fazla farklılık göstermemelidir, bu da algoritmanın girdiler ve çıktı değişkenleri arasındaki gizli eşlemeyi anlamada iyi olması gerektiği anlamına gelir. Varyans hataları, düşük varyanslı veya yüksek varyanslıdır.

Düşük varyans, eğitim veri setindeki değişikliklerle hedef fonksiyonun tahmininde küçük bir değişiklik olduğu anlamına gelir. Aynı zamanda, Yüksek varyans, eğitim veri kümesindeki değişikliklerle hedef fonksiyonun tahmininde büyük bir değişiklik gösterir.

Yüksek varyans gösteren bir model, çok şey öğrenir ve eğitim veri kümesiyle iyi performans gösterir ve görünmeyen veri kümesiyle iyi genelleme yapmaz. Sonuç olarak böyle bir model eğitim veri seti ile iyi sonuçlar verir ancak test veri seti üzerinde yüksek hata oranları gösterir.

Yüksek varyansla model, veri setinden çok fazla şey öğrendiğinden modelin aşırı uyumuna yol açar. Yüksek varyansa sahip bir model aşağıdaki problemlere sahiptir:

- Yüksek bir varyans modeli, fazla uydurmaya yol açar.
- Model karmaşıklıklarını artırın.

Genellikle, doğrusal olmayan algoritmalar, modele uyması için çok fazla esnekliğe sahiptir, yüksek varyansa sahiptir.

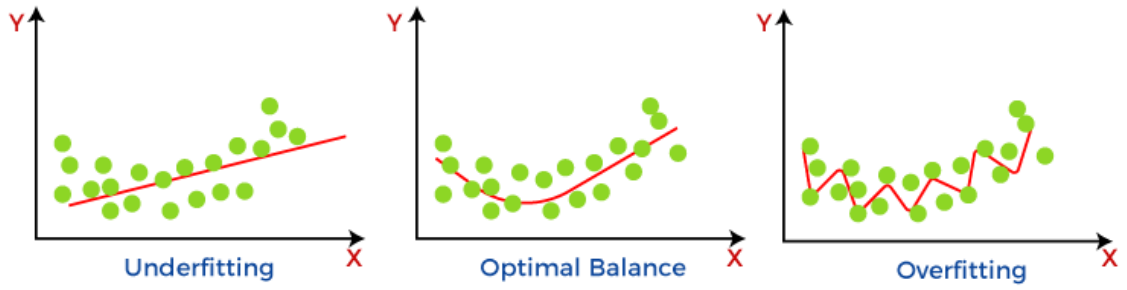

Düşük varyanslı makine öğrenimi algoritmalarının bazı örnekleri, Lineer Regresyon, Lojistik Regresyon ve Lineer diskriminant analizidir. Aynı zamanda, yüksek varyanslı algoritmalar karar ağacı, Destek Vektör Makinesi ve K-en yakın komşulardır.

Yüksek Varyansı Azaltmanın Yolları:

- Bir model fazla takıldığından giriş özelliklerini veya parametre sayısını azaltın.
- Çok karmaşık bir model kullanmayın.
- Eğitim verilerini artırın.
- Düzenleme süresini artırın.

Önyargı Varyansının Farklı Kombinasyonları

Aşağıdaki diyagramla temsil edilen dört olası yanlılık ve varyans kombinasyonu vardır:

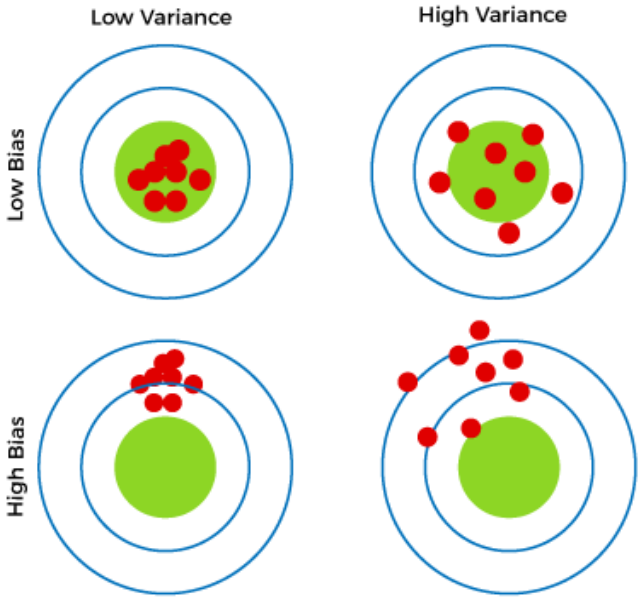

1. Düşük Önyargı, Düşük Varyans: Düşük yanlılık ve düşük varyansın birleşimi, ideal bir makine öğrenimi modelini gösterir. Ancak, pratik olarak mümkün değildir.
2. Düşük Sapma, Yüksek Varyans: Düşük sapma ve yüksek varyans ile model tahminleri ortalama olarak tutarsız ve doğrudur. Bu durum, model çok sayıda parametre ile öğrendiğinde ve dolayısıyla fazla uydurmaya yol açtığında ortaya çıkar.
3. Yüksek Önyargı, Düşük Varyans: Yüksek önyargı ve düşük varyans ile tahminler tutarlıdır ancak ortalama olarak yanlıştır. Bu durum, bir model eğitim veri kümesiyle iyi öğrenmediğinde veya az sayıda parametre kullandığında ortaya çıkar. Modelde yetersiz uyum sorunlarına yol açar.
4. Yüksek Önyargı, Yüksek Varyans: Yüksek yanlılık ve yüksek varyans ile tahminler tutarsız ve ortalama olarak da hatalıdır.

Yüksek Varyans veya Yüksek Önyargı nasıl belirlenir?

Modelin sahip olması durumunda yüksek varyans tespit edilebilir.: Düşük eğitim hatası ve yüksek test hatası.

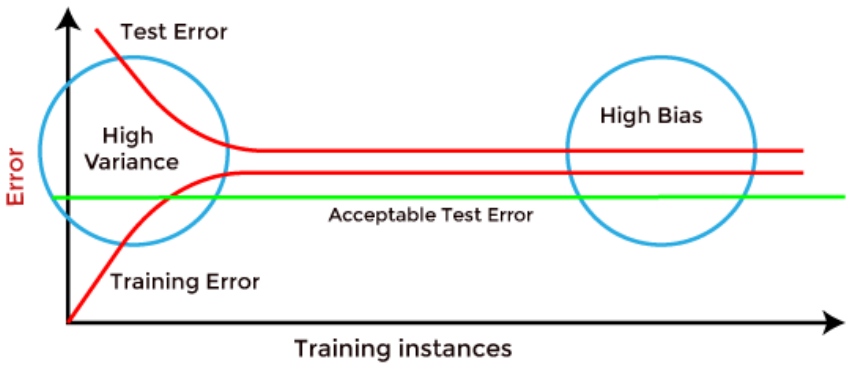

Modelde şunlar varsa Yüksek Önyargı tanımlanabilir: Yüksek eğitim hatası ve test hatası neredeyse eğitim hatasına benzer.

Önyargı-Varyans Dengeleme

Makine öğrenimi modelini oluştururken, modele fazla ve eksik uymayı önlemek için önyargı ve varyansa dikkat etmek gerçekten önemlidir. Model daha az parametre ile çok basitse, düşük varyansa ve yüksek yanlılığa sahip olabilir. Oysa model çok sayıda parametreye sahipse, yüksek varyansa ve düşük yanlılığa sahip olacaktır. Bu nedenle, önyargı ve varyans hataları arasında bir denge yapılması gerekir ve önyargı hatası ile varyans hatası arasındaki bu denge, Önyargı-Varyans değiş tokuşu olarak bilinir.

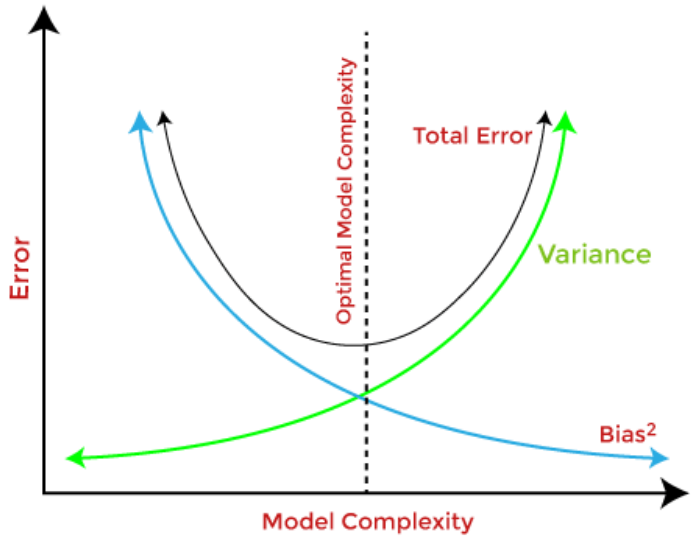

Modelin doğru bir şekilde tahmin edilmesi için algoritmaların düşük bir varyansa ve düşük bir önyargıya ihtiyacı vardır. Ancak bu mümkün değildir çünkü yanlılık ve varyans birbiriyle ilişkilidir:

- Varyansı azaltırsak, yanlılığı artıracaktır.
- Önyargıyı azaltırsak, varyansı artıracaktır.

Önyargı-Varyans değiş tokuşu, denetimli öğrenmede merkezi bir konudur. İdeal olarak, eğitim verilerindeki düzenlilikleri doğru bir şekilde yakalayan ve aynı anda görünmeyen veri kümesiyle iyi bir şekilde genelleştiren bir modele ihtiyacımız var. Ne yazık ki, bunu aynı anda yapmak mümkün değildir. Çünkü yüksek varyanslı bir algoritma, eğitim verileriyle iyi performans gösterebilir, ancak gürültülü verilere fazla uymaya yol açabilir. Oysa yüksek önyargılı algoritma, verilerdeki önemli düzenlilikleri bile yakalayamayan çok basit bir model oluşturur. Bu nedenle, optimal bir model oluşturmak için önyargı ve varyans arasında tatlı bir nokta bulmamız gerekiyor.

Differentiate between bias and variance in the context of deep learning models. How can you achieve balance between the two?

Derin öğrenme modelleri bağlamında yanlılık ve varyans arasında ayrım yapıldığına ikisi arasındaki denge nasıl sağlanabilir?

Tahminleri anlamak söz konusu olduğunda, tahmin hatalarını anlamak çok önemlidir. İndirgenebilir (karesel sapma veya karesel varyanstan kaynaklanan hatalar) ve indirgenemez (bir sistemdeki rastgelelik veya doğal değişkenlik nedeniyle ortaya çıkan ve model değiştirilerek azaltılamayan hatalar) hatalar başlıca iki tür hatadır. İki tür indirgenebilir hata vardır: yanlılık ve varyans. Bu kusurların tam olarak kavranması, fazla ve eksik uyumu önleyerek doğru bir modelin oluşturulmasına yardımcı olur.

Herhangi bir makine öğrenimi modelinin nihai amacı, örneklerden öğrenmek ve onu gerçekleştirmesi için eğittiğimiz görevle ilgili bir dereceye kadar bilgiyi genelleştirmektir. Bazı makine öğrenimi modelleri, bu bilginin altında yatan yapıyı önererek genelleme için bir çerçeve sağlar. Örneğin, doğrusal bir regresyon modeli, onu beslediğimiz bilgiler arasındaki doğrusal ilişkileri öğrenmek için bir çerçeve uygular. Bununla birlikte, bazen çok fazla önceden oluşturulmuş yapıya sahip bir model sağlarız ve modelin örneklerden öğrenme yeteneğini sınırlarız - örneğin, üstel bir veri kümesi üzerinde doğrusal bir model eğittiğimiz durum gibi. Bu durumda, modelimiz önceden empoze edilen yapı ve ilişkiler tarafından önyargılıdır.

Yüksek önyargılı modeller sunulan verilere çok az dikkat eder; bu aynı zamanda yetersiz donatma olarak da bilinir.

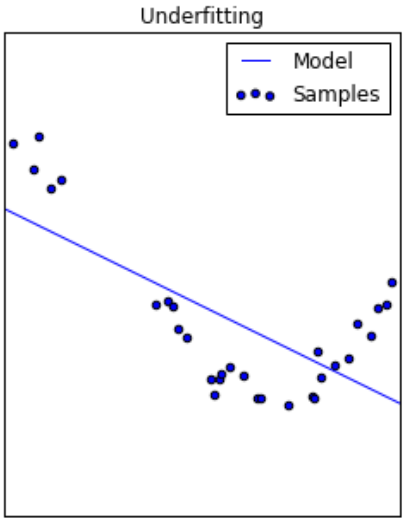

Ayrıca, gerekli tüm bilgileri sunmadan bir görevi gerçekleştirmeyi öğretmeye çalışarak bir modele önyargılı yaklaşmak da mümkündür. Modelin kısıtlamalarının modelin performansını etkilemediğini biliyorsanız, ancak yine de yetersiz uyum belirtileri gözlemliyorsanız, büyük olasılıkla modeli eğitmek için yeterli özellik kullanmıyorsunuzdur.

Diğer uçta, bazen modelimizi eğittiğimizde, eğitim verilerinden çok fazla şey öğrenir. Yani modelimiz sinyale ek olarak verilerdeki gürültüyü de yakalar. Bu, modelde gerçek eğilimi temsil etmeyen vahşi dalgalanmalara neden olabilir; bu durumda modelin yüksek varyansa

sahip olduğunu söylüyoruz. Bu durumda modelimiz, yeni verilere genellemeyi dikkate almadan eğitim verilerine çok fazla önem verdiği için iyi genelleme yapamamaktadır. Başka bir deyişle, modeli eğitim verilerine fazla uydurduk.

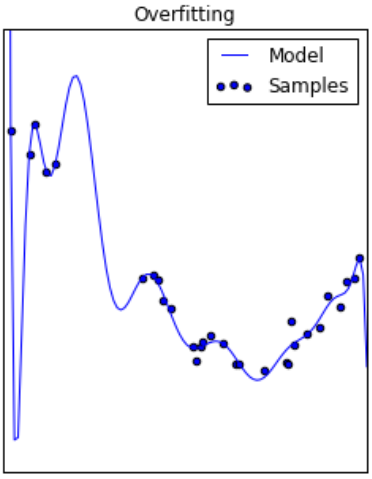

Özetle, yüksek yanlılığa sahip bir model, gerçek eğilimi öğrenmekle sınırlıdır ve verilere uymaz. Yüksek varyansa sahip bir model, eğitim verilerinden çok fazla şey öğrenir ve verilere gereğinden fazla uyar. En iyi model, iki uç noktanın ortasında bir yerde bulunur.

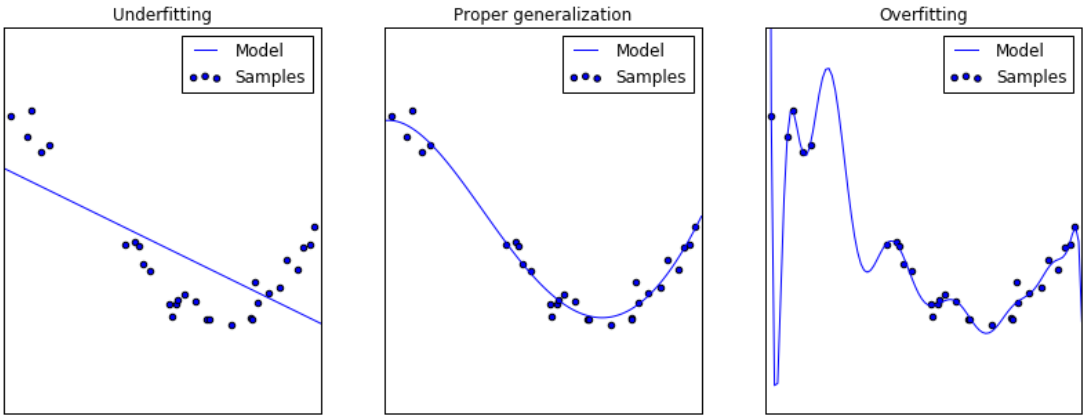

Doğrulama eğrileri

Herhangi bir makine öğrenimi modelinin amacı genellemedir. Doğrulama eğrileri, iyi genelleyen bir model oluşturmak için bir modeli eksik ve fazla uydurma arasındaki tatlı noktayı bulmamızı sağlar.

Tipik bir doğrulama eğrisi, modelin verilere fazla veya eksik uyma eğilimini kontrol eden bazı model hiperparametrelerinin bir fonksiyonu olarak model hatasının bir grafiğidir. Seçtiğiniz parametre, değerlendirdiğiniz belirli modele bağlıdır; örneğin, bir lineer regresyon modeli için polinom özelliklerinin derecesini (tipik olarak bu, bu dereceye kadar polinom özellikleriniz olduğu anlamına gelir) çizmeyi seçebilirsiniz. Genel olarak, seçilen parametre,

modelin karmaşıklığı üzerinde bir dereceye kadar kontrole sahip olacaktır. Bu eğri üzerinde modelin hem eğitim hatasını hem de doğrulama hatasını çiziyoruz. Bu hataların her ikisini bir arada kullanarak, bir modelin yüksek yanlılıktan mı yoksa yüksek varyanstan mı muzdarip olduğunu teşhis edebiliriz.

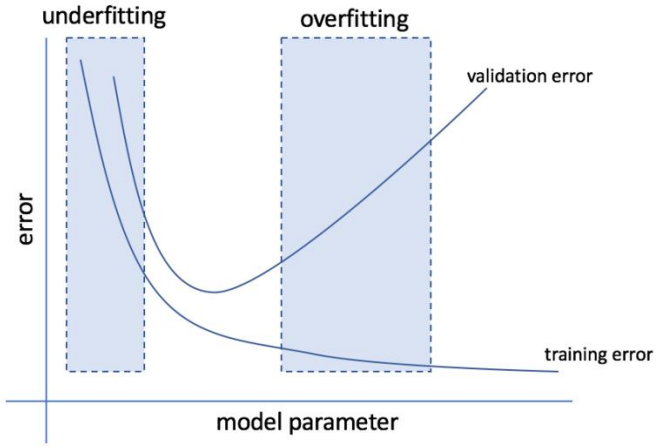

Hem eğitim hatasının hem de doğrulama hatasının yüksek olduğu bölgede, model yüksek yanlılığa tabidir. Burada verilerden ders çıkarılmaz ve kötü performans gösterir.

Eğitim hatasının ve doğrulama hatasının ayrıldığı bölgede, eğitim hatasının düşük kalması ve doğrulama hatasının artmasıyla yüksek varyansın etkilerini görmeye başlıyoruz. Modelimiz eğitim verilerinden yeni verilere genelleme yapamadığı için doğrulama hatası yüksek kalırken, verileri fazla uydurduğumuz ve eğitim örneklerinden çok fazla şey öğrendiğimiz için eğitim hatası düşüktür.

Öğrenme eğrileri

Bir modeldeki yanlılığı ve varyansı teşhis etmek için tartışacağımız ikinci araç, öğrenme eğrileridir. Burada, eğitim örneklerinin sayısının bir fonksiyonu olarak bir modelin hatasını çizeceğiz. Doğrulama eğrilerine benzer şekilde, hem eğitim verileri hem de doğrulama verileri için hatayı çizeceğiz.

Modelimiz yüksek önyargıya sahipse, doğrulama ve eğitim veri kümeleri için yüksek bir hataya oldukça hızlı yakınsama gözlemleyeceğiz. Model yüksek yanlılıktan muzdaripse, daha fazla veri üzerinde eğitim modeli geliştirmek için çok az şey yapacaktır. Bunun nedeni, verilere uymayan modellerin verilere çok az dikkat etmesidir, bu nedenle daha fazla veri beslemek işe yaramaz. Yüksek önyargıdan muzdarip modelleri iyileştirmeye yönelik daha iyi bir yaklaşım, modelin uygun ilişkileri öğrenmek için daha donanımlı olabilmesi için veri kümesine ek özellikler eklemeyi düşünmektir.

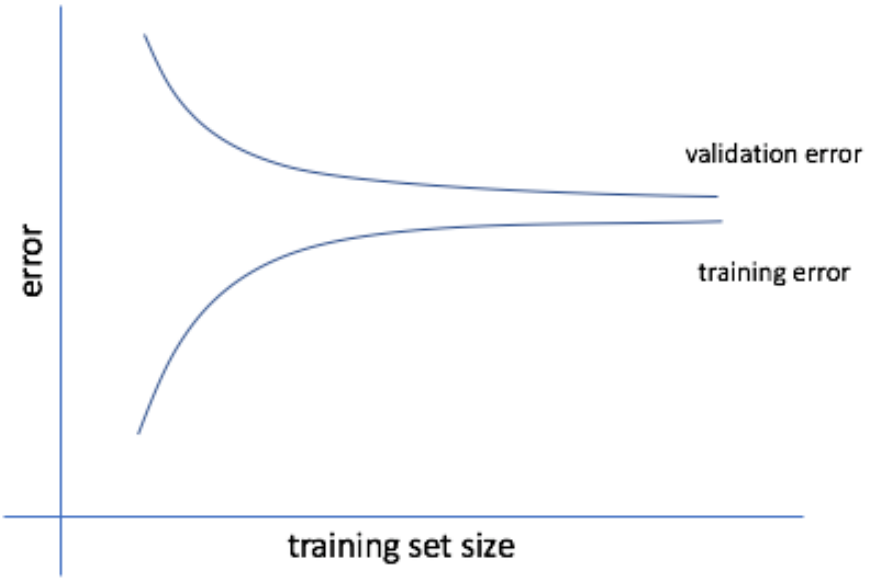

Modelimizin varyansı yüksekse, eğitim ve doğrulama hatası arasında bir boşluk görürüz. Bunun nedeni, modelin eğitim verileri için iyi performans göstermesidir, çünkü bu alt kümeye fazla uyarlanmıştır ve doğru ilişkileri genelleştiremediğinden doğrulama verileri için düşük performans gösterir. Bu durumda, eğitim sırasında daha fazla veri beslemek, modelin performansını iyileştirmeye yardımcı olabilir.

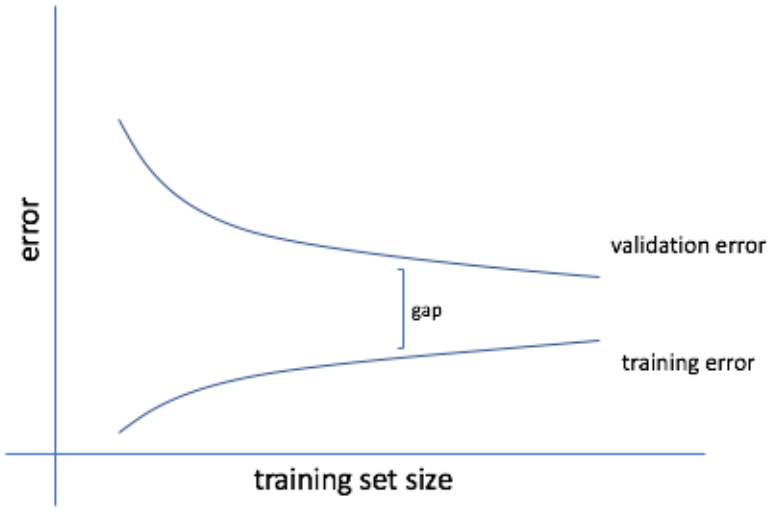

Diğer pratik tavsiyeler

Sınıflandırıcı modellerini değerlendirirken yapacağım bir diğer yaygın şey, veri setini iki boyuta indirgemek ve ardından gözlemleri ve karar sınırını çizmektir. Bazen, performansını değerlendirirken verileri ve modelinizi görsel olarak incelemek faydalı olabilir.

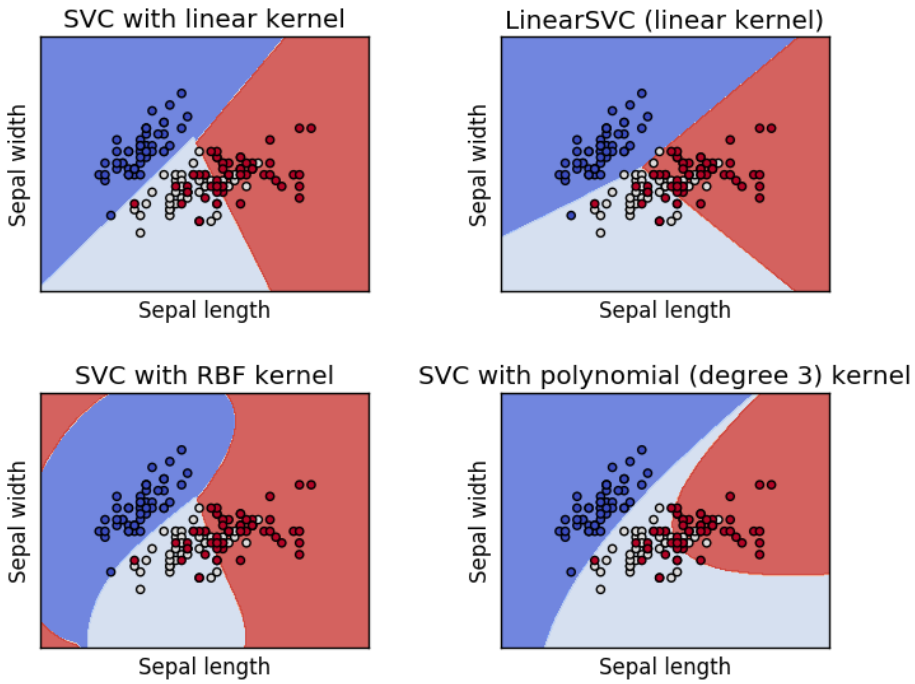

1.6.2. Aşırı Uyum

Makine öğreniminde, istatistiksel bir modelde, temelde yatan asıl ilişki yerine rastgele hata veya gürültüsü ile tanımladığında "aşırı uyum" ortaya çıkar. Bir model aşırı derecede karmaşık olduğunda, eğitim veri türlerinin sayısına göre çok fazla parametrenin olması nedeniyle normal olarak aşırı uyum gözlemlenir ve model, aşırı uyumlu olan zayıf performans sergiler.

Modeli eğitmek için kullanılan kriterler, bir modelin etkinliğini değerlendirmek için kullanılan kriterlerle aynı olmadığından, aşırı uyum olasılığı oluşur.

Küçük bir veritabanınız varsa ve buna dayalı bir modelle gelmek zorunda kalırsanız. Böyle bir durumda çapraz doğrulama olarak bilinen bir teknik kullanabilirsiniz. Bu yöntemde veri kümesi, test ve eğitim veri kümeleri olmak üzere iki bölüme ayrılır, test veri kümesi yalnızca modeli test ederken, eğitim veri kümesinde veri noktaları modelle birlikte gelir. Çapraz doğrulama fikri, eğitim aşamasında modeli "test etmek" için bir veri kümesi tanımlamaktır.

Bir nesneyi tanımlayan temel parametrelerin dışında daha fazla tanım verilirse ağırı uyuma neden olur.

1.7. Makine Öğrenmesi Yaşam Döngüsü

- Veri Toplama
- Veri hazırlama
- Veri Tartışması
- Verileri Analiz Et
- Modeli eğit
- Modeli test edin
- Uygulama

Tüm süreçteki en önemli şey sorunu anlamak ve sorunun amacını bilmektir. Bu nedenle, yaşam döngüsüne başlamadan önce sorunu anlamamız gerekir çünkü iyi sonuç, sorunun daha iyi anlaşılmasına bağlıdır.

Tüm yaşam döngüsü sürecinde bir problemi çözmek için "model" adı verilen bir makine öğrenme sistemi oluşturuyoruz ve bu model "eğitim" verilerek oluşturuluyor. Ancak bir modeli eğitmek için verilere ihtiyacımız var, dolayısıyla yaşam döngüsü veri toplamakla başlıyor.

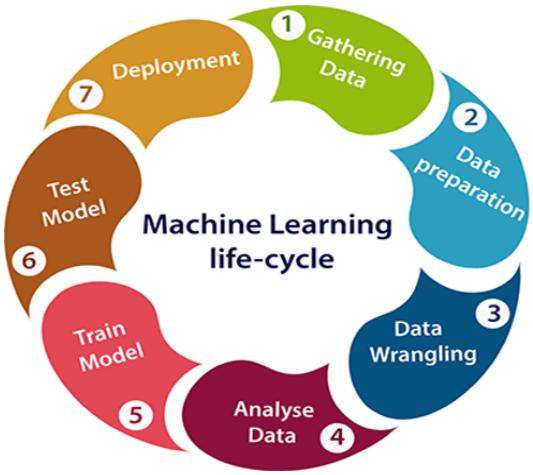

1.7.1. Makine öğrenimi algoritmalarını uygulamak için neden Python?

Python, popüler ve genel amaçlı bir programlama dilidir. Python kullanarak makine öğrenimi algoritmaları yazılabilir. Python'un veri bilimcileri arasında bu kadar popüler olmasının nedeni, Python'un çeşitli modül ve kütüphanelerin halihazırda uygulanmış ve kullanılmaya hazır olmasıdır.

Bazı Python kütüphalerim:

1. Numpy: Python'da bir matematik kitaplığıdır. Hesaplamaların etkili ve verimli bir şekilde yapılmasını sağlar.
2. Scipy: Sinyal işleme, optimizasyon, istatistik ve çok daha fazlasını içeren sayısal algoritmalara özgü araç kutusudur. Scipy, bilimsel ve yüksek performanslı hesaplamalar için işlevsel bir kitaplıktır.
3. Matplotlib: 2D çizimin yanı sıra 3D çizim de sağlayan grafik çizim paketidir.
4. Scikit-learn: Python programlama dili için ücretsiz bir makine öğrenimi kitaplığıdır. Sınıflandırma, regresyon ve kümeleme algoritmalarının çoğuna sahiptir ve Numpy, Scipy gibi Python sayısal kütüphaneleri ile çalışır.

Platformlar

Yapay zeka uygulama geliştiricileri için ürün oluşturmaya yönelik hazır araçlar sağlayan birçok yapay zeka platformu vardır. Yapay zeka platformları akıllı karar verme algoritmalarını ve verilerini birleştirirler. Bazı platformların kullanımı kolaydır, bazıları ise derin kodlama uzmanlığı gerektirir.

Yapay zeka yazılımı geliştirmek için yaygın olarak kullanılan platformlar şunlardır:

- **Google platformu:** Yapay zeka Hub'dan (Yapay zeka sistemleri geliştirme kaynakları), AI Building Blocks adlı araçlardan ve fikirlerden lansmana kadar projeler oluşturmak için kod tabanlı bir veri bilimi ortamı olan AI Platform'dan oluşur.
- **Microsoft Azure:** AI yetenekleri arasında uygulamalar ve aracılar, bilgi madenciliği ve makine öğrenimi hizmetleri bulunur. Platform, modeller oluşturmaya, eğitmeye ve dağıtmaya yardımcı olur. Ayrıca içerik, duygu analizi veya anahtar kelime öbekleri çıkarmada kalıp tanımlamanın yerleşik AI yetenekleriyle bulut arama kullanılabilir.
- **Amazon Makine Öğrenimi:** Hizmetler, her türlü karmaşıklıkta ML modelleri oluşturmaya, eğitmeye ve dağıtmaya yardımcı olur. Amazon'un AWS'si, şirketler ve kuruluşlar için kullanıma hazır analitikler sunar ve uygulama geliştirmeyi basitleştirir. Hizmetler, ürünlerle sorunsuz bir şekilde bütünleşir ve rutin prosedürleri basitleştirir.

Programlama Dilleri, Kitaplıklar ve Çerçeveler

AI uygulamaları için yaygın olarak kullanılan programlama dilleri şunlardır:

- **Python:** Veri yapılarıyla kolayca bütünleşir, standart programlamanın ötesinde benzersiz algoritmalar sunar ve geliştiricinin NumPy, Pandas, Scikit, AIMA vb. gibi kitaplıklar ve araçlarla bilgilerini genişletmesine olanak tanır.
- **Java Script:** İstisna işlemeye yönelik düşünceli bir yaklaşım, çok iş parçacıklı uygulamalar geliştirmeye yönelik araçların kullanılabilirliği ve diziler, listeler ve yapılar için destek açısından farklılık gösteren nesne yönelimli bir dil.
- **C++:** Küresel olarak en hızlı derleme dillerinden biri, performans kaybı olmadan son derece karmaşık mantığı uygulamanıza olanak tanır. C++ paketleri, yüksek hızlı animasyona ve işleme motoruyla anında kullanıcı etkileşimine sahip uygulamalar içindir.

Algoritmaları denemek ve ince ayar yapmak ve yapay zeka yazılımı oluşturmak için farklı AI/ML çerçeveleri, uygulama programlama arayüzleri (Application programming interfaces: API'ler) ve altyapılar arasından seçim yapabilirsiniz.

Örneğin,

- Google, Android ve iOS ile uyumlu ve Node.js ve Cordova'yı destekleyen güçlü bir AI aracı olan API.AI'yi oluşturdu. Bir başka kullanışlı Google ürünü, derin makine öğrenimine dayalı uygulamalar geliştirmeye yardımcı olan açık kaynaklı TensorFlow kitaplığıdır.
- CNTK, Caffe, Keras, PyTorch, Accord.NET, scikit-learn ve Spark MLlib gibi çerçeveler;
- Geliştiricilerin IDE'ler ve Jupyter Notebook'lar gibi grafiksel kullanıcı arabirimlerini kullanmalarına olanak tanıyan Hizmet olarak ML platformları;
- REST uç noktaları olarak sunulan ve sonuçlarla birlikte JSON döndüren API'ler (ör. Azure Konu Algılama API'si).

Takım Planlaması

Rekabetçi bir ürün elde etmek için deneyimli bir ekip oluşturulması gerekir:

- Yönetim ve araştırma — proje yöneticisi, iş analisti;
- Veri analizi — veri bilimciler, veri kümesi biçimlendirme ekibi, makine öğrenimi mühendisleri;
- Geliştirme — çözüm mimarı, ön uç ve arka uç geliştiricileri, CV, NLP, MLOps, DevOps mühendisleri; ve
- Test etme — kalite güvence (QA) mühendisleri.
- Veri Madenciliği ve Modelleme

1.7.2. Makine Öğrenimi Uygulama Adımları

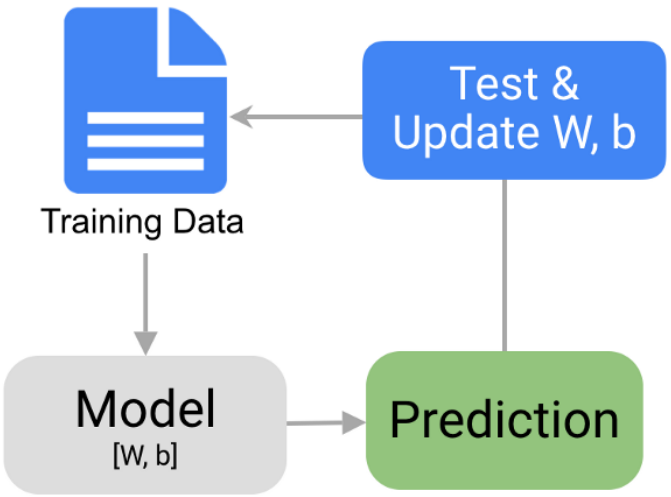

Makinelere zeka aktarma görevi 7 ana adıma ayrılabilir:

1. Veri Toplama:

Bildiğiniz gibi, makineler önce onlara verdiğiniz verilerden öğrenirler. Makine öğrenimi modelinizin doğru kalıpları bulabilmesi için güvenilir verilerin toplanması son derece önemlidir. Makineye beslediğiniz verilerin kalitesi, modelinizin ne kadar doğru olduğunu belirleyecektir. Yanlış veya güncel olmayan verileriniz varsa, konuyla ilgili olmayan yanlış sonuçlara veya tahminlere sahip olursunuz.

Modelinizin sonucunu doğrudan etkileyeceğinden, güvenilir bir kaynaktan gelen verileri kullandığınızdan emin olun. İyi veriler alakalıdır, çok az eksik ve tekrarlanan değer içerir ve mevcut çeşitli alt kategorileri/sınıfları iyi bir şekilde temsil eder.

Veri Toplama, makine öğrenimi yaşam döngüsünün ilk adımıdır. Bu adımın amacı, verilerle ilgili tüm sorunları belirlemek ve elde etmektir. Bu adımda, veriler dosyalar, veritabanı, internet veya mobil cihazlar gibi çeşitli kaynaklardan toplanabileceğinden farklı veri kaynaklarını tanımlamamız gerekir. Yaşam döngüsünün en önemli adımlarından biridir. Toplanan verilerin niceliği ve kalitesi, çıktının verimliliğini belirleyecektir. Veriler ne kadar fazla olursa, tahmin o kadar doğru olur.
Bu adım aşağıdaki görevleri içerir:

- Çeşitli veri kaynaklarını tanımlayın
- Veri topla
- Farklı kaynaklardan elde edilen verileri entegre edin

Yukarıdaki görevi gerçekleştirerek, veri kümesi olarak da adlandırılan tutarlı bir veri kümesi elde ederiz. Daha sonraki adımlarda kullanılacaktır.

2. Verilerin Hazırlanması:

Verileri topladıktan sonra, sonraki adımlar için hazırlamamız gerekiyor. Veri hazırlama, verilerimizi uygun bir yere yerleştirip makine öğrenimi eğitimimizde kullanmak üzere hazırladığımız bir adımdır. Bu adımda, önce tüm veriler bir araya getirilir ve ardından verilerin sıralaması rastgele yapılır. Bu adım iki işleme ayrılabilir:

Veri keşfi: Çalışmamız gereken verilerin doğasını anlamak için kullanılır. Verilerin özelliklerini, biçimini ve kalitesini anlamamız gerekir. Verilerin daha iyi anlaşılması, etkili bir sonuca yol açar. Bunun içinde Korelasyonlar, genel eğilimler ve aykırı değerler buluyoruz.

Veri ön işleme: Şimdi bir sonraki adım, analizi için verilerin ön işlenmesidir.

Verilerinizi aldıktan sonra, hazırlamanız gerekir. Bunu şu şekilde yapabilirsiniz:

- Sahip olduğunuz tüm verileri bir araya getirmek ve rastgele hale getirmek. Bu, verilerin eşit olarak dağıtıldığından ve sıralamanın öğrenme sürecini etkilemediğinden emin olmaya yardımcı olur.
- İstenmeyen verileri, eksik değerleri, satırları ve sütunları, yinelenen değerleri, veri türü dönüştürmeyi vb. kaldırmak için verileri temizleme. Hatta veri kümesini yeniden yapılandırmanız ve satırları ve sütunları veya satır ve sütunların dizinini değiştirmeniz bile gerekebilir.
- Nasıl yapılandırıldığını anlamak ve çeşitli değişkenler ve mevcut sınıflar arasındaki ilişkiyi anlamak için verileri görselleştirin.
- Temizlenen verileri iki kümeye bölme - bir eğitim seti ve bir test seti. Eğitim seti, modelinizin öğrendiği settir. Eğitimden sonra modelinizin doğruluğunu kontrol etmek için bir test seti kullanılır.

Veri tartışması, ham verileri temizleme ve kullanılabilir bir biçime dönüştürme işlemidir. Verilerin temizlenmesi, kullanılacak değişkenin seçilmesi ve bir sonraki adımda analize daha uygun hale getirilmesi için verinin uygun formata dönüştürülmesi işlemidir. Tüm sürecin en önemli adımlarından biridir. Kalite sorunlarını çözmek için verilerin temizlenmesi gerekir.
Bazı veriler yararlı olmayabileceğinden, topladığımız verilerin her zaman bizim kullanımımız için olması gerekli değildir. Gerçek dünya uygulamalarında, toplanan verilerin aşağıdakiler dahil çeşitli sorunları olabilir:

- Eksik Değerler
- Yinelenen veriler
- Geçersiz veri
- Gürültü

Bu nedenle, verileri temizlemek için çeşitli filtreleme teknikleri kullanıyoruz. Sonucun kalitesini olumsuz etkileyebileceğinden yukarıdaki hususların tespit edilip ortadan kaldırılması zorunludur.

Veri Analizi: Artık temizlenen ve hazırlanan veriler analiz aşamasına geçilir. Bu adım şunları içerir:

- Analitik tekniklerin seçimi
- Bina modelleri
- Sonucu gözden geçirin

Bu adımın amacı, çeşitli analitik teknikleri kullanarak verileri analiz etmek ve sonucu gözden geçirmek için bir makine öğrenimi modeli oluşturmaktır. Sınıflandırma, Regresyon, Kümeleme analizi, İlişkilendirme vb. gibi makine öğrenmesi tekniklerini seçtiğimiz, ardından hazırlanan verileri kullanarak modeli oluşturduğumuz ve modeli değerlendirdiğimiz problemlerin türünün belirlenmesi ile başlar. Bu nedenle, bu adımda verileri alıyoruz ve modeli oluşturmak için makine öğrenme algoritmalarını kullanıyoruz.

3. Model Seçimi:

Veri kümesinin yapısına ve problemin türüne göre algoritmalar belirlenir. Problemin türüne göre hangi makine öğrenmesi algoritmasının seçileceğine karar veren deneyim ve yetenek kazanma gereksinimine ihtiyaç vardır. Bir makine öğrenimi modeli, toplanan veriler üzerinde bir makine öğrenimi algoritması çalıştırıldıktan sonra elde ettiğiniz çıktıyı belirler. Eldeki görevle ilgili bir model seçmek önemlidir. Yıllar içinde bilim adamları ve mühendisler konuşma tanıma, görüntü tanıma, tahmin vb. gibi farklı görevlere uygun çeşitli modeller geliştirdiler. Bunun dışında modelinizin sayısal mı yoksa kategorik veriler için mi uygun olduğunu görmeli ve buna göre seçim yapmalısınız.

Eğitim Modeli: Şimdi bir sonraki adım modeli eğitmek, bu adımda modelimizi, problemin daha iyi sonuçlanması için performansını geliştirmek üzere eğitiyoruz. Modeli çeşitli makine öğrenimi algoritmaları kullanarak eğitmek için veri kümelerini kullanıyoruz. Çeşitli kalıpları, kuralları ve özellikleri anlayabilmesi için bir modelin eğitimi gereklidir.

Test Modeli: Makine öğrenimi modelimiz belirli bir veri kümesinde eğitildikten sonra modeli test ederiz. Bu adımda, modelimize bir test veri seti sağlayarak modelimizin doğruluğunu kontrol ederiz.
Modelin test edilmesi, proje veya problemin ihtiyacına göre modelin yüzde doğruluğunu belirler.

4. Modelin Eğitimi:

Eğitim, makine öğreniminde en önemli adımdır. Eğitimde, kalıpları bulmak ve tahminler yapmak için hazırlanan verileri makine öğrenme modelinize iletirsiniz. Görev setini gerçekleştirebilmesi için modelin verilerden öğrenmesiyle sonuçlanır. Zamanla, eğitimle model tahmin etmede daha iyi hale gelir.

5. Modelin Değerlendirilmesi:
Modelinizi eğittikten sonra, nasıl performans gösterdiğini kontrol etmeniz gerekir. Bu, modelin performansını daha önce görülmemiş veriler üzerinde test ederek yapılır. Kullanılan görünmeyen veriler, verilerimizi daha önce böldüğünüz test kümesidir. Eğitim için kullanılan aynı veriler üzerinde test yapılırsa, model verilere zaten alıştığından ve daha önce yaptığı gibi aynı kalıpları bulduğundan doğru bir ölçüm elde edemezsiniz. Bu size orantısız bir şekilde yüksek doğruluk sağlayacaktır. Test verileri üzerinde kullanıldığında, modelinizin nasıl performans göstereceğine ve hızına ilişkin doğru bir ölçüm elde edersiniz.

Dağıtım: Makine öğrenimi yaşam döngüsünün son adımı, modeli gerçek dünya sistemine yerleştirdiğimiz dağıtımdır.
Hazırlanan model, kabul edilebilir bir hızda ihtiyacımıza göre doğru bir sonuç üretiyorsa, modeli gerçek sisteme yerleştiririz. Ancak projeyi dağıtmadan önce, mevcut verileri kullanarak performansını iyileştirip iyileştirmediğini kontrol edeceğiz. Dağıtım aşaması, bir proje için nihai raporun hazırlanmasına benzer.

6. Parametre Ayarı:
Modelinizi oluşturup değerlendirdikten sonra, doğruluğunun herhangi bir şekilde geliştirilip geliştirilemeyeceğine bakın. Bu, modelinizde bulunan parametreleri ayarlayarak yapılır. Parametreler, programcının genel olarak karar verdiği modeldeki değişkenlerdir. Parametrenizin belirli bir değerinde doğruluk maksimum olacaktır. Parametre ayarlama, bu değerleri bulmayı ifade eder. En iyileme yapılacak parametrelerin aralığı belirlenir.

7. Tahmin Yapmak
Sonunda, doğru tahminler yapmak için modelinizi öngörülemeyen, beklenen veriler üzerinde işlem yapılabilir.

1.7.3. Model Eğitimi

Model eğitimi, veri bilimi ekibinin yapılacak tahmin aralığı üzerindeki kayıp işlevini en aza indirmek için bir makine öğrenmesi algoritmasına en iyi ağırlıkları ve önyargıları uydurmak işlemidir.

Kayıp işlevleri, makine öğrenimi algoritmalarının nasıl optimize edileceğini tanımlar. Bir veri bilimi ekibi, proje hedeflerine, kullanılan veri türüne ve algoritma türüne bağlı olarak farklı türde kayıp işlevleri kullanabilir.

Denetimli öğrenme tekniği kullanıldığında, model eğitimi, veri özellikleri ile hedef etiket arasındaki ilişkinin matematiksel bir temsilini oluşturur. Denetimsiz öğrenmede, veri özellikleri arasında benzerler arasındaki ilişkiği bulmaya yönelik matematiksel bir temsil oluşturur.

Model Eğitiminin Önemi

Model eğitimi, makine öğreniminde birincil adımdır ve daha sonra doğrulanabilen, test edilebilen ve optimize edilebilen bir modelle sonuçlanır. Modelin eğitim sırasındaki performansı, nihai olarak gerçek dünyada uygulamaya konduğunda ne kadar iyi çalışacağını belirleyecektir.

Hem eğitim verilerinin kalitesi hem de algoritma seçimi, model eğitim aşamasının merkezinde yer alır. Çoğu durumda, eğitim verileri eğitim ve ardından doğrulama ve test için iki kümeye bölünür.

Model eğitiminde algoritma-model karmaşıklığı, performans, yorumlanabilirlik, bilgisayar kaynak gereksinimleri ve hız gibi her zaman dikkate alınması gereken ek faktörlerden etkilenirr. Bu çeşitli gereksinimlerin dengelenmesi, algoritma seçmeyi ilgili ve karmaşık bir süreç haline getirebilir.

Bir Makine Öğrenimi Modeli Nasıl Eğitilir

Bir modeli eğitmek, mevcut eğitim verilerinizin kullanımını ve veri bilimi ekibinizin zamanını en üst düzeye çıkaran sistematik, tekrarlanabilir bir süreç gerektirir. Eğitim aşamasına başlamadan önce problemin belirlenmesi, veri setinize erişilmesi ve modele sunulacak verilerin temizlenmesi gerekir. Buna ek olarak hangi algoritmaları kullanacağınızı ve hangi parametrelerle (hiperparametreler) çalışacağını belirlemeniz gerekir. Tüm bunları yaptıktan sonra, veri kümesi bir eğitim seti ve bir test seti olarak ayrılabilir, ardından da model algoritmaları eğitim için hazırlanabilir.

Veri Kümesinin Bölünmesi

İlk eğitim verileriniz, dikkatli bir şekilde tahsis edilmesi gereken sınırlı bir kaynaktır. Bazıları modelinizi eğitmek için kullanılabilir ve bazıları modelinizi test etmek için kullanılabilir – ancak her adım için aynı verileri kullanamazsınız. Daha önce karşılaşmadığı yeni bir veri seti vermediğiniz sürece bir modeli doğru şekilde test edemezsiniz. Eğitim verilerini iki veya daha fazla kümeye bölmek, tek bir veri kaynağı kullanarak modeli eğitmenize ve ardından doğrulamanıza olanak tanır. Bu, modelin fazla uyumlu olup olmadığını görmenizi sağlar, yani eğitim verileriyle iyi performans gösterirken test verileriyle zayıf performans gösterir.

Eğitim verilerini bölmenin yaygın bir yolu, çapraz doğrulama kullanmaktır. Örneğin, 10 kat çapraz doğrulamada, veriler on kümeye bölünerek verileri on kez eğitmenize ve test etmenize olanak tanır. Bunu yapmak için:

1. Verileri on eşit parçaya veya katlara bölün.
2. Bir katı, uzatılmış kat olarak atayın.
3. Modeli diğer dokuz kat üzerinde eğitin.
4. Modeli uzatılmış kat üzerinde test edin.

Bu işlemi on kez tekrarlayın, her seferinde ayrı kat olarak farklı bir kat seçin. On uzatma katmanındaki ortalama performans, çapraz doğrulanmış puan olarak adlandırılan performans tahmininizdir.

Test Edilecek Algoritmaların Seçilmesi

Makine öğreniminde, aralarından seçim yapabileceğiniz binlerce algoritma vardır ve bir belirli model için hangisinin en iyi olacağını belirlemenin kesin bir yolu yoktur. Çoğu durumda, doğru bir çalışma modeliyle sonuçlananı bulmak için muhtemelen yüzlerce değilse de düzinelerce algoritma deneyeceksiniz. Aday algoritmaların seçilmesi genellikle aşağıdaki koşullara bağlı olacaktır:

- Eğitim verilerinin boyutu.
- Gerekli çıktının doğruluğu ve yorumlanabilirliği.
- Doğrulukla ters orantılı olan gerekli eğitim süresinin hızı.
- Eğitim verilerinin doğrusallığı.
- Veri setindeki özelliklerin sayısı.

Hiperparametrelerin Ayarlanması

Hiperparametreler, model kurulmadan ve eğitilmeden önce veri bilimi ekibi tarafından belirlenen üst düzey niteliklerdir. Eğitim verilerinden birçok öznitelik öğrenilebilirken, kendi hiperparametrelerini öğrenemezler.

Örnek olarak, bir regresyon algoritması kullanıyorsanız, model verileri analiz ederek regresyon katsayılarını kendisi belirleyebilir. Örnek: f(x)=ax2+bx+c ifadesinde a, b, c katsayıları. Bu katsayılardan birindeki hassasiyet durumuna bağl aşırı sapmaya neden olan

parametreler. Ancak, değişkenlerin fazlalığını düzenlemek için kullanması gereken cezanın gücünü belirleyemez. Başka bir örnek olarak, rastgele orman tekniğini kullanan bir model, karar ağaçlarının nereye bölüneceğini belirleyebilir, ancak kullanılacak ağaç sayısının önceden ayarlanması gerekir.

Modellerin Sığdırılması ve Ayarlanması

Artık veriler hazırlandığına ve modelin hiperparametreleri belirlendiğine göre, sıra modelleri eğitmeye başlamaya geldi. İşlem, esasen, keşfetmeye karar verdiğiniz her bir hiperparametre değeri kümesini kullanarak farklı algoritmalar arasında geçiş yapmaktır.

Bunu yapmak için:

1. Verileri bölün.
2. Bir algoritma seçin.
3. Hiperparametre değerlerini ayarlayın.
4. Modeli eğitin.
5. Başka bir algoritma seçin ve 3. ve 4. adımları tekrarlayın.

Ardından, aynı algoritma için denemek istediğiniz başka bir hiperparametre değeri kümesi seçin, tekrar çapraz doğrulayın ve yeni puanı hesaplayın. Her bir hiperparametre değerini denedikten sonra, ek algoritmalar için aynı adımları tekrarlayabilirsiniz.

Bu denemeleri atletizm yarışları olarak düşünün. Her algoritma, farklı hiperparametre değerleriyle neler yapabileceğini göstermiştir. Artık her algoritmadan en iyi versiyonu seçip onları final yarışmasına gönderebilirsiniz.

En İyi Modelin Seçilmesi

Şimdi, size genel olarak en iyi modeli vereni belirlemek için her bir algoritmanın en iyi sürümlerini test etme zamanı.

1. Test verileriniz üzerinde tahminler yapın.
2. Bu modelin eğitimi sırasında hedef değişkeniniz için temel gerçeği belirleyin.
3. Tahminlerinizden ve kesinlik hedefi değişkeninden performans ölçütlerini belirleyin.
4. Her finalist modeli test verileriyle çalıştırın.

Test tamamlandıktan sonra, hangi modellerin daha iyi olduğunu belirlemek için performanslarını karşılaştırabilirsiniz. Genel kazanan, testte olduğu kadar eğitimde de (en iyisi değilse) iyi performans göstermiş olmalıdır. Aynı zamanda diğer performans ölçütleriniz üzerinde (hız ve deneysel kayıp gibi) iyi performans göstermeli ve – nihayetinde – problem ifadenizde ortaya atılan soruyu yeterince çözmeli veya yanıtlamalıdır.

Model Eğitimine Sistematik Yaklaşım

Sistematik ve tekrarlanabilir bir model eğitim süreci kullanmak, ölçekte başarılı ML/AI modelleri oluşturmayı planlayan herhangi bir kuruluş için büyük önem taşır. Bunun merkezinde, tüm kaynaklarınızın, araçlarınızın, kitaplıklarınızın ve belgelerinizin, işbirliğini engellemek yerine işbirliğini teşvik edecek tek bir kurumsal platformda bulunması yer alır.

Eğitim Modelleri

Veri kümelerini tanımlamak için kullanılan farklı matematiksel modeller arasından seçme işlemi "Eğitim Model Seçimi" olarak bilinir. Model seçimi istatistik, makine öğrenimi ve veri madenciliği alanlarına uygulanmaktadır.

Makine öğrenmesi modelleri iyi performans gösterebilmeleri için çok fazla veri gerektirir. Bir makine öğrenmesi modeli eğitilirken, temsili veri örneklerinin toplanması gerekir. Eğitim setindeki veriler, bir metin topluluğuna, bir resim koleksiyonuna ve bir hizmetin tek tek kullanıcılarından toplanan verilerine kadar değişebilir. Bir modeli eğitmek, tüm ağırlıklar ve etiketli örneklerden eşik seviye değeri bulabilmek için iyi değerleri öğrenmek (belirlemek) anlamına gelir.

Denetimli öğrenmede, bir makine öğrenimi algoritması birçok örneği inceleyerek ve kaybı en aza indiren bir model bulmaya çalışarak bir model oluşturur; bu sürece ampirik risk minimizasyonu denir.

Kayıp, modelin tahmininin ne kadar kötü olduğunu gösteren bir sayıdır. Modelin tahminin performansı yüksekse, kayıp minumumdur; aksi takdirde kayıp daha büyüktür. Makine öğrenmesinde bir modeli eğitmenin amacı, tüm örneklerde ortalama olarak düşük kayıplı bir eşik değer bulmaktır. Örneğin, aşağıdaki şekilde, solda yüksek kayıplı bir modeli ve sağda düşük kayıplı bir modeli gösterilmektedir. Şekilde okların uzunluğu kaybı temsil eder. Mavi çizgiler tahminleri temsil eder.

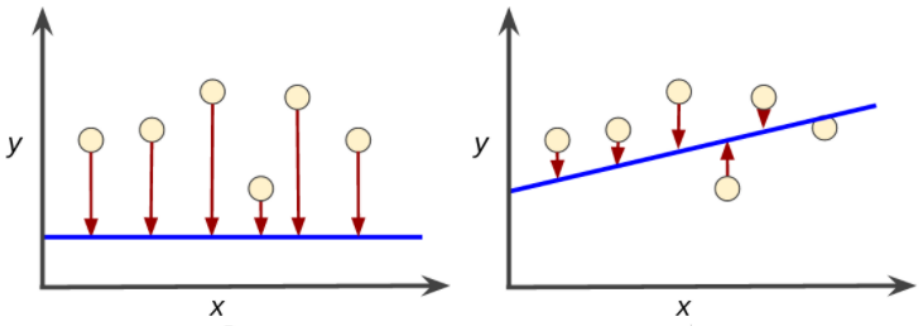

Şekil. Sol modelde yüksek kayıp; doğru modelde düşük kayıp.

Soldaki grafikteki okların sağdaki grafikteki benzerlerinden çok daha uzun olduğuna dikkat edin. Açıkçası, sağdaki çizimdeki çizgi, soldaki grafikteki çizgiden çok daha iyi bir tahmin

modelidir. Kayıpları anlamlı bir şekilde bir araya getirecek bir matematiksel fonksiyon - bir kayıp fonksiyonu – kullanılır.

Sayısal modeller için karesel kayıp adı verilen bir kayıp fonksiyonu kullanır. -1 ile 1 arasındaki farkların karelerinin toplamının toplam eleman sayısına bölümü ile küçük değer elde edilir.

Tek bir örnek için kayıpların karesi *= etiket ve tahmin arasındaki farkın karesi*
= (gözlem - tahmin (x))²
= (y - y ') ²

Ortalama kareler hatası (MSE), tüm veri kümesi boyunca örnek başına düşen ortalama kare kayıptır. MSE'yi hesaplamak için, tek tek örnekler için tüm kayıpların karesi toplanır ve ardından örneklerin sayısına bölünür:

$$MSE = \frac{1}{N}\sum_{(x,y)\in D}(y - yt)^2 = \frac{1}{N}\sum_{i=1}^{N}(y_i - yt_i)^2$$

burada:
(x,y) bir örnektir
x, modelin tahminlerde bulunmak için kullandığı özellikler kümesidir.
y, örneğin etiketidir.
Tahmin(x), yt: özellikler kümesi ile birlikte ağırlıkların ve yanlılığın bir fonksiyonudur.
D, (x,y) çiftler olan birçok etiketli örneği içeren bir veri kümesidir.
N, D içindeki örneklerin sayısıdır.

MSE, makine öğreniminde yaygın olarak kullanılmasına rağmen, ne tek pratik kayıp işlevi ne de tüm koşullar için en iyi kayıp işlevi değildir.

Örnek:
Makine öğrenmesinde bir modeli eğitmenin amacı, tüm örneklerde ortalama olarak düşük kayıplı bir eşik değer bulmaktır. Bu eşik değer ortalama kareler hatası ile bulunur.

i=1...5
örnek değerler, yi= 1, 2, 3, 4, 5 ;
modelin örnekleme tahmin değerleri yti=1, 2, 7, 2, 3
MSE=((1-1)^2+(2-2)^2+(3-7)^2+ (4-2)^2+(5-3)^2)/5= (0+0+16+4+4)/5=24/5=4.8

örnek değerler, yi= 1, 2, 3, 4, 5 ;
modelin örnekleme tahmin değerleri yti=1, 2, 4, 3, 5

MSE=((1-1)^2+(2-2)^2+(3-4)^2+ (4-3)^2+(5-5)^2)/5= (0+0+1+1+0)/5=2/5=0.4
İkinci örnek ortalama düşük kayıplı olduğu görülmektedir.

Toplu öğrenme:
Belirli bir hesaplama programını çözmek için sınıflandırıcılar veya uzmanlar gibi birden çok model stratejik olarak oluşturulur ve birleştirilir. Bu süreç toplu öğrenme olarak bilinir. Toplu öğrenme, bir modelin sınıflandırmasını, tahminini, işlev yaklaşımını geliştirmek için kullanılır. Topluluk öğrenme, daha doğru ve birbirinden bağımsız bileşen sınıflandırıcılar oluşturduğunuzda kullanılır.

Toplu yöntemler:
Topluluk yöntemlerinin iki paradigması şunlardır:

- Sıralı topluluk yöntemleri
- Paralel topluluk yöntemleri

Bir topluluk yönteminin genel ilkesi, tek bir modele göre sağlamlığı artırmak için belirli bir öğrenme algoritması ile oluşturulmuş birkaç modelin tahminlerini birleştirmektir. Torbalama, istikrarsız tahmin veya sınıflandırma şemalarını iyileştirmek için topluluk içinde bir yöntemdir. Arttırma yöntemi, kombine modelin yanlılığını azaltmak için sırayla kullanılır. Artırma ve Torbalama, varyans terimini azaltarak hataları azaltabilir.

Bir öğrenme algoritmasının beklenen hatası, yanlılık ve varyansa ayrıştırılabilir. Bir yanlılık terimi, öğrenme algoritması tarafından üretilen ortalama sınıflandırıcının hedef işlevle ne kadar yakından eşleştiğini ölçer. Varyans terimi, öğrenme algoritmasının tahmininin farklı eğitim setleri için ne kadar dalgalandığını ölçer.

Toplulukta Artımlı Öğrenme algoritması, bir algoritmanın, sınıflandırıcı halihazırda mevcut olan veri kümesinden oluşturulduktan sonra mevcut olabilecek yeni verilerden öğrenme yeteneğidir.

1.7.4. Tahmine Dayalı Modelleme Analitiği

Birçok kuruluş için, büyük veriler (inanılmaz hacimlerde ham yapılandırılmış, yarı yapılandırılmış ve yapılandırılmamış veriler) iş kararlarını destekleyebilen ve operasyonları geliştirebilen, kullanılmayan bir zeka kaynağıdır. Veriler çeşitlenmeye ve değişmeye devam ettikçe, giderek daha fazla kuruluş bu kaynaktan yararlanmak ve verilerden uygun ölçekte yararlanmak için tahmine dayalı analitiği benimsiyor.

Tahmine dayalı analitik nedir?

Yaygın bir yanlış anlama, tahmine dayalı analitik ve makine öğreniminin aynı şey olduğudur. Durum bu değil. Özünde, tahmine dayalı analitik, çeşitli istatistiksel teknikleri (makine öğrenimi, tahmine dayalı modelleme ve veri madenciliği dahil) kapsar ve gelecekteki sonuçları tahmin etmek veya "tahmin etmek" için istatistikleri (hem geçmiş hem de mevcut) kullanır. Bu sonuçlar, örneğin bir müşterinin sergilemesi muhtemel davranışlar veya pazardaki olası değişiklikler olabilir. Tahmine dayalı analitik, geçmişi analiz ederek gelecekteki olası olayları anlamamıza yardımcı olur.

Öte yandan makine öğrenimi, Arthur Samuel'in 1959'daki tanımına göre, "bilgisayarlara açıkça programlanmadan öğrenme yeteneği" veren bilgisayar biliminin bir alt alanıdır. Makine öğrenimi, örüntü tanıma çalışmasından gelişti ve algoritmaların verilerden öğrenebileceği ve veriler üzerinde tahminlerde bulunabileceği fikrini araştırıyor. Ve daha "akıllı" hale gelmeye başladıklarında, bu algoritmalar son derece doğru, veriye dayalı kararlar vermek için program talimatlarının üstesinden gelebilir.

Tahmine dayalı analitik nasıl çalışır?

Tahmine dayalı analitik, tahmine dayalı modelleme tarafından yönlendirilir. Bir süreçten çok bir yaklaşımdır. Tahmine dayalı analitik ve makine öğrenimi el ele gider, çünkü tahmine dayalı modeller tipik olarak bir makine öğrenimi algoritması içerir. Bu modeller, yeni verilere veya değerlere yanıt vermek için zamanla eğitilebilir ve işletmenin ihtiyaç duyduğu sonuçları sağlayabilir. Tahmine dayalı modelleme, makine öğrenimi alanıyla büyük ölçüde örtüşmektedir.

İki tür tahmin modeli vardır. Bunlar, sınıf üyeliğini tahmin eden Sınıflandırma modelleri ve bir sayıyı tahmin eden Regresyon modelleridir. Bu modeller daha sonra algoritmalardan oluşur. Algoritmalar, verilerdeki eğilimleri ve kalıpları belirleyerek veri madenciliği ve istatistiksel analiz gerçekleştirir. Tahmine dayalı analitik yazılım çözümleri, tahmine dayalı modeller oluşturmak için kullanılabilecek yerleşik algoritmalara sahip olacaktır. Algoritmalar, verilerin hangi kategorilere ait olduğunu belirleyen "sınıflandırıcılar" olarak tanımlanır.

Makine Öürenmesinde en yaygın olarak kullanılan tahmin modelleri şunlardır:

- **Karar ağaçları:** Karar ağaçları, çok değişkenli analizin basit ama güçlü bir şeklidir. Verileri dal benzeri bölümlere ayırmanın çeşitli yollarını tanımlayan algoritmalar tarafından üretilirler. Karar ağaçları, verileri girdi değişkenlerinin kategorilerine göre alt kümelere bölerek birinin karar yolunu anlamanıza yardımcı olur.

- **Regresyon (doğrusal ve lojistik):** Regresyon, istatistikte en popüler yöntemlerden biridir. Regresyon analizi, değişkenler arasındaki ilişkileri tahmin eder, büyük ve çeşitli veri kümelerinde anahtar kalıpları ve bunların birbirleriyle nasıl ilişkili olduğunu bulur.

- **Nöral ağlar:** İnsan beynindeki nöronların işleyişinden sonra modellenen sinir ağları (yapay sinir ağları olarak da adlandırılır), çeşitli derin öğrenme teknolojileridir. Genellikle karmaşık örüntü tanıma sorunlarını çözmek için kullanılırlar ve büyük veri kümelerini analiz etmek için inanılmaz derecede faydalıdırlar. Verilerdeki doğrusal olmayan ilişkileri yönetmede harikadırlar ve belirli değişkenler bilinmediğinde iyi çalışırlar.

Diğer sınıflandırıcılar:

- **Zaman Serisi Algoritmaları:** Zaman serisi algoritmaları verileri sırayla çizer ve zaman içindeki sürekli değerleri tahmin etmek için kullanışlıdır.
- **Kümeleme Algoritmaları:** Kümeleme algoritmaları, verileri benzer üyeleri olan gruplar halinde düzenler.
- **Aykırı Değer Algılama Algoritmaları:** Aykırı değer algılama algoritmaları, bir veri kümesi içinde beklenen bir modele veya standarda uymayan öğeleri, olayları veya gözlemleri belirleyerek anormallik algılamaya odaklanır.
- **Topluluk Modelleri:** Topluluk modelleri, tek bir algoritmadan elde edilebilecek olandan daha iyi tahmin performansı elde etmek için birden çok makine öğrenimi algoritması kullanır.
- **Faktör Analizi:** Faktör analizi, değişkenliği tanımlamak için kullanılan ve bağımsız gizil değişkenleri bulmayı amaçlayan bir yöntemdir.
- **Naïve Bayes:** Naïve Bayes sınıflandırıcısı, olasılığı kullanarak belirli bir özellik kümesine dayalı bir sınıf/kategori tahmin etmemizi sağlar.
- **Destek vektör makineleri:** Destek vektör makineleri, verileri analiz etmek ve kalıpları tanımak için ilişkili öğrenme algoritmalarını kullanan denetimli makine öğrenimi teknikleridir.

Her sınıflandırıcı verilere farklı bir şekilde yaklaşır, bu nedenle kuruluşların ihtiyaç duydukları sonuçları alabilmeleri için doğru sınıflandırıcıları ve modelleri seçmeleri gerekir.

Tahmine dayalı analitik ve makine öğrenimi uygulamaları

Verilerle dolup taşan ancak bunları yararlı içgörülere dönüştürmekte zorlanan kuruluşlar için tahmine dayalı analitik ve makine öğrenimi çözüm sağlayabilir. Bir kuruluş ne kadar veriye sahip olursa olsun, bu verileri iç ve dış süreçleri geliştirmek ve hedeflere ulaşmak için kullanamıyorsa, veriler işe yaramaz bir kaynak haline gelir.

Tahmine dayalı analitik, en yaygın olarak güvenlik, pazarlama, operasyonlar, risk ve dolandırıcılık tespiti için kullanılır. Tahmine dayalı analitik ve makine öğreniminin farklı sektörlerde nasıl kullanıldığına dair birkaç örnek:

- Bankacılık ve finansal hizmetler sektöründe, dolandırıcılığı tespit etmek ve azaltmak, piyasa riskini ölçmek, fırsatları belirlemek ve çok daha fazlası için tahmine dayalı analitik ve makine öğrenimi birlikte kullanılır.

- Siber güvenliğin günümüzde her işletmenin gündeminin başında yer almasıyla tahmine dayalı analitik ve makine öğreniminin güvenlikte önemli bir rol oynaması şaşırtıcı olmamalı. Güvenlik kurumları, genellikle hizmetleri ve performansı iyileştirmek için tahmine dayalı analitiği kullanır, aynı zamanda anormallikleri, sahtekarlığı tespit etmek, tüketici davranışını anlamak ve veri güvenliğini geliştirmek için de kullanır.

- Perakendeciler, tüketici davranışını daha iyi anlamak için tahmine dayalı analitik ve makine öğrenimi kullanıyor; kim neyi nereden satın alıyor? Bu sorular, doğru tahmine dayalı modeller ve veri setleri ile kolayca yanıtlanabilir, perakendecilerin önceden plan yapmasına ve mevsimsellik ve tüketici eğilimlerine göre ürün stoklamasına yardımcı olarak yatırım getirisini önemli ölçüde artırır.

Doğru ortamı geliştirmek

Makine öğrenimi ve tahmine dayalı analitik, herhangi bir kuruluş için bir nimet olabilirken, bu çözümleri, günlük operasyonlara nasıl uyacağını düşünmeden gelişigüzel uygulamak, kuruluşun ihtiyaç duyduğu içgörüleri sağlama yeteneklerini büyük ölçüde engeller.

Tahmine dayalı analitik ve makine öğreniminden en iyi şekilde yararlanmak için kuruluşların, bu çözümleri destekleyecek mimariye ve bunları besleyecek ve öğrenmelerine yardımcı olacak yüksek kaliteli verilere sahip olduklarından emin olmaları gerekir. Veri hazırlama ve kalite, tahmine dayalı analitik için kilit unsurlardır. Birden çok platforma yayılabilen ve birden çok büyük veri kaynağı içerebilen girdi verileri, merkezileştirilmiş, birleşik ve tutarlı bir biçimde olmalıdır.

Bunu başarmak için kuruluşlar, verilerin genel yönetimini denetlemek ve yalnızca yüksek kaliteli verilerin yakalanmasını ve kaydedilmesini sağlamak için sağlam bir veri yönetişim programı geliştirmelidir. İkinci olarak, kuruluşların işin her noktasında verimliliği artırmalarını sağlayacağından, tahmine dayalı analitik ve makine öğrenimini içerecek şekilde mevcut

süreçlerin değiştirilmesi gerekecektir. Son olarak, kuruluşların hangi sorunları çözmeye çalıştıklarını bilmeleri gerekir, çünkü bu, kullanacakları en iyi ve en uygun modeli belirlemelerine yardımcı olacaktır.

Tahmine dayalı modelleri anlama

Tipik olarak, bir kuruluşun veri bilimcileri ve BT uzmanları, doğru tahmine dayalı modelleri seçme veya kuruluşun ihtiyaçlarını karşılamak için kendi modellerini oluşturma konusunda görevlendirilir. Ancak bugün, tahmine dayalı analitik ve makine öğrenimi artık yalnızca matematikçilerin, istatistikçilerin ve veri bilimcilerin değil, aynı zamanda iş analistlerinin ve danışmanların da alanıdır. Giderek daha fazla şirket çalışanı bunu içgörüler geliştirmek ve iş operasyonlarını iyileştirmek için kullanıyor - ancak çalışanlar hangi modeli kullanacaklarını, nasıl uygulayacaklarını bilmediklerinde veya hemen bilgiye ihtiyaç duyduklarında sorunlar ortaya çıkıyor.

SAS'ta, kuruluşları veri yönetişimi ve analitiğiyle desteklemek için gelişmiş yazılımlar geliştiriyoruz. Veri yönetişimi çözümlerimiz, kuruluşların yüksek kaliteli verileri korumasına ve aynı ortamda işletme genelindeki operasyonları uyumlu hale getirmesine ve veri sorunlarını saptamasına yardımcı olur. . Bu tahmine dayalı analitik çözümleri, her tür kullanıcının ihtiyaçlarını karşılamak üzere tasarlanmıştır ve tahmine dayalı modelleri hızla dağıtmalarını sağlar.

1.7.5. Öngörülü Modelleme: Türler, Yararlar ve Algoritmalar

Tahmine dayalı modelleme, veri modellemeyi kullanarak gelecekteki sonuçları tahmin etme yöntemidir. Bir işletmenin ileriye dönük yolunu görmesinin ve buna göre planlar yapmasının önde gelen yollarından biridir. Kusursuz olmasa da, bu yöntem yüksek doğruluk oranlarına sahip olma eğilimindedir, bu yüzden bu kadar yaygın olarak kullanılır.

Öngörülü Modelleme Nedir?

Kısacası, tahmine dayalı modelleme, geçmiş ve mevcut verilerin yardımıyla gelecekteki olası sonuçları tahmin etmek ve tahmin etmek için makine öğrenimi ve veri madenciliğini kullanan istatistiksel bir tekniktir. Mevcut ve geçmiş verileri analiz ederek ve öğrendiklerini olası sonuçları tahmin etmek için oluşturulan bir modele yansıtarak çalışır. Tahmine dayalı modelleme, TV reytinglerinden ve bir müşterinin bir sonraki satın alımından kredi risklerine ve kurumsal kazançlara kadar hemen hemen her şeyi tahmin etmek için kullanılabilir.

Tahmine dayalı bir model sabit değildir; temel verilerdeki değişiklikleri dahil etmek için düzenli olarak doğrulanır veya revize edilir. Başka bir deyişle, tek başına yapılan bir tahmin değil. Tahmine dayalı modeller, geçmişte ne olduğuna ve şimdi ne olduğuna bağlı olarak

varsayımlarda bulunur. Gelen, yeni veriler şu anda olanlarda değişiklikler gösteriyorsa, gelecekteki olası sonuç üzerindeki etkisi de yeniden hesaplanmalıdır. Örneğin, bir yazılım şirketi, pazarlama harcamasının etkisine dayalı olarak gelecekteki gelir için bir model oluşturmak için birden fazla bölgedeki pazarlama harcamalarına karşı geçmiş satış verilerini modelleyebilir.

Tahmine dayalı modellerin çoğu hızlı çalışır ve genellikle hesaplamalarını gerçek zamanlı olarak tamamlar. Bu nedenle bankalar ve perakendeciler, örneğin bir çevrimiçi ipotek veya kredi kartı başvurusunun riskini hesaplayabilir ve bu tahmine dayanarak talebi neredeyse anında kabul edebilir veya reddedebilir.

Hesaplamalı biyoloji ve kuantum hesaplamada kullanılanlar gibi bazı kestirimci modeller daha karmaşıktır; ortaya çıkan çıktıların hesaplanması bir kredi kartı uygulamasından daha uzun sürer, ancak bilgi işlem gücü de dahil olmak üzere teknolojik yeteneklerdeki gelişmeler sayesinde geçmişte mümkün olandan çok daha hızlı yapılır.

Tahmine Dayalı Modeller

Neyse ki, tahmine dayalı modellerin her uygulama için sıfırdan oluşturulması gerekmez. Tahmine dayalı analitik araçları, çok çeşitli kullanım durumlarına uygulanabilecek çeşitli incelenmiş modeller ve algoritmalar kullanır.

Tahmine dayalı modelleme teknikleri zamanla mükemmelleştirildi. Daha fazla veri ekledikçe, daha güçlü bilgi işlem, yapay zeka ve makine öğrenimi ekledikçe ve analitikteki genel gelişmeleri gördükçe, bu modellerle daha fazlasını yapabiliyoruz.

İlk beş tahmine dayalı analitik modeli şunlardır:

1) **Sınıflandırma modeli:** En basit model olarak kabul edilir, verileri basit ve doğrudan sorgu yanıtı için sınıflandırır. Örnek bir kullanım durumu, “Bu bir hileli işlem mi?” Sorusuna cevap vermek olabilir.
2) **Kümeleme modeli:** Bu model, verileri ortak niteliklere göre iç içe yerleştirir. Ortak özelliklere veya davranışlara sahip şeyleri veya insanları gruplayarak çalışır ve her grup için daha büyük ölçekte stratejiler planlar. Bir örnek, aynı veya benzer durumdaki diğer kişilerin geçmişte yaptıklarına dayalı olarak bir kredi başvurusunda bulunan kişinin kredi riskinin belirlenmesidir.
3) **Tahmin modeli:** Bu çok popüler bir modeldir ve tarihsel verilerden öğrenmeye dayalı sayısal değeri olan her şey üzerinde çalışır. Örneğin, bir restoranın gelecek hafta ne kadar marul sipariş etmesi gerektiğini veya bir müşteri destek temsilcisinin günde veya haftada kaç aramayı idare edebileceğini yanıtlarken, sistem geçmiş verilere bakar.
4) **Aykırı Değerler modeli:** Bu model, anormal veya aykırı veri noktalarını analiz ederek çalışır. Örneğin, bir banka, bir işlemin müşterinin normal satın alma alışkanlıklarının dışında olup olmadığını veya belirli bir kategorideki harcamanın normal olup olmadığını

sorarak dolandırıcılığı belirlemek için aykırı bir model kullanabilir. Örneğin, kart sahibinin tercih ettiği büyük marketteki bir çamaşır ve kurutma makinesi için kredi kartından 1000$'lık bir ücret endişe verici olmayacaktır, ancak müşterinin başka hiçbir üründen ücret almadığı bir yerde tasarımcı kıyafetlerine harcanan 1.000$, bir hesabın ihlal edildiğinin göstergesi olabilir.

5) **Zaman serisi modeli:** Bu model, zamana dayalı olarak bir dizi veri noktasını değerlendirir. Örneğin, son dört ayda hastaneye kabul edilen felçli hasta sayısı, hastanenin önümüzdeki hafta, gelecek ay veya yılın geri kalanında kaç hasta kabul etmeyi bekleyebileceğini tahmin etmek için kullanılır. Bu nedenle, zaman içinde ölçülen ve karşılaştırılan tek bir metrik, basit bir ortalamadan daha anlamlıdır.

Tahmin Algoritmaları

Tahmine dayalı algoritmalar iki şeyden birini kullanır: makine öğrenimi veya derin öğrenme. Her ikisi de yapay zekanın (AI) alt kümeleridir. Makine öğrenimi (ML), elektronik tablo veya makine verileri gibi yapılandırılmış verileri içerir. Derin öğrenme (DL), video, ses, metin, sosyal medya gönderileri ve görüntüler gibi yapılandırılmamış verilerle ilgilenir; esasen insanların iletişim kurduğu şeyler, sayılar veya metrik okumalar değildir.

Daha yaygın tahmin algoritmalarından bazıları şunlardır:

1) **Rastgele Orman (Random Forest):** Bu algoritma, hiçbiri birbiriyle ilişkili olmayan karar ağaçlarının bir kombinasyonundan türetilmiştir ve büyük miktarda veriyi sınıflandırmak için hem sınıflandırma hem de regresyon kullanabilir.
2) **İki Değer için Genelleştirilmiş Doğrusal Model (GLM: Generalized Linear Model):** Bu algoritma, “en uygun”u bulmak için değişken listesini daraltır. "En uygun" sonucu belirlemek için devrilme noktalarını çözebilir ve veri yakalamayı ve kategorik tahminciler gibi diğer etkileri değiştirebilir, böylece diğer modellerdeki düzenli doğrusal regresyon gibi dezavantajların üstesinden gelebilir.
3) **Gradyan Artırılmış Model (Gradient Boosted Model):** Bu algoritma aynı zamanda birkaç birleşik karar ağacı kullanır, ancak Rastgele Ormanın aksine ağaçlar ilişkilidir. Her seferinde bir ağaç oluşturur, böylece bir sonraki ağacın önceki ağaçtaki kusurları düzeltmesini sağlar. Genellikle arama motoru çıktıları gibi sıralamalarda kullanılır.
4) **K-Means:** Popüler ve hızlı bir algoritma olan K-Means, veri noktalarını benzerliklere göre gruplandırır ve bu nedenle kümeleme modeli için sıklıkla kullanılır. Benzer şekilde astarlı kırmızı yün paltolardan hoşlanan bir milyon veya daha fazla müşteri gibi büyük bir grup içindeki bireylere kişiselleştirilmiş perakende teklifleri gibi şeyleri hızlı bir şekilde sunabilir.
5) **Prophet:** Bu algoritma, envanter ihtiyaçları, satış kotaları ve kaynak tahsisleri gibi kapasite planlaması için zaman serisi veya tahmin modellerinde kullanılır. Oldukça esnektir ve buluşsal yöntemleri ve bir dizi faydalı varsayımı kolayca barındırabilir.

Tahmine Dayalı Modelleme ve Veri Analitiği

Tahmine dayalı modelleme, tahmine dayalı analitik olarak da bilinir. Genel olarak, "tahmini modelleme" terimi akademik ortamlarda tercih edilirken, "tahmini analitik", tahmine dayalı modellemenin ticari uygulamaları için tercih edilen terimdir.

Tahmine dayalı analitiklerin başarılı kullanımı büyük ölçüde yeterli miktarda doğru, temiz ve alakalı verilere sınırsız erişime bağlıdır. Tahmine dayalı modeller, karar ağaçları ve k-ortalama kümeleme kullananlar gibi olağanüstü derecede karmaşık olabilse de, en karmaşık kısım her zaman sinir ağıdır; yani, bilgisayarların sonuçları tahmin etmek için eğitildiği model. Makine öğrenimi, son derece büyük veri kümelerindeki korelasyonları bulmak ve verilerdeki kalıpları "öğrenmek" ve tanımlamak için bir sinir ağı kullanır.

Öngörülü Modellemenin Faydaları

Özetle, tahmine dayalı analitik, iş sonuçlarını tahmin etmede zaman, çaba ve maliyetleri azaltır. Çevresel faktörler, rekabetçi zeka, düzenleme değişiklikleri ve piyasa koşulları gibi değişkenler, nispeten düşük maliyetlerle daha eksiksiz görünümler elde etmek için matematiksel hesaplamaya dahil edilebilir.

İşletmelere fayda sağlayabilecek belirli tahmin türlerinin örnekleri arasında talep tahmini, personel sayısı planlaması, kayıp analizi, dış faktörler, rekabet analizi, filo ve BT (IT) donanım bakımı ve finansal riskler yer alır.

Öngörülü Modellemenin Zorlukları

Tahmine dayalı analitiğin faydalı iş içgörüleri üretmeye odaklanmasını sağlamak önemlidir çünkü bu teknolojinin çıkardığı her şey yararlı değildir. Bazı mayınlı bilgiler, yalnızca meraklı bir zihni tatmin etmede değerlidir ve çok az veya hiç ticari etkisi yoktur. Taraflardan takip edilmek, birkaç işletmenin karşılayabileceği bir dikkat dağıtıcıdır.

Ayrıca, tahmine dayalı modellemede daha fazla veri kullanabilmek sadece bir noktaya kadar bir avantajdır. Çok fazla veri hesaplamayı bozabilir ve anlamsız veya hatalı sonuçlara yol açabilir. Örneğin, dış sıcaklık düştükçe daha fazla kat satılır. Ama sadece bir noktaya kadar. İnsanlar dışarısı -20 derece Fahrenhayt olduğunda, donma noktasının -5 derece altında olduğundan daha fazla palto almazlar. Belli bir noktada, soğuk, palto satın almaya teşvik edecek kadar soğuktur ve daha fazla soğuk sıcaklıklar artık bu kalıbı önemli ölçüde değiştirmez.

Tahmine dayalı modellemede yer alan devasa veri hacimleri ile güvenlik ve mahremiyeti korumak da zor olacaktır. Diğer zorluklar, makine öğreniminin sınırlamalarında yatmaktadır.

Öngörülü Modellemenin Sınırlamaları

Yaygın sınırlamalar ve bunların "en iyi düzeltmeleri" şunları içerir:

1) **Veri etiketlemedeki hatalar:** Bunlar, pekiştirmeli öğrenme veya üretken çekişmeli ağlar (GAN'lar) ile aşılabilir.
2) **Makine öğrenimini eğitmek için gereken çok büyük veri kümelerinin eksikliği:** Olası düzeltme, bir makinenin çok büyük bir veri kümesi yerine az sayıda gösterimden öğrendiği "tek adımda öğrenme"dir.
3) **Makinenin neyi neden yaptığını açıklayamaması:** Makineler insanlar gibi “düşünmez” veya “öğrenmez”. Aynı şekilde, hesaplamaları o kadar olağanüstü karmaşık olabilir ki, insanlar mantığı takip etmek şöyle dursun, bulmakta bile güçlük çekerler. Bütün bunlar, bir makinenin işini açıklamasını veya insanların bunu yapmasını zorlaştırıyor. Yine de, insan güvenliği başta olmak üzere birçok nedenden dolayı model şeffaflığı gereklidir. Umut verici potansiyel düzeltmeler: yerel-yorumlanabilir-modelden bağımsız açıklamalar (LIME: local-interpretable-model-agnostic explanations) ve dikkat teknikleri.
4) **Öğrenmenin genellenebilirliği veya daha doğrusu eksikliği:** İnsanlardan farklı olarak, makineler öğrendiklerini ileriye taşımakta zorluk çekerler. Başka bir deyişle, öğrendiklerini yeni koşullara uygulamakta zorlanırlar. Öğrendiği her şey yalnızca bir kullanım durumu için geçerlidir. Bu, büyük ölçüde, yakında herhangi bir zamanda AI derebeylerinin yükselişi konusunda endişelenmemize gerek yok. Yeniden kullanılabilir olması, yani birden fazla kullanım durumunda yararlı olması için makine öğrenimini kullanan tahmine dayalı modelleme için olası bir düzeltme, aktarım öğrenimidir.
5) **Veri ve algoritmalarda önyargı:** Temsil etmeme, sonuçları çarpıtabilir ve büyük insan gruplarına kötü muamele yapılmasına yol açabilir. Ayrıca, yerleşik önyargıları bulmak ve daha sonra temizlemek zordur. Başka bir deyişle, önyargılar kendi kendini sürdürme eğilimindedir. Bu hareketli bir hedeftir ve henüz net bir düzeltme tespit edilmemiştir.

Öngörülü Modellemenin Geleceği

Tahmine dayalı analitik olarak da bilinen tahmine dayalı modelleme ve makine öğrenimi hala genç ve gelişmekte olan teknolojiler, yani çok daha fazlası var. Teknikler, yöntemler, araçlar ve teknolojiler geliştikçe, işletmelere ve toplumlara faydaları da artacaktır.

Ancak bunlar, işletmelerin daha sonra, teknoloji olgunlaştıktan ve tüm pürüzler çözüldükten sonra benimsemeye gücü yetecek teknolojiler değil. Kısa vadeli avantajlar, geç benimseyen bir kişinin üstesinden gelmesi ve rekabetçi kalması için çok güçlüdür.

Öneri: Teknolojiyi şimdi anlayın ve devreye alın ve ardından teknolojilerdeki müteakip gelişmelerin yanı sıra iş avantajlarını büyütün.

Platformlarda Öngörülü Modelleme

En büyük şirketler dışındaki herkes için, tahmine dayalı analitikten yararlanmak, en kolay şekilde, yerleşik teknolojilere sahip ve önceden eğitilmiş makine öğrenimi içeren ERP sistemleri kullanılarak elde edilir. Örneğin, planlama, tahmin ve bütçeleme özellikleri, değişen piyasa koşullarıyla ilgilenen birden çok senaryoyu hızla modellemek için istatistiksel bir model motoru sağlayabilir.

Başka bir örnek olarak, bir tedarik planlama veya tedarik kapasitesi işlevi, potansiyel olarak geç teslimatları, satın alma veya satış siparişlerini ve diğer riskleri veya etkileri benzer şekilde tahmin edebilir. Şirketlerin üretim veya dağıtım gereksinimlerini karşılamak için dönmelerini sağlamak için alternatif tedarikçiler de gösterge tablosunda temsil edilebilir.

Finansal modelleme, planlama ve bütçeleme, ekibinizi bunaltmadan bu ileri teknolojileri kullanmanın birçok avantajını elde etmek için kilit alanlardır.

2. Matematiksel Programlama

Matematiksel programlama, eniyileme ya da optimizasyon, benzerini model olarak matematiksel programlama ile oluşturma işevinde bir gerçel fonksiyonu minimize ya da maksimize etmek amacı ile gerçek ya da tam sayı değerlerini tanımlı bir aralıkta seçip fonksiyona yerleştirerek sistematik olarak bir problemi incelemek ya da çözmek işlemlerini ifade eder.

Yapay zeka bilimi, mevcut bilgiler dahilinde etkili kararlar alınması için rehberlik sağlamada veya mevcut bilginin uygun bir karara ulaşmak için yetersiz olması durumunda daha fazla bilgi aramada matematiksel modellerin kullanılmasıyla karakterize edilir.

Yapay zeka biliminin özü, model oluşturma yaklaşımıdır; yani, ele alınan kararın en önemli özelliklerini matematiksel bir soyutlama yoluyla yakalama girişimidir. Modeller gerçek dünyanın basitleştirilmiş temsilleridir. Modellerin karar vermede faydalı olabilmesi için anlaşılması ve kullanılması kolay olmalıdır. Aynı zamanda, incelenen problemin özünü karakterize etmek için gereken tüm unsurları dahil ederek karar ortamının tam ve gerçekçi

bir temsilini sağlamalıdırlar. Bu kolay bir iş değildir ancak doğru şekilde yapılırsa, karmaşık karar durumlarında kullanılabilecek müthiş bir araç sağlayacaktır.

Modeller, dikkate alınan alternatifler arasında mevcut olabilecek birçok karşılıklı ilişkiyi hızlı ve etkili bir şekilde açıklayabilir ve mevcut kaynakların ve bu kaynakların kullanımına yönelik taleplerin dayattığı kısıtlamalar dahilinde kullanabilecek eylemlerin sonuçlarını açıkça değerlendirebilir.

Yapay zekada modelin ele alacağı temel sorular formüle edilmeli ve daha sonra modelin sınırlılıklarının farkında olarak modelin sonuçları deneyim ve sezgileri ışığında yorumlamalıdır.

Modelin sağladığı üstün hesaplama yetenekleri ile karar vericinin yüksek yargılama yetenekleri arasındaki tamamlayıcılık, başarılı bir yapay zeka yaklaşımının anahtarıdır.

Son olarak, bu kararı etkili bir şekilde ele almak için gereken bilgi miktarını belirlemesi gereken, karar verme sürecini araştırmak için kullanılan araç değil, incelenen kararın karmaşıklığıdır. Modeller, bilgi için makul olmayan gereksinimler yarattığı için eleştirilir. Aslında bu gerekli değildir. Tam tersine, modeller mevcut bilgilerin mevcut durumu dahilinde oluşturulabilir ve ek bilgi toplamanın fayda – yarar ilişkisinde istenip istenmediğini değerlendirmek için kullanılabilir.

Analitik modelde problem tamamen matematiksel terimlerle temsil edilir; maksimize etmeye veya en aza indirmeye çalıştığımız bir kriter veya amaç için alınması gereken koşulları gösteren bir dizi matematiksel kısıtlamaya tabidir. Model, tüm kısıtlamaları karşılayan ve amaç fonksiyonunun mümkün olan en iyi değerini veren optimal çözümü hesaplar.

Analitik Metotların Kesinlik (Precision) Tanımları

Terim	Tanım
Mutlak standart sapma, s	$s = \sqrt{\frac{\sum_{i=1}^{N} (x_i - \mathbf{x})^2}{N-1}}$
Relatif standart sapma, RSD	$RSD = \frac{s}{\mathbf{x}}$
Ortalamanın standart hatası, s_m	$s_m = \frac{s}{\sqrt{N}}$
Değişme katsayısı, CV	$CV = \frac{s}{x} 100\ (\%)$
Değişme (variance)	s^2

x_i = i'nci ölçmenin sayısal değeri

$\mathbf{x}$ (veya, $x_{ort.}$) = N ölçmenin ortalaması $\quad \mathbf{x} = \frac{\sum_{i=1}^{N} x_i}{N}$

2.1. Optimizasyon (Eniyileme)

Optimizasyon, olası tasarım varyasyonları arasından daha iyi veya daha uygun bir tasarım örneği bulma sürecidir. Parametrelerin değişim aralığı duyarlılığına odaklanılması gerekir. Akort – Uygun olana ayarlama işlevine odaklanır.

Matematiksel modellemede, bir gerçel fonksiyonu minimize ya da maksimize etmek amacı ile gerçek ya da tam sayı değerlerini tanımlı bir aralıkta seçip fonksiyona yerleştirerek sistematik olarak bir problemi incelemek ya da çözmek işlemlerini ifade eder. Optimizasyon, algoritmaları bir öğrenme setindeki kaybı en aza indirirken, makine öğrenmesi görünmeyen numunelerdeki kaybı en aza indiren algoritma kullanılan paremetrelerdeki en iyileme yöntemidir. Hız ve ölçeklenebilirlik optimize edilir.

Optimize edilen parametreler:

- Geometriksel boyutlar, şekiller, yön, miktar vb.
- Malzemeler: kayıpsız, karmaşık, iletken, yalıtka, yarıiletken, anizotropik vb.
- Sınırlar: empedans ya da iletkenlik sınırları, bağlantılı sınır tarama açıları, simetri veya mod durumları, vb.

Parametrik analiz yapılırken:

- Model paremetrelerine atanan değişkenlerle nominal tasarım oluşturulur.
- Bir veya daha fazla değişken tarama tanımı yapılır. Her biri, bir aralıktaki değişken değerleri dizisini belirtir.
- Her varyasyon için tasarım çözülür. Her bir varyasyonun performansı nasıl etkilediğini belirlemek için sonuçlar karşılaştırılır.
- Yalnızca bilgi işlem kaynaklarıyla sınırlanan varyasyon sayısı belirlenir.
- Parametrik analizler, makul aralıktaki değişken değerlerin belirlenmesine yardımcı oldukları için genellikle optimizasyonun öncüleri olarak kullanılır.

Optimizasyon analiz parametreleri:

- Maliyet fonksiyonu: Maliyet işlevini en aza indirir. Bunu, minimum konumun da optimum konum olacak şekilde tanımlanır.
- Kabul Edilebilir Maliyet: Optimizasyonun durduğu maliyet fonksiyonunun değeri (negatif olabilir).
- Hedef Ağırlığı: Maliyet birden çok hedefle çalışıyorsa, her bir hedefe farklı ağırlık verebilirsiniz. Maliyet hesaplamasında daha ağır olan hedefe daha çok önem verilmelidir.
- Adım Boyutu: Aramayı mantıklı kılmak için algoritma, bireysel optimizasyon değişkenleri için minimum ve maksimum adım sınırlarını sınırlar.

- Maliyet Fonksiyonu Gürültü: Elemanlar ağındaki değişiklikler nedeniyle maliyet fonksiyonuna çeşitli gürültü kaynakları getirir. Gürültü, değişimin maliyet fonksiyonunun gerçekleştirilmesini desteklemek için yeterince önemli olup olmadığını gösterir.

Kullanılabilir Optimize Ediciler:

- Quasi Newton
- Sequential Non-Linear Programming (SNLP)
- Sequential Mixed Integer Non-Linear Programming
- Pattern Search
- Genetic Algorithm

Duyarlılık analizi:

- Belirli parametrelerdeki küçük değişikliklere karşı çıkış sinyalerin hassasiyetini belirlemek için kullanılır.
- Tasarım hedeflerinin karşılandığından emin olmak için bir tasarımı tolere edebilir. Örneğin, empedansın iyi eşleştiğinden emin olmak için mikroşerit hattının substrat geçirgenliği için maksimum kabul edilebilir sapmayı belirlenir.
- Bu amaçla parametrik analize tercih edilir. Duyarlılığı belirlemek ve bunu sayısal ağ gürültüsünden ve parametre değerlerindeki büyük ölçekli varyasyonlardan ayırmak için gereken parametre varyasyonlarının dikkatli seçimi.
- Optimetrikler, tasarım noktası ile ilgili parametreleri değiştirir ve ikinci dereceden polinomu istenen çıktıya otomatik olarak uyarlar.

İstatistiksel analiz:

- Parametre değerlerinde rastgele değişikliklere maruz kaldığında bileşenin verimini tahmin etmek için kullanılır.
- Optimetrics, tek tip ve Gauss dağılımı işlevlerini içerir.
  Tekdüze dağılım: Kullanıcı, analiz için değişkenin başlangıç değerinden yüzde toleransını belirtir. Bu tolerans aralığı içindeki değerleri tekdüze olasılık varsayarak çözer.
  Gauss dağılımı: Kullanıcı, dağılımın standart sapmasını ve üst ve alt limitleri belirtir. Gauss olasılığını varsayarak üst ve alt sınırlar arasındaki değerleri çözer.

2.2. Simülasyon (Benzerini Matematiksel Programlama ile Oluşturma)

Simülasyon, gerçek sistemin yapısı ve davranışını anlayabilmek için mantıksal ve matematiksel modelleme kullanılarak deney yapma olanağı sağlayan bir modeldir. Teknik anlamda gerçek bir sisteminin işletilmesinin zaman üzerinden taklit edilmesidir.

Bilgisayar simülasyonu, gerçek veya teorik bir fiziksel sistemin bir matematiksel modelini tasarlama, gerçek dünyada gibi işlevlerini yerine getirme ve çıktısını analiz etme disiplinidir. Günümüzde uygulamalı eğitim alanlarında çok yoğun olarak kullanılmaya başlanılmıştır.

Simülasyon ve makine öğreniminin neredeyse zıt olduğu belirtilse de simülasyon modeli ile, rastgele değişken girdileri tam olarak bilinmez, ancak model genellikle tam olarak bilinir. Makine öğrenimi ile girdiler tam olarak bilinir, ancak eğitimden önce model bilinmez. Her ikisi de bir çıktı verir, ancak belirsizliğin kaynağı farklıdır. Simülasyonda, belirsizliğin ana kaynağı girdilerdedir. Bir dizi olası çıktı elde etmek ve sonuç olasılıkları hakkında açıklamalar yapmak için tekrar tekrar simülasyon yapmamız gerekiyor. Makine öğreniminde, belirsizliğin ana kaynağı modeldedir. Bir tahmin yaparken, model genellikle tahminden %100 emin değildir. Performans artımı ile doğru modele erişilmeye çalışılır.

Çıktı ile ilgili olarak, farklılıklar daha incedir. Her ikisi de bir çıktı verir, ancak belirsizliğin kaynağı farklıdır. Simülasyonda, belirsizliğin ana kaynağı girdilerdedir. Bir dizi olası çıktı elde etmek ve sonuç olasılıkları hakkında açıklamalar yapmak için tekrar tekrar simülasyon yapmamız gerekiyor. Makine öğreniminde, belirsizliğin ana kaynağı modeldedir. Bir tahmin yaparken, model genellikle tahminden %100 emin değildir.

Simülasyon, “gerçek uygulamaları sanal ortamlarda yaparak öğrenme”' ilkesini bünyesinde barındırır - sistem hakkında bilgi edinmek için önce bir çeşit model oluşturmalı ve ardından modeli çalıştırmalıyız.

Simülasyonun Özellikleri:

- Sistem davranışlarını gözler ve tanımlar.
- Gözlenen davranışlar için geçerli olan teori ve hipotezleri kurar.
- Sistem davranışlarını öngörür.
- Sistemi kontrol etme olanağı sağlar.
- Simülasyon, karmaşık sistemlerin tasarımı ve analizinde kullanılır.

Simülasyon aşağıda verilen amaçlardan birisini veya bir kaçını gerçekleştirmek için kullanılır:

- Değerlendirme: Belirlenen kriterlere göre önerilen sistemin ne kadar iyi çalıştığının gösterilmesi
- Karşılaştırma: Önerilen sistem tasarımlarının veya politikaların karşılaştırılması
- Tahmin : Önerilen koşullar altında sistemin performansının tahmin edilmesi
- Duyarlılık Analizi: Sistemin performansı üzerinde hangi faktörlerin etkili olduğunu belirlenmesi
- Optimizasyon: En iyi performans değerini veren faktör düzeylerinin bir kombinasyonunun belirlenmesidir.
- Darboğaz Analizi: Bir sistemde darboğazların belirlenmesi amacıyla simülasyon kullanılır.

İyi bir simülasyon çalışması için aşağıdaki koşulların sağlanması gerekir:

- Kullanıcılar tarafından kolay anlaşılmalıdır.
- Amaçlar veya hedefler doğru tanımlanmalıdır.
- Güçlü ve güvenilir olmalı, model hatalı sonuçlar vermemelidir.
- Kolayca dönüştürülebilir ve kontrol edilebilir olmalıdır.
- Kolayca değişikliklere uyarlanabilmeli kontrol edilebilmeli ve güncelleştirilebilmelidir.
- Hiç bir model tam olarak gerçek sistemin aynısı olamaz. Dolayısıyla simülasyon modeli kurulurken unutulan veya göz ardı edilen bazı ayrıntılar veya yapılan bazı varsayımlar simülasyon sonuçlarını etkileyebilir.
- Simülasyon çalışmasında insan faktörünün olması simülasyon sonuçlarını etkileyebilir.
- Tüm analiz yöntemlerinde olduğu gibi simülasyon çalışmasında da hatalı verilerin kullanılması, parametrelerin yanlış belirlenmesi ve soyutlamanın yanlış yapılması hatalı sonuçlara neden olur.

Simülasyon Ne Zaman Kullanılır? Bazı problemlerin çözümünde simülasyonun kullanılması zorunluluğu ortaya çıkabilir.

Aşağıdaki durumlarda simülasyon kullanılmasında yarar vardır:

- Problemin tam matematiksel modelinin olmaması.
- Matematiksel modelin analitik yaklaşımla çözülememesi.
- Analitik çözümün mümkün fakat bu çözümün matematiksel olarak çok karmaşık olması.
- Analitik çözümün maliyetleri artırması.
- Sistem henüz tasarım aşamasında ise
- Sistemin davranış analizi yapılacaksa
- Pahalı ve riskler içeren işlerde uzman eleman yetiştirmek amacıyla simülasyon kullanılır

Simülasyonun Avantajları:

- Devam eden operasyonları aksatmadan mevcut sistemleri incelemek için kullanılabilir.
- Önerilen sistemler, kaynaklar kullanılmadan önce "test edilebilir".
- Zamanı kontrol etmemize izin verir.
- Darboğazları belirlememize izin verir.
- Sistem performansı için hangi değişkenlerin en önemli olduğuna dair fikir edinmemizi sağlar.

Simülasyonun dezavantajları:

- Model inşa etmek bir bilim olduğu kadar bir sanattır. Analizin kalitesi, modelin kalitesine ve modelleyicinin becerisine bağlıdır.
- Simülasyon sonuçlarının yorumlanması bazen zordur.

- Simülasyon analizi zaman alıcı ve pahalı olabilir. Analitik bir yöntem daha hızlı sonuçlar sağlayacaksa kullanılmamalıdır.
- Analitik yöntemlere göre daha fazla uzmanlık isteyen bir yöntemdir.
- Simülasyon, incelenen sistemin etkinliği hakkında sadece sayısal bilgiler verebilir. Sebepsonuç ilişkileri hakkında sayısal verilerden görülebilecek ipuçları dışında bilgi vermez.
- Uygun olmayan varsayımlar, modeli gerçek sistemden uzaklaştırır ve yanlış kararlar alınmasına neden olur.

2.3. Kalibrasyon ve Kesinlik

Tüm analitik metotlar kantitatif analiz amacıyla kullanıldıklarında kalibrasyona gereksinim vardır. Kalibrasyon, bir ölçüm yapan sistemin çıkışında ölçülen analitik sinyalin doğru olarak saptanması amacıyla yapılan bir işlemdir: Sinyalin (veya yanıtın) kalibrasyonu yapılmadan bir örnek için alınan verilerle doğru kararlar verilemez. Bir kalibrasyon metodunun özgünlüğü kesinlik, doğruluk, eik değer, hassasiyet, algılama sınırları, seçicilik ve uygulanabilir oadaklanma kapasitesine ya da yeteneğine bağlıdır.

Kesinlik (Precision): Metodun tekrar üretilebilirliğinin (reproduciblility) bir ölçüsüdür; aynı şekilde elde edilen sonuçlar birbirlerine ne kadar yakın değerlerdedir? Rastgele (random) hatalar standart sapmayla izlenebilir; genellikle % relatif sapma değeriyle ifade edilir.

3. Makine Öğrenmesi Türleri

1. Denetimli Öğrenme

Denetimli öğrenmede, eğitim verileri için bilinen veya etiketlenmiş veriler kullanılır. Veriler bilindiği için, öğrenme denetlenir, yani başarılı uygulamaya yönlendirilir.

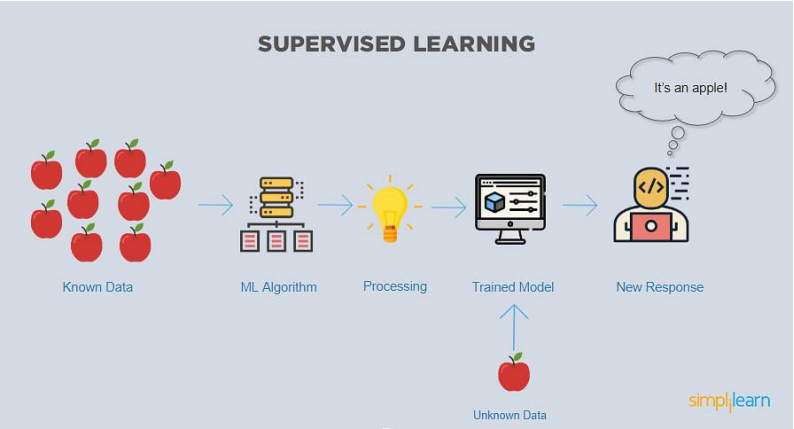

Model iyi eğitildikten sonra, verinin bir elma olduğunu belirleyecek ve istenen yanıtı verecektir.

2. Denetimsiz Öğrenme

Denetimsiz öğrenmede, eğitim verileri bilinmez ve etiketlenmez - bu, daha önce hiç kimsenin verilere bakmadığı anlamına gelir. Denetimsiz öğrenmeye ait eğitilmiş modelde, benzerleri bir araya getirmeye çalışır. Filtreleme yapılır. Bilinen verilerin yönü olmadan girdi, denetimsiz terimin kaynaklandığı algoritmaya yönlendirilemez.

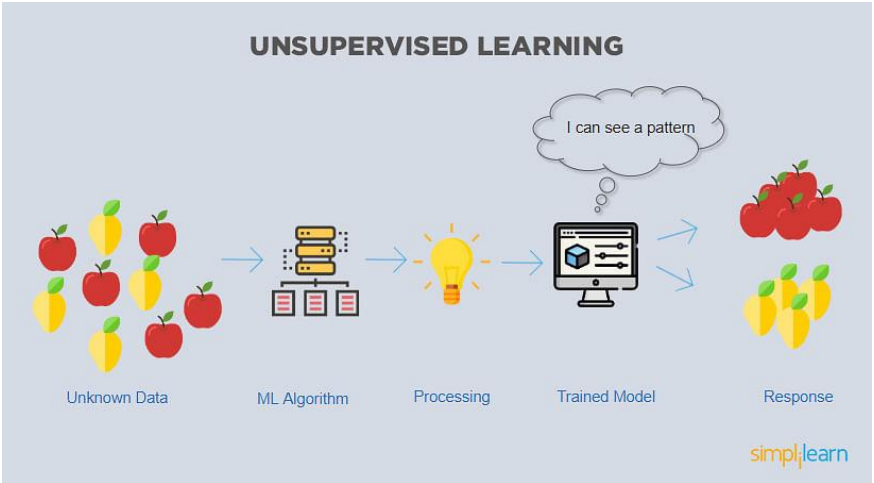

Yukarıdaki örnekte bilinmeyen veriler birbirine benzeyen elma ve armutlardan oluşmaktadır.

3. Pekiştirmeli Öğrenme

Geleneksel veri analizi türleri gibi, algoritma bir deneme yanılma süreci yoluyla verileri keşfeder ve ardından hangi eylemin daha yüksek ödüllerle sonuçlanacağına karar verir. Kümeleme yapılırken başarı oranına bakılır. Üç ana bileşen pekiştirmeli öğrenmeyi oluşturur: etmen, çevre ve eylemler. Etmen, öğrenen veya karar vericidir, çevre, aracının etkileşimde bulunduğu her şeyi içerir ve eylemler, aracının yaptığı şeydir.

Destekleyici öğrenme, aracı belirli bir süre içinde beklenen ödülü en üst düzeye çıkaran eylemleri seçtiğinde gerçekleşir. Temsilci sağlam bir politika çerçevesi içinde çalışırken bunu başarmak en kolay yoldur.

Aşağıda gösterilen süreç akışı, Makine Öğreniminin nasıl çalıştığını gösterir:

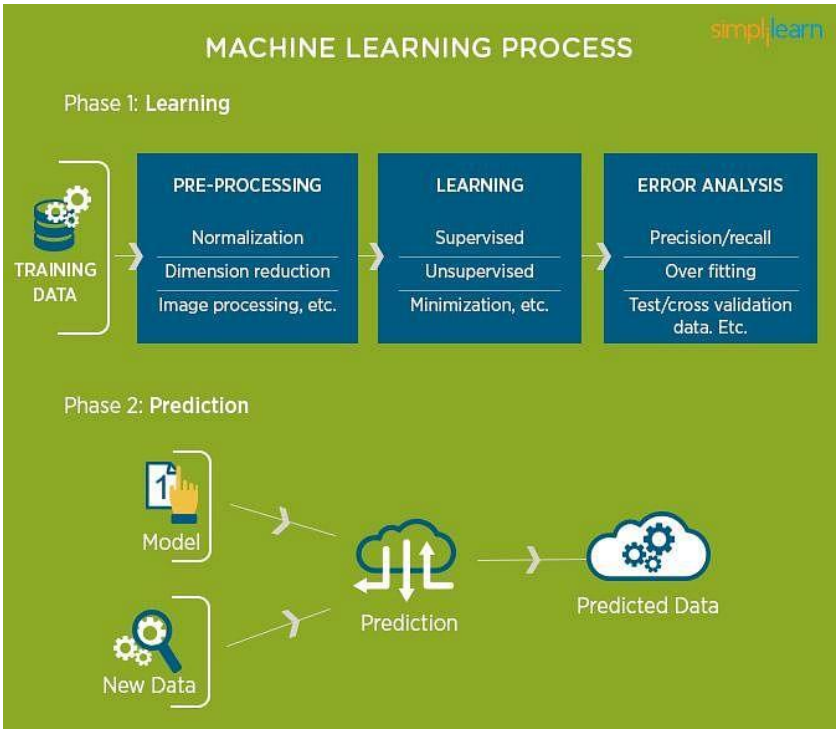

Makine Öğrenimi, matematiksel modellerdeki katsayıları veya algoritmaları otomatikleştirerek ya da otonomlaştırılarak veri çıkarma ve yorumlama şeklini almıştır ve böylece geleneksel istatistiksel ve olasık teknikleri yerini almıştır.

Hangi makine öğrenimi algoritmasının kullanılacağına nasıl karar verilir?
Aralarından seçim yapabilecek düzinelerce farklı algoritma var, ancak en iyi seçenek veya her duruma uyan bir seçenek yok. Çoğu durumda, deneme yanılmaya başvurmanız gerekir.

Ancak, seçimlerinizi daraltmanıza yardımcı olabilecek sorabileceğiniz bazı sorular var.

- Üzerinde çalışacağınız verilerin boyutu nedir?
- Üzerinde çalışacağınız veri türü nedir?

- Verilerden ne tür içgörüler arıyorsunuz?
- Bu içgörüler nasıl kullanılacak, karar vermeme nasıl yardım edecek?

Makine Öğrenimi için En İyi Programlama Dili Nedir?

Matlab, Python, Java Script, C++ mevcut birçok kütüphanenin yanı sıra veri analizi ve veri madenciliği için idealdir ve birçok algoritmayı (sınıflandırma, kümeleme, regresyon ve boyut azaltma için) ve makine öğrenimi modellerini destekler.

Bazı Makine Öğrenimi Algoritmalarına ve Süreçlerine Bir Bakış

Makine Öğreniminin ne olduğunu öğreniyorsanız, standart Makine Öğrenimi algoritmalarına ve süreçlerine aşina olmalısınız. Bunlara sinir ağları, karar ağaçları, rastgele ormanlar, ilişkiler ve dizi keşfi, gradyan artırma ve torbalama, destek vektör makineleri, kendi kendini organize eden haritalar, k-ortalama kümeleme, Bayes ağları, Gauss karışım modelleri ve daha fazlası dahildir.

Büyük verilerden en fazla değeri elde etmek için çeşitli algoritmaları kıyaslayan makine öğrenimi araçları ve süreçleri vardır:

- Kapsamlı veri kalitesi ve yönetimi
- Algoritmalarda modeller ve süreç akışları oluşturmak
- Etkileşimli veri keşfi ve model sonuçlarının görselleştirilmesi
- Uygulamaya yönelik en iyisini hızlı bir şekilde belirlemek için farklı Makine Öğrenimi modellerinin karşılaştırmaları
- En iyi performans gösterenleri belirlemek için otomatikleştirilmiş topluluk modeli değerlendirmesi
- Hızlı bir şekilde tekrarlanabilir, güvenilir sonuçlar alabilmeniz için kolay model dağıtımı
- Veriden karara kadar sürecin otomasyonu için entegre bir uçtan uca platform

Makine öğrenimi (ML) için ön koşullar

Makine Öğrenimi alanında başarılı olmak için birkaç gereksinimin karşılanması gerekir:

1. Matlab, Python, R, Java, JavaScript vb. programlama dilleri hakkında temel bilgi
2. Orta düzeyde istatistik ve olasılık bilgisi
3. Temel lineer cebir bilgisi. Polinom ve denklemlerde katsayıların belirlenmesi. Doğrusal regresyon modelinde, tüm veri noktalarından bir doğru çizilir ve bu doğru yeni değerleri hesaplamak için kullanılır.
4. Hesaplamalarda yorumların anlaşılması (Türev, Integral, Limit)
5. Karar verme için harcanan süreyi azaltmak için ham verilerin nasıl temizleneceği ve istenen formatta yapılandırılacağı bilgisi, veri hazırlama.

3.1. Denetimli Öğrenme

Denetimli öğrenme, etiketli eğitim verilerinden fonksiyonlar oluşturulması ile ilgili makine öğreniminin bir dalıdır. Belki de şimdilik makine ya da derin öğrenmenin ana akımıdır. Denetimli öğrenmede, eğitim verileri bir dizi giriş ve hedef çiftinden oluşur; burada giriş, özelliklerin bir vektörü (Öznitelik Vektörü) olabilir ve hedef, işlevin çıktı vermesi için ne istediğimizi belirtir. Hedef, sınıfın veya değer etiketinin tahmin edilmesidir.

Hedefin türüne bağlı olarak, denetimli öğrenimi kabaca iki kategoriye ayrılır: Sınıflandırma ve regresyon. (Kategori: Aralarında herhangi yönden benzerlik, bağ ya da ilgi bulunması)

- Sınıflandırma, aralarında herhangi yönden benzerlik, bağ ya da ilgi bulunan hedefleri içerir; Görüntü sınıflandırması gibi bazı basit durumlardan makine çevirileri ve resim yazısı gibi bazı gelişmiş konulara kadar değişen örnekler.
- Regresyon, nicel (sayısal) değişkenler arasındaki ilişkilerin belirlendiği hedefleri içerir. Uygulamaların tümü bu kategoriye girer. Örneğin, stok tahmini, görüntü maskeleme ve diğerlerini içerir.

Denetimli öğrenmeye yönelik standart yaklaşım, veri yığınını eğitim kümesi ve test kümesi olarak bölmektir. Eğitim seti, test setinden farklıdır.

Soru: Meyvelerden oluşan torbayı taşıyan robotun taşıdığı torba parçalanır ve tüm meyveler birbirine karışır. Robot, topladığı meyveleri önceden etiketlediğinden hemen ayrıştırır. Bu örnekteki robotta hangi öğrenme algoritması bulunmaktadır?

Soru: Bir çocuğa içinde on aslan, on maymun, on fil ve diğerleri gibi her türden on hayvanın bulunduğu 100 oyuncak hayvan veriyoruz. Daha sonra, çocuğa bir hayvanın farklı özelliklerine (özelliklerine) dayalı olarak farklı hayvan türlerini tanımayı öğretiyoruz. Rengi turuncuysa, o zaman bir aslan olabilir. Gövdesi büyük bir hayvansa, fil olabilir gibi.

Çocuğa hayvanları nasıl ayırt edeceğini öğretiriz, bu nasıl öğrenmeye bir örnektir? Şimdi çocuğa farklı hayvanlar verdiğimizde, onları uygun bir hayvan grubuna ayırabilmelidir.

Aynısı bilgisayarlar için de geçerlidir. Onlara gerçek etiketli değerleri ile binlerce veri noktası sağlıyoruz (Etiketli veriler, özellik değerleriyle birlikte farklı gruplara sınıflandırılır). Daha sonra eğitim döneminde farklı özelliklerinden ders çıkarır. Eğitim dönemi bittikten sonra eğitimli modelimizi tahmin yapmak için kullanabiliriz. Makineyi zaten etiketli verilerle beslediğimizi, bu nedenle tahmin algoritmasının denetimli öğrenmeye dayandığını unutmayın. Kısaca bu örnekteki tahminlerin etiketli verilere dayandığını söyleyebiliriz.

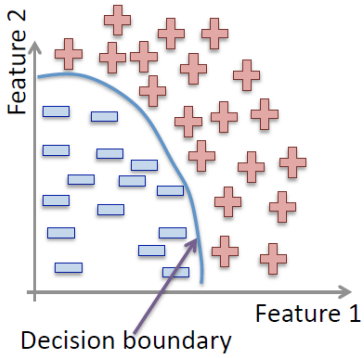

Denetimli öğrenme algoritmaları:

- K-En Yakın Komşular
- Doğrusal Regresyon
- Lojistik regresyon
- Rastgele Orman
- Gradyan Güçlendirilmiş Ağaçlar
- Destek Vektör Makineleri (SVM)
- Naive Bayes
- Nöral ağlar
- Karar ağaçları

Matematiksel modelde, her öğrenme örneği bazen özellik vektörü olarak adlandırılan bir dizi veya vektörle temsil edilir veya öğrenme verileri bir matrisle temsil edilir. Nesnel bir fonksiyonun yinelemeli optimizasyonu yoluyla, denetimli öğrenme algoritmaları yeni girdilerle ilişkili çıktıyı tahmin etmek için kullanılabilecek bir işlevi öğrenir. Zaman içinde çıktılarının veya tahminlerinin doğruluğunu arttıran bir algoritmanın bu görevi yerine getirmeyi öğrendiği söylenir.

Sıralı Denetimli Öğrenme problemlerini çözmek için farklı yöntemler şunlardır:

- Sürgülü pencere yöntemleri
- Tekrarlayan sürgülü pencereler
- Gizli Markow modelleri
- Maksimum entropi Markow modelleri
- Koşullu rastgele alanlar
- Grafik trafo ağları

3.2. Denetimsiz Öğrenme

Öğrenme algoritmasına hiçbir etiket verilmez ve girdisinde yapı bulmak için tek başına bırakılır. Denetimsiz öğrenmeye ait eğitilmiş modelde, benzer gruplarda aynı şeyleri elde edebilmeniz için benzerlerin ve farklı olanların özelliklerini belirlemeye çalışır. Filtreleme yapılır. Denetimsiz öğrenme algoritmaları, yalnızca girdileri içeren bir veri yığınını alır ve verileri yapısal olarak gruplar veya kümeler. Bu nedenle algoritmalar, etiketlenmemiş, sınıflandırılmamış veya kategorize edilmemiş test verilerinden öğrenilir.

Geri bildirime yanıt vermek yerine, denetimsiz öğrenme algoritmaları verilerdeki ortaklıkları ve farklılıkları tanımlar ve her yeni veri parçasında bu tür ortak özelliklerin varlığına veya yokluğuna bağlı olarak tepki verir. Denetimsiz öğrenmenin merkezi bir uygulaması, olasılık yoğunluk işlevini bulmak gibi istatistiklerde yoğunluk tahmini alanındadır.

Denetimsiz Öğrenmenin işlevleri:

- Veri kümeleri bulunur,
- Verilerin düşük boyutlu temsilleri bulunur,
- Verilerde ilginç benzer ve farklı yönler bulunur,
- İlginç koordinatlar ve korelasyonlar elde edilir,
- Yeni gözlemler ya da veritabanı elde edilir.

Soru: Elmalardan oluşan torbayı taşıyan robotun taşıdığı torba parçalanır ve tüm elmalar (Çürük, büyük, küçük, ort boy, ...) birbirine karışır. Robot, topladığı elmaları önceden etiketlemediğinden hemen ayrıştıramaz. Tek başına farklılıkları öğrenerek ayrıştırma işleme yapar. Bu örnekteki robotta hangi öğrenme algoritması bulunmaktadır?

Denetimli öğrenmenin aksine, denetimsiz öğrenme, benzerlikleri ve benzerler arasındaki ilişkileri belirlemek için verilerdeki gizli yapıları tanımlayan bir işlev olan etiketlenmemiş verilerden kaynaklanır. Belki de denetimsiz öğrenmenin en temel türü, boyut azaltma yöntemleridir; PCA genellikle veri ön işlemede kullanılır ve t-SNE genellikle veri görselleştirmede kullanılır. Daha gelişmiş bir dal, verilerdeki gizli kalıpları araştıran ve daha sonra bunlar hakkında tahminlerde bulunan kümelemedir; örnekler arasında K-ortalama kümeleme, Gauss karışım modelleri, gizli Markov modelleri ve diğerleri bulunur.

Denetimsiz öğrenme algoritmalarına örnekler:

- Boyut Küçültme
- Yoğunluk Tahmini
- Pazar Sepeti Analizi
- Üretken düşmanlık ağları (GAN'lar)
- Kümeleme

3.3. Yarı denetimli öğrenme

Yarı denetimli öğrenme, denetimsiz öğrenme (herhangi bir etiketlenmiş öğrenme verisi olmadan) ve denetimli öğrenme (tamamen etiketlenmiş öğrenme verisi ile) arasındadır. Bazı öğrenme örnekleri öğrenme etiketlerinin eksik olmasına rağmen, birçok makine öğrenmesi araştırmacısı, etiketlenmemiş verilerin, az miktarda etiketlenmiş verilerle birlikte kullanıldığında, öğrenme doğruluğunda önemli bir gelişme sağlayabildiğini bulmuştur.

Zayıf denetimli öğrenmede, öğrenme etiketleri gürültülü, sınırlı veya kesin değildir; bununla birlikte, bu etiketlerin elde edilmesi genellikle daha ucuzdur, bu da daha büyük etkili öğrenme setleriyle sonuçlanır.

3.4. Takviyeli Öğrenme

Bir bilgisayar programı, belirli bir hedefi (araç kullanmak veya rakibe karşı oyun oynamak gibi) gerçekleştirmesi gereken **dinamik bir ortamla etkileşime girer**. Sorun alanı içinde ilerledikçe, program ödüllendirmeye benzeyen ve performansı en üst düzeye çıkarmaya çalışan geri bildirim sağlar.

Takviye öğrenmesi, yazılım temsilcilerinin kümülatif ödül kavramını en üst düzeye çıkarmak için bir ortamda nasıl işlem yapmaları gerektiğiyle ilgili bir makine öğrenmesi alanıdır. Genelliği nedeniyle, oyun teorisi, kontrol teorisi, yöneylem araştırması, bilgi teorisi, simülasyon tabanlı optimizasyon, çok etmenli sistemler, sürü zekası, istatistikler ve genetik algoritmalar gibi birçok disiplinde çalışılmaktadır. Makine öğrenmesinde, ortam tipik olarak bir Markov Karar Süreci (MDP) olarak temsil edilir. Pek çok takviye öğrenme algoritması dinamik programlama teknikleri kullanır. Takviye öğrenme algoritmaları, MDP'nin kesin bir matematiksel modeli hakkında bilgi sahibi değildir ve kesin modeller mümkün olmadığında kullanılır. Takviye öğrenme algoritmaları otonom araçlarda veya bir insan rakibe karşı bir oyun oynamayı öğrenmek için kullanılır.

- Q-Learning
- Temporal Difference (TD)
- Monte-Carlo Tree Search (MCTS)
- Asynchronous Actor-Critic Agents (A3C)

3.5. Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, davranışçılıktan esinlenen, öznelerin bir ortamda en yüksek ödül miktarına ulaşabilmesi için hangi eylemleri yapması gerektiğiyle ilgilenen bir makine öğrenmesi yaklaşımıdır. Bu problem, genelliğinden ötürü oyun kuramı, kontrol kuramı, yöneylem araştırması, bilgi kuramı, benzetim tabanlı eniyileme ve istatistik gibi birçok diğer dalda da çalışılmaktadır.

Makine öğrenmesinde, ortam genellikle bir Markov karar süreci (MKS) olarak modellenir, bu bağlamda birçok pekiştirmeli öğrenme algoritması dinamik programlama tekniklerini kullanır. Pekiştirmeli öğrenme algoritmalarının klasik tekniklerden farkı, MKS hakkında ön bilgiye ihtiyaç duymamaları ve kesin yöntemlerin verimsiz kaldığı büyük MKS'ler için kullanılmalarıdır.

Pekiştirmeli öğrenme, doğru girdi/çıktı eşleşmelerinin verilmemesi ve optimal olmayan eylemlerin dışarıdan düzeltilmemesi yönleriyle gözetimli öğrenmeden ayrışır. Dahası, pekiştirmeli öğrenmede bilinmeyen uzayda keşif (İngilizce: exploration) ile mevcut bilgiden istifade (İngilizce: exploitation) arasında bir denge kurma söz konusudur.

3.6. Özellik Öğrenme

Öğrenme algoritmaları, genellikle eğitim sırasında sağlanan girdilerin daha iyi temsilini keşfetmeyi amaçlamaktadır. Klasik örnekler temel bileşenler analizi ve küme analizini içerir. Temsili öğrenme algoritmaları olarak da adlandırılan özellik öğrenme algoritmaları, genellikle girdilerindeki bilgileri korumaya çalışır, ancak sınıflandırma veya tahminler gerçekleştirmeden önce genellikle bir ön işleme adımı olarak yararlı hale getirecek şekilde dönüştürür. Bu teknik, bilinmeyen veri üreten dağıtımdan gelen girdilerin yeniden yapılandırılmasına izin verirken, bu dağıtım altında mantıksız olan yapılandırmalara mutlaka sadık kalmaz. Bu, manuel özellik mühendisliğinin yerini alır ve bir makinenin hem özellikleri öğrenmesini hem de belirli bir görevi gerçekleştirmek için kullanmasını sağlar.

Denetimli özellik öğrenmede, özellikler etiketli giriş verileri kullanılarak öğrenilir. Örnekler arasında yapay sinir ağları, çok katmanlı algılayıcılar ve denetimli sözlük öğrenmesi sayılabilir. Denetimsiz özellik öğrenmede, özellikler etiketlenmemiş girdi verileriyle benzerlikler ve benzerler arası ilişkiler öğrenilir. Örnekler arasında sözlük öğrenmesi, bağımsız bileşen analizi, otomatik kodlayıcılar, matris çarpanlarına ayırma ve çeşitli kümeleme biçimleri bulunmaktadır.

Manifold öğrenme algoritmaları, öğrenilen sunumun düşük boyutlu olması kısıtlaması altında bunu yapmaya çalışır. Seyrek kodlama algoritmaları, öğrenilen sunumun seyrek

olduğu, yani matematiksel modelin çok sayıda sıfır olduğu kısıtlaması altında bunu yapmaya çalışır. Çok satırlı altuzay öğrenme algoritmaları, düşük boyutlu gösterimleri, çok boyutlu veriler için tensör gösterimlerinden, daha yüksek boyutlu vektörlere dönüştürmeden doğrudan öğrenmeyi amaçlamaktadır. Derin öğrenme algoritmaları birden çok temsil düzeyini ya da bir özellik hiyerarşisini keşfeder; daha düşük düzey özellikler (ya da üretme) açısından daha yüksek düzey, daha soyut özellikler tanımlanır. Akıllı bir makinenin, gözlemlenen verileri açıklayan temel varyasyon faktörlerini çözen bir temsili öğrenen bir makine olduğu ileri sürülmüştür.

Özellik öğrenme, makine öğrenmesinin sınıflandırma algoritmalarında, görevlerin genellikle matematiksel ve hesaplamaya uygun olarak işlenmesi için girdi gereksinimi gerçeğiyle motive edilir ve performansı yükseltir. Bununla birlikte, görüntüler, video ve duyusal veriler gibi gerçek dünya verileri, belirli özellikleri algoritmik olarak tanımlama girişimlerine yol açmamıştır. Bir alternatif, açık algoritmalara dayanmadan, bu özellikleri veya gösterimleri muayene yoluyla keşfetmektir.

3.7. Diğer Öğrenme Yöntemleri

Kendi kendine öğrenme:

Makine öğrenmesi paradigması olarak kendi kendine öğrenme 1982'de Crossbar Adaptive Array (CAA) adı verilen kendi kendine öğrenebilen bir sinir ağı ile tanıtıldı. Dış ödüller ve dış öğretmen tavsiyeleri olmayan bir öğrenmedir. CAA kendi kendine öğrenme algoritması, çapraz çubuk şeklinde, sonuç durumlarıyla ilgili eylemler ve duygular (duygular) hakkındaki kararları hesaplar. Sistem, biliş ve duygu arasındaki etkileşim tarafından yönlendirilir. Kendi kendine öğrenme algoritması W = || w (a, s) || bellek matrisini günceller böylece her yinelemede aşağıdaki makine öğrenme rutini yürütülür.

Seyrek sözlük öğrenme:

Seyrek sözlük öğrenmesi, bir eğitim örneğinin temel işlevlerin doğrusal bir kombinasyonu olarak temsil edildiği ve seyrek bir matris olduğu varsayılan bir özellik öğrenme yöntemidir. Yöntem güçlü bir şekilde NP-zordur (Nondeterministic polynomial) ve yaklaşık olarak çözülmesi zordur. Seyrek sözlük öğrenmesi için popüler bir sezgisel yöntem K-SVD algoritmasıdır. Seyrek sözlük öğrenmesi çeşitli bağlamlarda uygulanmıştır. Sınıflandırmada sorun, daha önce görülmemiş bir eğitim örneğinin ait olduğu sınıfı belirlemektir. Her sınıfın önceden oluşturulduğu bir sözlük için, sınıfla ilgili sözlük tarafından en iyi şekilde temsil edilen yeni bir eğitim örneği ilişkilendirilir. Görüntü parazitlenmesinde seyrek sözlük öğrenmesi de uygulanmıştır. Ana fikir, temiz bir görüntü yamasının bir görüntü sözlüğü ile seyrek olarak temsil edilebileceğidir, ancak gürültü olamaz.

Robot öğrenme:

Gelişimsel robot biliminde, robot öğrenme algoritmaları, öz rehberli keşif ve insanlarla sosyal etkileşim yoluyla kümülatif olarak yeni beceriler kazanmak için müfredat olarak da bilinen kendi öğrenme deneyimleri dizilerini oluşturur. Bu robotlar aktif öğrenme, olgunlaşma, motor sinerjileri ve taklit gibi rehberlik mekanizmalarını kullanır.

Birleşik öğrenme:

Birleşik öğrenme, eğitim sürecini ademi merkeziyetçi hale getiren ve verilerini merkezi bir sunucuya göndermeye gerek kalmadan kullanıcıların gizliliğinin korunmasına izin veren eğitim makinesi öğrenme modellerine uyarlanmış bir Dağıtılmış Yapay Zeka biçimidir. Bu, eğitim sürecini birçok cihaza dağıtarak verimliliği de arttırır. Örneğin, Gboard, bireysel aramaları Google'a geri göndermek zorunda kalmadan kullanıcıların cep telefonlarında arama sorgusu tahmin modellerini eğitmek için birleşik makine öğrenmesi kullanır.

Sıralı öğrenme:

Sıralı öğrenme, mantıklı bir şekilde öğretme ve öğrenme yöntemidir.
Sıralı öğrenme sürecini kategorize edebileceğiniz farklı kategoriler:

- Sıra tahmini
- Sıra oluşturma
- Sıra tanıma
- Sıralı karar

Toplu istatistiksel öğrenme:

İstatistiksel öğrenme teknikleri, görünmeyen veya gelecekteki veriler hakkında tahminlerde bulunabilen bir dizi gözlemlenen veriden bir işlevi veya öngörücüyü öğrenmeye izin verir. Bu teknikler, öğrenilen tahmincinin gelecekteki görünmeyen veriler üzerindeki performansı hakkında, veri oluşturma sürecine ilişkin istatistiksel bir varsayıma dayalı olarak garantiler sağlar.

PAC öğrenimi:

PAC (Probably Approximately Correct) öğrenme, öğrenme algoritmalarını ve bunların istatistiksel verimliliklerini analiz etmek için tanıtılan bir öğrenme çerçevesidir.

PCA (Temel Bileşenler Analizi), KPCA (Çekirdek Tabanlı Temel Bileşen Analizi) ve ICA (Bağımsız Bileşen Analizi), boyut azaltma için kullanılan önemli özellik çıkarma teknikleridir.

Endüktif (Tümevarım) makine öğrenimi:

Tümevarımlı makine öğrenimi, bir sistemin gözlemlenen bir dizi örnekten genel bir kural oluşturmaya çalıştığı örneklerle öğrenme sürecini içerir.

Endüktif Mantık Programlama (ILP), arka plan bilgisini ve örnekleri temsil eden mantıksal programlamayı kullanan bir makine öğrenimi alt alanıdır.

Endüktif mantık programlama (ILP), giriş örnekleri, arka plan bilgisi ve hipotezler için tekdüze bir sunum olarak mantık programlamayı kullanarak kural öğrenmeye bir yaklaşımdır. Bilinen arka plan bilgisinin bir kodlaması ve gerçeklerin mantıksal bir veritabanı olarak temsil edilen bir dizi örnek göz önüne alındığında, bir ILP sistemi, tüm olumlu ve olumsuz örnekleri içeren varsayılmış bir mantık programı türetecektir. Endüktif programlama, fonksiyonel programlar gibi hipotezleri (ve sadece mantık programlamayı değil) temsil etmek için her türlü programlama dilini göz önünde bulunduran ilgili bir alandır.

Endüktif mantık programlama özellikle biyoinformatik ve doğal dil işlemede yararlıdır. Gordon Plotkin ve Ehud Shapiro, endüktif makine öğrenmesi için ilk teorik temeli mantıklı bir ortamda ortaya koydu. Shapiro ilk uygulamalarını (Model Çıkarım Sistemi) 1981'de kurdu: mantık programlarını pozitif ve negatif örneklerden indüktif olarak çıkartan bir Prolog programı. Buradaki tümevarım terimi, iyi düzenlenmiş bir kümenin tüm üyeleri için bir özellik kanıtlayan, matematiksel tümevarım yerine gözlemlenen gerçekleri açıklayan bir teori öneren felsefi tümevarım anlamına gelir.

Tembel öğrenme algoritması:

Örnek tabanlı öğrenme algoritması, sınıflandırma gerçekleştirilinceye kadar indüksiyon veya genelleme sürecini geciktirdiği için Tembel öğrenme algoritması olarak da adlandırılır.

4. Makine Öğrenmesinde Model Değerlendirme

Model değerlendirme teknikleri:

Bir modelin performansını değerlendirme teknikleri iki bölüme ayrılabilir: çapraz doğrulama ve bekleme. Bu tekniklerin her ikisi de model performansını değerlendirmek için bir test setinden yararlanır.

Hodout (bekletme) tekniği: Model performansının tarafsız bir tahminini elde etmek önemlidir. Holdout tekniğinin sunduğu şey tam olarak budur. Bu tarafsız tahmini elde etmek için, üzerinde eğittiğimiz verilerden farklı veriler üzerinde bir modeli test ederiz. Bu teknik, bir veri kümesini üç alt kümeye ayırır: eğitim, doğrulama ve test kümeleri.

Eğitim setinin modelin tahmin yapmasına yardımcı olduğunu ve test setinin modelin performansını değerlendirdiğini biliyoruz. Doğrulama seti, modelin parametrelerinde ince ayar yapmak için bir ortam sağlayarak modelin performansını değerlendirmeye de yardımcı olur. Buradan en iyi performans gösteren modeli seçiyoruz.

Holdout yöntemi, çok büyük bir veri kümesiyle uğraşırken idealdir, modelin fazla takılmasını önler ve daha düşük hesaplama maliyetlerine neden olur.

Bir işlev, bir dizi veri noktasına çok sıkı bir şekilde sığdığında, fazla uydurma olarak bilinen bir hata oluşur. Sonuç olarak, bir model görünmeyen veriler üzerinde düşük performans gösterir. Fazla uyumu tespit etmek için önce veri setimizi eğitim ve test setlerine ayırabiliriz. Daha sonra modelin performansını hem eğitim verileri hem de test verileri üzerinde izliyoruz.

Modelimiz, test seti ile karşılaştırıldığında eğitim setinde üstün performans sunuyorsa, fazla uydurma olma ihtimali yüksektir. Örneğin, bir model eğitim setinde %90 doğruluk sunarken test setinde %50 doğruluk sağlayabilir.

Model değerlendirme metrikleri:

Sınıflandırma sorunları için metrikler: Sınıflandırma problemlerine yönelik tahminler dört tür sonuç verir: gerçek pozitifler, gerçek negatifler, yanlış pozitifler ve yanlış negatifler.

Sınıflandırma doğruluğu: Sınıflandırma problemleri için en yaygın değerlendirme ölçütü doğruluktur. Yapılan tahminlerin (veya girdi örneklerinin) toplam sayısına karşı doğru

tahminlerin sayısı olarak alınır. Ancak, bir modeli değerlendirmek için doğruluk kullanıldığı kadar, daha önce belirttiğimiz gibi model performansının net bir göstergesi değildir.

Sınıflandırma doğruluğu, her sınıfa ait örneklerin sayıca eşit olması durumunda en iyi sonucu verir. Bir eğitim setinde X sınıfından %97 ve Y sınıfından %3 örnek içeren bir senaryo düşünün. Bir model, X sınıfındaki her eğitim örneğini tahmin ederek çok kolay bir şekilde %97 eğitim doğruluğu elde edebilir.

Aynı model, %55 X numunesi ve %45 Y numunesi içeren bir test setinde test edildiğinde, test doğruluğu %55'e düşürülür. Bu nedenle sınıflandırma doğruluğu performansın açık bir göstergesi değildir. Yüksek düzeyde doğruluk elde etme konusunda yanlış bir his sağlar.

4.1. Modellerin Seçilmesi ve Değerlendirilmesi

Yüksek düzeyde, Makine Öğrenimi, istatistik ve hesaplamanın birleşimidir. Makine öğreniminin püf noktası, aslında istatistiksel tahminleri içeren algoritmalar veya matematiksel modeller kavramı etrafında döner. Bununla birlikte, herhangi bir modelin veri dağılımına bağlı olarak çeşitli sınırlamaları vardır. Hiçbiri tamamen doğru olamaz, çünkü bunlar sadece tahminlerdir. Bu sınırlamalar yaygın olarak önyargı ve varyans adıyla bilinir.

Yüksek önyargılı bir model, eğitim noktalarına fazla dikkat etmeyerek aşırı basitleştirecektir (örn.: Doğrusal Regresyonda, veri dağılımından bağımsız olarak, model her zaman doğrusal bir ilişki üstlenecektir).

Yüksek varyansa sahip bir model, daha önce görmediği test noktaları için genelleme yapmayarak kendisini eğitim verileriyle sınırlayacaktır (örneğin: Rastgele Orman ile maksimum_derinlik = Yok).

Sorun, rastgele bir orman algoritması ile bir gradyan artırma algoritması arasında veya aynı karar ağacı algoritmasının iki varyasyonu arasında seçim yapmamız gerektiğinde olduğu gibi, sınırlamalar ince olduğunda ortaya çıkar. Her ikisi de yüksek varyansa ve düşük önyargıya sahip olma eğiliminde olacaktır.

İşte burada model seçimi ve model değerlendirmesi devreye giriyor:

- Model seçimi ve model değerlendirmesi nedir?
- Etkili model seçim yöntemleri (yeniden örnekleme ve olasılıksal yaklaşımlar)
- Popüler model değerlendirme yöntemleri
- Önemli Makine Öğrenimi modeli ödünleşimleri

Model değerlendirmesi, test verileri üzerindeki modellerin doğruluğunu değerlendirme yöntemidir. Test verileri, model tarafından daha önce görülmeyen veri noktalarından oluşur.

Model seçimi, bireysel modeller gerekli kriterlere göre değerlendirildikten sonra en iyi modeli seçme tekniğidir.

Yeniden örnekleme yöntemleri, adından da anlaşılacağı gibi, modelin eğitim almadığı veri örneklerinde iyi performans gösterip göstermediğini kontrol etmek için veri örneklerini yeniden düzenlemenin basit tekniklerdir. Başka bir deyişle, yeniden örnekleme, modelin iyi bir genelleme yapıp yapmayacağını anlamamıza yardımcı olur.

Rastgele Bölmeler, verilerin bir yüzdesini eğitim, test ve tercihen doğrulama kümelerine rastgele örneklemek için kullanılır. Bu yöntemin avantajı, orijinal popülasyonun her üç kümede de iyi temsil edilme şansının yüksek olmasıdır. Daha resmi bir ifadeyle, rastgele bölme, verilerin önyargılı bir şekilde örneklenmesini önleyecektir.

Model seçiminde doğrulama setinin kullanımına dikkat etmek çok önemlidir. Doğrulama seti ikinci test setidir ve biri neden iki test seti var diye sorabilir. Özellik seçimi ve model ayarlama sürecinde, model değerlendirmesi için test seti kullanılır. Bu, model parametrelerinin ve özellik setinin, test setinde en uygun sonucu verecek şekilde seçildiği anlamına gelir. Böylece, son değerlendirme için tamamen görünmeyen veri noktalarına sahip (tuning ve özellik seçim modüllerinde kullanılmamış) doğrulama seti kullanılır.

Zamana Dayalı Bölme: Rastgele bölmelerin mümkün olmadığı bazı veri türleri vardır. Örneğin, hava tahmini için bir model eğitmemiz gerekiyorsa, verileri rastgele eğitim ve test setlerine bölemeyiz. Bu mevsimsel deseni karıştıracak! Bu tür veriler genellikle - Zaman Serileri terimi ile anılır.

Bu gibi durumlarda, zamana dayalı bir bölme kullanılır. Eğitim seti içinde bulunulan yılın son üç yılı ve 10 ayı için veri içerebilir. Son iki ay, test veya doğrulama seti için ayrılabilir.

Ayrıca, modelin belirli bir tarihe kadar eğitildiği ve eğitim penceresinin bir gün kaymaya devam edeceği şekilde ileriki tarihlerde yinelemeli olarak test edildiği bir pencere kümeleri kavramı da vardır (sonuç olarak, test seti de bir gün azalır). Bu yöntemin avantajı, modeli stabilize etmesi ve test seti çok küçük olduğunda (örneğin 3 ila 7 gün) fazla takmayı önlemesidir.

Ancak, zaman serisi verilerinin dezavantajı, olayların veya veri noktalarının karşılıklı olarak bağımsız olmamasıdır. Bir olay, ardından gelen her veri girişini etkileyebilir.

Örneğin, iktidar partisindeki bir değişiklik, önümüzdeki yıllarda nüfus istatistiklerini önemli ölçüde değiştirebilir. Veya kötü şöhretli koronavirüs pandemisi, önümüzdeki birkaç yıl için ekonomik veriler üzerinde büyük bir etkiye sahip olacak.

Böyle bir durumda hiçbir makine öğrenme modeli geçmiş verilerden öğrenemez çünkü olaydan önceki ve sonraki veri noktaları büyük farklılıklar gösterir.

K-Katlama Çapraz Doğrulama: Çapraz doğrulama tekniği, veri kümesini rastgele karıştırarak ve ardından onu k gruba bölerek çalışır. Daha sonra, her grup üzerinde yineleme yapıldığında, diğer tüm gruplar eğitim setinde bir araya getirilirken grubun bir test seti olarak düşünülmesi gerekir. Model test grubu üzerinde test edilir ve işlem k grupları için devam eder. Böylece, sürecin sonunda, k farklı test grubu üzerinde k farklı sonuç elde edilir. En iyi model daha sonra en yüksek puana sahip olanı seçerek kolayca seçilebilir.

Tabakalı K-Katlama (Stratified K-Fold): Tabakalı K-Katlama işlemi, tek bir fark noktasıyla K-Katlama çapraz doğrulama işlemine benzer – k-kat çapraz doğrulamadan farklı olarak, hedef değişkenin değerleri, katmanlı k-katlamada dikkate alınır. Örneğin, hedef değişken 2 sınıflı kategorik bir değişkense, tabakalı k-katlama, eğitim seti ile karşılaştırıldığında her bir test katının iki sınıfın eşit oranını almasını sağlar. Bu, model değerlendirmesini daha doğru ve model eğitimini daha az önyargılı hale getirir.

Önyükleme (Bootstrap): Bootstrap, kararlı bir model elde etmenin en güçlü yollarından biridir. Rastgele örnekleme kavramını takip ettiğinden rastgele bölme tekniğine yakındır.

İlk adım, bir örnek boyutu seçmektir (genellikle orijinal veri kümesinin boyutuna eşittir). Daha sonra, orijinal veri kümesinden rastgele bir örnek veri noktası seçilmeli ve önyükleme örneğine eklenmelidir. Ekleme işleminden sonra numunenin orijinal numuneye geri konması gerekir. Bu işlemin N kez tekrarlanması gerekir, burada N örnek boyutudur.

Bu nedenle, orijinal veri kümesinden değiştirme ile veri noktalarını örnekleyerek önyükleme örneğini oluşturan bir yeniden örnekleme tekniğidir. Bu, önyükleme örneğinin aynı veri noktasının birden çok örneğini içerebileceği anlamına gelir.

Model, önyükleme örneğinde eğitilir ve ardından önyükleme örneğine ulaşmayan tüm veri noktalarında değerlendirilir. Bunlara torba dışı örnekler denir.

Olasılık ölçüleri (Probabilistic measures): Olasılık Ölçütleri sadece model performansını değil, aynı zamanda model karmaşıklığını da hesaba katar. Model karmaşıklığı, modelin verilerdeki varyansı yakalama yeteneğinin ölçüsüdür. Örneğin, doğrusal regresyon algoritması gibi oldukça önyargılı bir model daha az karmaşıktır ve diğer yandan bir sinir ağı karmaşıklığı çok yüksektir. Burada dikkat edilmesi gereken bir diğer önemli nokta, olasılık

ölçütlerinde dikkate alınan model performansının sadece eğitim setinden hesaplanmasıdır. Bir bekletme testi seti genellikle gerekli değildir. Bununla birlikte, biraz dezavantaj, olasılık ölçümlerinin modellerin belirsizliğini dikkate almaması ve karmaşık modeller yerine daha basit modelleri seçme şansına sahip olması gerçeğinde yatmaktadır.

Akaike Bilgi Kriteri (AIC: Akaike Information Criterion): Her modelin tamamen doğru olmadığı yaygın bir bilgidir. Her zaman KL bilgi metriği kullanılarak ölçülebilen bir miktar bilgi kaybı vardır. Kulback-Liebler veya KL sapması, iki değişkenin olasılık dağılımındaki farkın ölçüsüdür.

Bir istatistikçi olan Hirotugu Akaike, KL Bilgisi ile Maksimum Olabilirlik arasındaki ilişkiyi dikkate aldı (maksimum olasılıkta, parametreler ve belirli bir olasılık dağılımı veriliyken, bir X veri noktasını gözlemlemenin koşullu olasılığını maksimize etmek istenir) ve şu kavramı geliştirdi: Bilgi Kriteri (veya IC). Bu nedenle, Akaike'nin IC veya AIC'si bilgi kaybının ölçüsüdür. Bu şekilde iki farklı model arasındaki uyumsuzluk yakalanır ve en az bilgi kaybı olan model tercih edilen model olarak önerilir.

$$AIC = (2K - 2log(L))/N$$

- K = bağımsız değişkenlerin veya tahmin edicilerin sayısı
- L = modelin maksimum olasılığı
- N = eğitim setindeki veri noktalarının sayısı (özellikle küçük veri setleri durumunda faydalıdır)

AIC'nin sınırlaması, daha az eğitim bilgisi kaybeden karmaşık modelleri seçme eğiliminde olduğu için genelleme modelleri konusunda çok iyi olmamasıdır.

Bayes Bilgi Kriteri (BIC: Bayesian Information Criterion**):** BIC, Bayes olasılık kavramından türetilmiştir ve maksimum olabilirlik tahmini altında eğitilmiş modeller için uygundur.

$$BIC = K * log(N) - 2log(L)$$

• K = bağımsız değişken sayısı
• L = maksimum olasılık
• N = Eğitim setindeki örnekleyici/veri noktalarının sayısı

BIC, modeli karmaşıklığından dolayı cezalandırır ve tercihen veri kümesinin boyutu çok küçük olmadığında kullanılır (aksi takdirde çok basit modellere yerleşme eğilimi gösterir).

Minimum Açıklama Uzunluğu (MDL: Minimum Description Length): MDL, bir olayı bir olasılık dağılımından veya rastgele bir değişkenden temsil etmek için gereken ortalama bit sayısını ölçen entropi gibi niceliklerle ilgilenen Bilgi teorisinden türetilmiştir. MDL veya minimum açıklama uzunluğu, modeli temsil etmek için gereken bu tür bitlerin minimum sayısıdır.

$$MDL = L(h) + L(D|h)$$

- d = model
- D = model tarafından yapılan tahminler
- L(h) = modeli temsil etmek için gereken bit sayısı
- L(D | h) = modelden tahminleri temsil etmek için gereken bit sayısı

Yapısal Risk Minimizasyonu (SRM: Structural Risk Minimization)
Makine öğrenimi modelleri, bir dizi sonlu veriden genelleştirilmiş bir teori tanımlamanın kaçınılmaz sorunuyla karşı karşıyadır. Bu, modelin birincil öğrenme kaynağı olan eğitim verilerine önyargılı olduğu aşırı uyum durumlarına yol açar. SRM, modelin karmaşıklığını verilere uymadaki başarısına karşı dengelemeye çalışır.

ML modelleri nasıl değerlendirilir?
Modeller birden fazla metrik kullanılarak değerlendirilebilir. Ancak, bir değerlendirme metriğinin doğru seçimi çok önemlidir ve çoğu zaman çözülmekte olan soruna bağlıdır. Çok çeşitli metriklerin net bir şekilde anlaşılması, değerlendiricinin sorun ifadesi ile metrik arasında uygun bir eşleşme bulmasına yardımcı olabilir.

Sınıflandırma metrikleri:

Her sınıflandırma modeli tahmini için, doğru ve yanlış sınıflandırılan test senaryolarının sayısını gösteren, karışıklık matrisi adı verilen bir matris oluşturulabilir.

Şuna benziyor (1 -Positive ve 0 -Negative, hedef sınıflardır):
gerçek 0
gerçek 1
tahmin edilen 0
Gerçek Negatifler (TN)
Yanlış Negatifler (FN)

Tahmin edilen 1
Yanlış Pozitifler (FP)
Gerçek Pozitifler (TP)

• TN: Doğru sınıflandırılmış negatif vaka sayısı
• TP: Doğru sınıflandırılmış pozitif vaka sayısı
• FN: Yanlış bir şekilde negatif olarak sınıflandırılan pozitif vakaların sayısı
• FP: Doğru olarak pozitif olarak sınıflandırılan negatif vakaların sayısı

Doğruluk (Accuracy): Doğruluk en basit ölçüdür ve doğru sınıflandırılan test senaryolarının toplam test senaryosu sayısına bölünmesiyle tanımlanabilir.

$$Accuracy = (TP+TN)/(TP+TN+FP+FN)$$

Çoğu genel soruna uygulanabilir, ancak dengesiz veri kümeleri söz konusu olduğunda çok kullanışlı değildir.

Örneğin, banka verilerinde dolandırıcılık tespit ediyorsak, dolandırıcılığın dolandırıcılık dışı durumlara oranı 1:99 olabilir. Bu gibi durumlarda doğruluk kullanılırsa, tüm test durumları dolandırıcılık dışı olarak tahmin edilerek modelin %99 doğru olduğu ortaya çıkacaktır. %99 doğru model tamamen işe yaramaz olacaktır.

Bir model, tüm 1000 (örneğin) veri noktasını sahtekarlık dışı olarak tahmin edecek şekilde kötü eğitilmişse, 10 sahtekarlık veri noktasında eksik olacaktır. Doğruluk ölçülürse, o modelin 990 veri noktasını doğru tahmin ettiğini gösterecek ve böylece (990/1000)*100 = %99 doğruluk oranına sahip olacaktır!

Bu nedenle doğruluk, modelin sağlığının yanlış bir göstergesidir.
Bu nedenle, böyle bir durum için, model tarafından tamamen gözden kaçırılan on dolandırıcılık veri noktasına odaklanabilen bir metrik gereklidir.

Kesinlik (Precision): Kesinlik, sınıflandırmanın doğruluğunu belirlemek için kullanılan ölçüdür.

$$Precision = TP/(TP + FP)$$

Sezgisel olarak, bu denklem, doğru pozitif sınıflandırmaların, tahmin edilen pozitif sınıflandırmaların toplam sayısına oranıdır. Kesir ne kadar büyükse, hassasiyet de o kadar yüksek olur, bu da modelin pozitif sınıfı doğru bir şekilde sınıflandırma yeteneğinin daha iyi olduğu anlamına gelir.

Öngörücü bakım probleminde (bir makinenin ne zaman onarılması gerektiğini önceden tahmin etmek gerektiği yerde), hassasiyet devreye girer. Bakım maliyeti genellikle yüksektir ve bu nedenle yanlış tahminler şirket için kayıplara neden olabilir. Bu gibi durumlarda,

modelin pozitif sınıfı doğru bir şekilde sınıflandırma ve yanlış pozitiflerin sayısını azaltma yeteneği çok önemlidir!

Geriçağırma (Recall): Geri çağırma, toplam pozitif vaka sayısından doğru bir şekilde tespit edilen pozitif vakaların sayısını söyler.

$$Recall = TP/(TP + FN)$$

Hile sorununa geri dönersek, geri çağırma değeri hile davalarında çok faydalı olacaktır çünkü yüksek bir geri çekme değeri, toplam hile sayısından çok sayıda hile vakasının tespit edildiğini gösterecektir.

F1 Score: F1 puanı, Geri Çağırma ve Kesinliğin harmonik ortalamasıdır ve bu nedenle her birinin güçlü yönlerini dengeler.
Onarım gerektirebilecek uçak parçalarının tanımlanmasında olduğu gibi, hem hatırlamanın hem de kesinliğin değerli olabileceği durumlarda yararlıdır. Burada, şirketin maliyetinden tasarruf etmek için hassasiyet gerekecektir (çünkü uçak parçaları son derece pahalıdır) ve makinelerin stabil olmasını ve insan yaşamı için bir tehdit oluşturmamasını sağlamak için geri çağırma gerekecektir.

$$F1Score = 2 * ((precision * recall)/(precision + recall))$$

AUC-ROC: ROC eğrisi, yanlış pozitif hıza (TN / (TN+FP) karşı gerçek pozitif oranın (hatırlatma) bir grafiğidir. AUC-ROC, Alıcı Çalışma Karakteristikleri Altında Alan anlamına gelir ve alan ne kadar yüksek olursa, model performansı o kadar iyi olur. Eğri %50 çapraz çizgiye yakınsa, modelin çıktı değişkenini rastgele tahmin ettiğini gösterir.

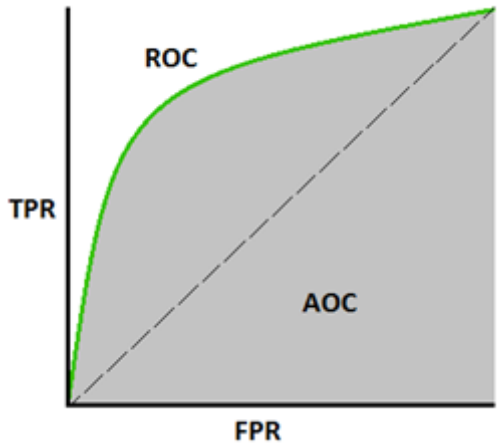

Kayıp listesi **(Log loss)** çok etkili bir sınıflandırma metriğidir ve olabilirlik işlevinin, modelin gözlemlenen sonuç kümesinin ne kadar olası olduğunu düşündüğünü önerdiği -1* log'a (olasılık işlevi) eşdeğerdir.

Olabilirlik işlevi çok küçük değerler sağladığından, bunları yorumlamanın daha iyi bir yolu, değerleri günlüğe dönüştürmek ve daha düşük bir kayıp puanı daha iyi bir model önerecek şekilde ölçümün sırasını tersine çevirmek için negatif eklemektir.

Kazanç ve Artış Grafikleri: Kazanç ve artış çizelgeleri, tıpkı kafa karışıklığı matrisi gibi, ancak ince ancak önemli bir farkla model performansını değerlendiren araçlardır. Karışıklık matrisi, modelin tüm popülasyon veya tüm test seti üzerindeki performansını belirlerken, kazanç ve artış çizelgeleri, modeli tüm popülasyonun bölümleri üzerinde değerlendirir. Bu nedenle, popülasyonun her %'si (x ekseni) için bir puanımız (y ekseni) vardır.

Kaldırma çizelgeleri, bir modelin rastgele tahminlere kıyasla getirdiği gelişmeyi ölçer. İyileştirme, 'kaldırma' olarak adlandırılır.

K-S Grafiği: K-S şeması veya Kolmogorov-Smirnov şeması, iki dağılım arasındaki ayrım derecesini belirler – pozitif sınıf dağılımı ve negatif sınıf dağılımı. Fark ne kadar yüksek olursa, model olumlu ve olumsuz durumları ayırmada o kadar iyidir.

Regresyon metrikleri: Regresyon modelleri, ayrı çıktı değişkenlerine sahip sınıflandırma modellerinin aksine, sürekli bir çıktı değişkeni sağlar. Bu nedenle, regresyon modellerini değerlendirmek için metrikler buna göre tasarlanmıştır.

Ortalama Kare Hat (Mean Squared Error – MSE): MSE, gerçek değer ile tahmin edilen değer (hata) arasındaki farkı hesaplayan, karesini alan ve ardından tüm hataların ortalamasını sağlayan basit bir ölçümdür.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \widetilde{y_i})^2$$

MSE aykırı değerlere karşı çok hassastır ve aksi takdirde iyi donatılmış model tahminlerinde birkaç aykırı değer mevcut olsa bile çok yüksek bir hata değeri gösterecektir.

Kök Ortalama Kare Hatası (Root Mean Squared Error – RMSE): RMSE, MSE'nin köküdür ve hataların ölçeğini gerçek değerlere yaklaştırarak daha yorumlanabilir hale getirmeye yardımcı olduğu için faydalıdır.

Ortalama Mutlak Hata (Mean Absolute Error - MAE): MAE, mutlak hata değerlerinin ortalamasıdır (gerçekler – tahminler)

$$MAE = \frac{1}{n}\sum_{i=1} |x_i - x|$$

Aykırı değerlerin belirli bir dereceye kadar yok sayılması isteniyorsa, kare terimlerin kaldırılmasıyla aykırı değerlerin cezasını önemli ölçüde azalttığı için MAE seçimdir.

Kök Ortalama Kare Kayıtlı Hata Listesi (RMSLE Root Mean Squared Log Error): RMSLE'de, gerçek ve tahmin edilen değerlerle birlikte eklenen bir günlük işlevi dışında RMSE ile aynı denklem izlenir.

$$RMSLE = \sqrt{\frac{1}{n}\Sigma_{i=1}^{n}(log(x_i + 1)) - (log(y_i + 1))^2}$$

x gerçek değerdir ve y tahmin edilen değerdir. Bu, log işleviyle daha yüksek hata oranlarını küçümseyerek aykırı değerlerin etkisini azaltmaya yardımcı olur. Ayrıca, RMSLE, günlükleri kullanarak (tüm hata değerlerini karşılaştırarak) göreli bir hatayı yakalamaya yardımcı olur.

R-Squared: R-Square, bağımsız değişkenler veya tahmin ediciler yardımıyla yakalanabilen hedef değişkenin varyans oranını belirlemeye yardımcı olur.

$$R - Squared = 1 - \frac{Unexplained\ Variation}{Total\ Variation} = 1 - \frac{Variance\ (Model)}{Variance\ (Average)}$$

Ancak R-karenin devasa bir sorunu var. Diyelim ki, atanan ağırlığı w olan bir modele ilgisiz yeni bir özellik eklendi. Model, yeni tahmin edici ile hedef değişken arasında kesinlikle hiçbir korelasyon bulamazsa, w 0'dır. Bununla birlikte, rastgelelik nedeniyle küçük bir pozitif ağırlık (w>0) ekleyen ve yeni bir minimum kayıp elde edilen hemen hemen her zaman küçük bir korelasyon vardır. fazla takılma nedeniyle.

Bu nedenle, herhangi bir yeni özellik eklenmesiyle R-kare artar. Bu nedenle, yeni özellikler eklendiğinde değerinde azalma olmaması, modelin daha az özellikle daha iyi performans gösterip göstermediğini belirleme yeteneğini sınırlar.

Düzeltilmiş R-Kare: Düzeltilmiş R-Kare, eklenen özelliklerle değerin azaltılamaması sorununu ortadan kaldırarak R-Kare sorununu çözer. Daha fazla özellik eklendikçe puanı cezalandırır.

$$adjR_2 = 1 - (1 - R^2)\frac{n-1}{n-m-1}$$

Buradaki payda, öznitelik sayısı arttıkça artan sihirli unsurdur. Bu nedenle, genel değeri artırmak için R2'de önemli bir artış gereklidir.

Kümeleme metrikleri: Kümeleme algoritmaları, veri noktası gruplarını tahmin eder ve bu nedenle mesafeye dayalı metrikler en etkilidir.

Dunn Index: Dunn Index, düşük varyansa sahip (kümedeki tüm üyeler arasında) ve kompakt olan kümeleri belirlemeye odaklanır. Farklı kümelerin ortalama değerlerinin de birbirinden uzak olması gerekir.

• δ(Xi, Yj) kümeler arası mesafedir, yani Xi ve Xj arasındaki mesafe
• Δ(Xk) Xk kümesinin kümeler arası uzaklığıdır, yani Xk kümesi içindeki uzaklık

Ancak Dunn indeksinin dezavantajı, daha fazla sayıda küme ve daha fazla boyut ile hesaplama maliyetinin artmasıdır.

Siluet Katsayısı: Siluet Katsayısı, bir kümedeki her noktanın diğer kümelerdeki her noktaya -1 ile +1 aralığında ne kadar yakın olduğunu izler:

• Daha yüksek Silhouette değerleri (+1'e yakın) iki farklı kümeden alınan örnek noktaların çok uzakta olduğunu gösterir.
• 0, noktaların karar sınırına yakın olduğunu gösterir
• ve -1'e yakın değerler, noktaların kümeye yanlış atandığını gösterir.

Dirsek yöntemi (Elbow method)**:** Dirsek yöntemi, bir veri kümesindeki küme sayısını, x eksenindeki küme sayısını y ekseninde açıklanan varyans yüzdesine karşı çizerek belirlemek için kullanılır. Eğrinin aniden büküldüğü x eksenindeki noktanın (dirsek) optimal küme sayısını önerdiği kabul edilir.

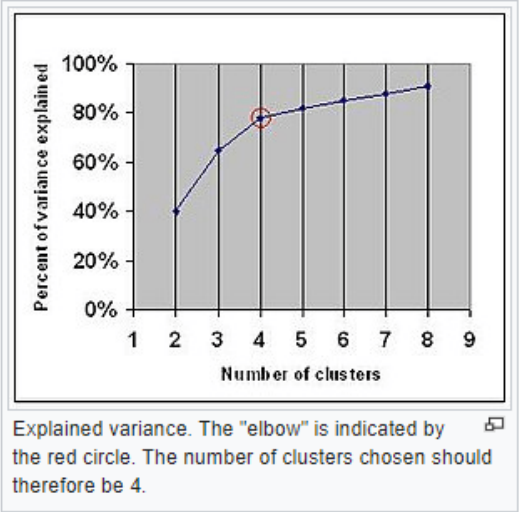

Explained variance. The "elbow" is indicated by the red circle. The number of clusters chosen should therefore be 4.

Takaslar

Önyargıya karşı varyans: Bu makalenin başında, model değerlendirmesi ve seçimi ihtiyacını anlamak için yanlılık ve varyanstan bahsetmek önemliydi. Ancak bunu daha ayrıntılı anlamak, değerlendirme ve seçme kavramlarını iyi kavramak için gereklidir.

Önyargı, bir model kesinlikle varsayımlarla yönetildiğinde ortaya çıkar – doğrusal regresyon modelinin çıktı değişkeninin bağımsız değişkenlerle ilişkisinin düz bir çizgi olduğunu varsayması gibi. Bu, gerçek değerler bağımsız değişkenlerle doğrusal olmayan bir şekilde ilişkili olduğunda eksik uydurmaya yol açar.

Bir model eğitim setine çok fazla odaklandığında ve varyasyonları çok yakından öğrendiğinde ve genellemeden ödün verdiğinde varyans yüksektir. Bu, aşırı uyumaya yol açar.

Optimal bir model, en düşük yanlılığa ve varyansa sahip olandır ve bu iki özellik dolaylı olarak orantılı olduğundan, bunu başarmanın tek yolu ikisi arasında bir ödünleşmedir. Bu nedenle, model seçimi, aşağıdaki resimdeki gibi yanlılık ve varyans kesişecek şekilde olmalıdır.

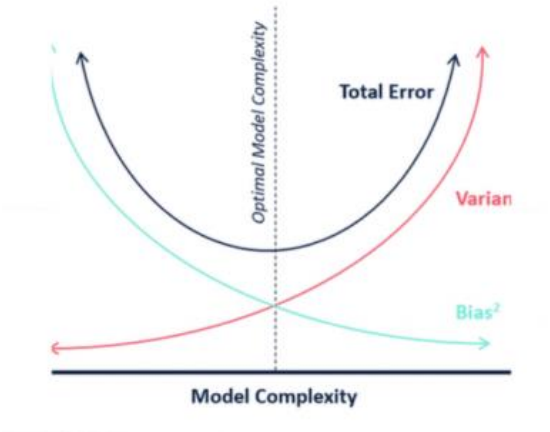

Bu, kullanımdaki modelin hiperparametrelerini yinelemeli olarak ayarlayarak başarılabilir (Hiperparametreler, model işlevlerine beslenen giriş parametreleridir). Her iterasyondan sonra model değerlendirmesi uygun bir metrik kullanılarak yapılmalıdır.
Öğrenme eğrileri

Model eğitiminin veya oluşturmanın ilerlemesini izlemenin en iyi yolu, öğrenme eğrilerini kullanmaktır. Bu eğriler, bir dizi hiperparametre kombinasyonundaki optimal noktaları belirlemeye yardımcı olur ve model seçimi ve model değerlendirme sürecinde büyük ölçüde yardımcı olur.
Tipik olarak, bir öğrenme eğrisi, y ekseninde model performansındaki öğrenmeyi veya gelişmeyi ve x ekseninde zaman veya deneyimi izlemenin bir yoludur.

En popüler iki öğrenme eğrisi şunlardır:
• Eğitim Öğrenme Eğrisi – Bir eğitim süreci sırasında fazla mesai değerlendirme metrik puanını etkin bir şekilde çizer ve böylece eğitim sırasında modelin öğrenimini veya ilerlemesini izlemeye yardımcı olur.
• Doğrulama Öğrenme Eğrisi – Bu eğride, değerlendirme metrik puanı doğrulama setinde zamana karşı çizilir.
•
Bazen, eğitim eğrisinin bir gelişme gösterdiği, ancak doğrulama eğrisinin bodur performans gösterdiği durumlar olabilir.

Bu, modelin fazla uyumlu olduğu ve önceki yinelemelere geri döndürülmesi gerektiği gerçeğinin göstergesidir. Başka bir deyişle, doğrulama öğrenme eğrisi, modelin ne kadar iyi genelleme yaptığını tanımlar.

Bu nedenle, eğitim öğrenme eğrisi ile doğrulama öğrenme eğrisi arasında bir ödünleşim vardır ve model seçim tekniği, hem eğrilerin kesiştiği hem de en düşük olduğu noktaya dayanmalıdır.

Bir makine öğrenimi algoritması değerlendirin ve seçin
Farklı makine öğrenimi algoritmaları, farklı eğilimler ve kalıplar arar. Tek bir algoritma, tüm veri kümeleri veya tüm kullanım durumları için en iyisi değildir. En iyi çözümü bulmak için birçok deney yapmanız, makine öğrenimi algoritmalarını değerlendirmeniz ve hiperparametrelerini ayarlamanız gerekir.

En iyi çözüm nasıl bulunur
İlk olarak, modelinizi değerlendirmek ve bir algoritma seçimini doğrulamak için bir model performans göstergesi seçer, gerekçelendirir ve uygularsınız. Model performans

göstergelerinin örnekleri arasında F1 puanı, gerçek pozitif oran ve küme içi hata karesi toplamı yer alır.

Algoritmanızı en az bir derin öğrenme ve en az bir derin olmayan öğrenme algoritmasında uygulayın. Ardından, model performansını karşılaştırın ve belgeleyin.

En azından özellik oluşturma görevini içeren süreç modelinde en az bir yineleme daha uygulayın. Veri normalleştirme ve temel bileşen analizi (PCA) gibi model performansı üzerindeki etkiyi kaydedin. Algoritma sınıfına ve veri kümesi boyutuna bağlı olarak, sorununuzu çözmek için belirli teknolojileri veya çerçeveleri seçebilirsiniz.

Algoritmaları değerlendirirken ilgili terminolojiyi bilmek faydalıdır:

Term	Tanım
Açıklayıcı analitik	Açıklayıcı analitik, muhtemelen panolar ve raporlar oluşturmak için kullanılan en yaygın analiz türüdür. Daha önce meydana gelen olayları tanımlar ve özetler. Bir örnek, son beş yılda bir bölgedeki tüm mağazalarda her bir ürünün ürünlerinin nasıl satıldığını bilmek isteyen bir bakkal sahibidir.
Tahmine dayalı analitik	Tahmine dayalı analitik, gelecekteki sonuçları tahmin etmek için matematiksel ve istatistiksel yöntemlerin kullanılması anlamına gelir. Bakkal sahibi, stok seviyelerine karar verebilmek için önümüzdeki birkaç ay içinde kaç ürünün satılabileceğini anlamak istiyor.
Kuralcı analitik	Kuralcı analitik, bir dizi kısıtlamaya dayalı senaryoları simüle ederek iş kararlarını optimize etmek için kullanılır. Market sahibi, çalışanlar için bir personel programı oluşturmak istiyor, ancak bunu yapmak için uygunluk, tatil süresi, çalışma saatleri ve olası acil durumlar (kısıtlamalar) gibi faktörleri hesaba katması gerekiyor. Ayrıca herkes için çalışan bir program oluşturmalı ve işinin günlük olarak işlemesini sağlamalıdır.
Denetimli öğrenme	Denetimli öğrenme, etiketlenmiş eğitim verilerinden bir model öğretir ve görünmeyen veya gelecekteki veriler hakkında tahminler yapmanıza yardımcı olur. Eğitim sırasında algoritmaya doğru cevapları içeren bir veri seti verirsiniz (y etiketi). Ardından, doğru cevapları olan bir test veri seti ile model doğruluğunu doğrularsınız. Bir veri seti eğitim ve test setlerine bölünmelidir.
Sınıflandırma	Sınıflandırma ile, az sayıda ayrık değerli çıktıdan birini tahmin etmeye çalışıyorsunuz. Örneğin, etiketinizin ikili (ikili sınıflandırma) veya kategorik (çok sınıflı sınıflandırma) olup olmadığını tahmin etmeye çalışabilirsiniz.

regresyon	Regresyonda, öğrenme probleminin amacı sürekli değer çıktısını tahmin etmektir.

Algoritmaları eğitin, doğrulayın ve test edin

Makine öğrenimi algoritmaları örneklerden öğrenir. İyi verileriniz varsa, ne kadar çok örnek verirseniz, model verilerdeki kalıpları bulmada o kadar iyi olur. Ancak, aşırı takma konusunda dikkatli olun. İlk tabloda açıklandığı gibi, fazla uydurma, bir modelin eğitildiği veriler için doğru tahminlerde bulunabildiği ancak diğer verilere genelleyemediği yerdir.

Fazla uydurma, verilerinizi eğitim verileri, doğrulama verileri ve test verileri olarak ayırmanızın nedenidir. Doğrulama verileri ve test verileri genellikle birbirinin yerine kullanılır, ancak farklı amaçları vardır.

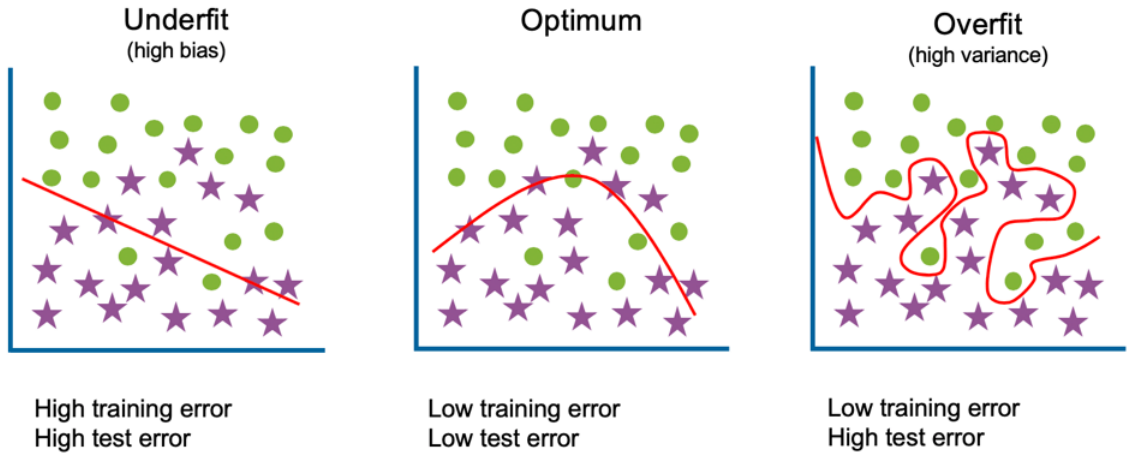

Verilerin eğitimi, test edilmesi ve doğrulanmasıyla ilgili terminolojiye aşina olun:

Terim	Tanım
Eğitim verileri	Bu veriler, modeli eğitmek ve model parametrelerine uydurmak için kullanılır. Modelin mümkün olduğunca çok örnek görmesini istediğiniz için en büyük veri oranını oluşturur.
Doğrulama	Bu veriler, hiperparametreleri sığdırmak ve özellik seçimi için kullanılır. Model,

verileri	eğitim sırasında bu verileri hiçbir zaman görmese de, bu verilere dayalı belirli özellikleri veya hiperparametreleri seçerek, sapma ve aşırı uyum riskini ortaya çıkarırsınız.
Test verisi	Bu veriler, ayarlanmış modellerinizi değerlendirmek ve karşılaştırmak için kullanılır. Bu veriler eğitim veya ayarlama sırasında görülmediğinden, modellerinizin görünmeyen verilere iyi genellenip genellenmediği konusunda fikir verebilir.
Çapraz doğrulama	Çapraz doğrulamanın amacı, belirli bir algoritmanın verileriniz ve kullanım durumunuz için uygun olup olmadığını değerlendirmektir. Çapraz doğrulama, hiperparametre ayarlama ve özellik seçimi için de kullanılır. Veriler, tren ve doğrulama kümelerine bölünür, ancak test verilerinin de bir tarafa yerleştirilmesi gerekir. Veri dilimlerinin her biri ile bir model oluşturursunuz. Algoritmanın son değerlendirmesi, modellerin her birinin ortalama performansıdır.
Bekletme yöntemi	Çapraz doğrulamanın en basit versiyonu, verilerinizi rastgele iki kümeye böldüğünüz hold-out yöntemidir: bir eğitim seti ve bir doğrulama seti. Bu yöntem en hızlıdır çünkü bir modelin yalnızca bir kez oluşturulmasını gerektirir. Ancak, yalnızca bir doğrulama veri seti ile, tahmin edilmesi kolay veya zor gözlemler içerme riskini taşırsınız. Bu nedenle, bu doğrulama verilerine gereğinden fazla uyduğunuzu ve test setinde kötü performans gösterdiğini fark edebilirsiniz.
K-kat çapraz doğrulama	Bu yöntem, verileri k-alt kümelere bölmeyi içerir. Daha sonra, doğrulama verileri olarak k-alt kümelerden birini kullanarak her seferinde bir modeli k kez eğitirsiniz. Eğitim verileri, doğrulama kümesinde olmayan diğer tüm gözlemlerdir. Son değerlendirmeniz, tüm k kıvrımların ortalamasıdır.
Birini dışarıda bırak çapraz doğrulama	Bu yöntem, k-kat çapraz doğrulamanın en uç versiyonudur. İçinde, k'niz N'dir (veri kümenizdeki gözlem sayısı). Bir gözlem dışında tüm verileri kullanarak bir modeli N ayrı zamanlarda eğitirsiniz ve ardından bu gözlem için tahmini ile doğruluğunu doğrularsınız. Bu algoritmanın veri kümenizle ne kadar iyi çalıştığını kapsamlı bir şekilde değerlendiriyor olsanız da, bu yöntem pahalıdır çünkü N model oluşturmanızı gerektirir.
Stratified cross-validation	Bu yöntem, k-katlı kümelerin, kategorik özelliklerde veya etikette her sınıf için benzer gözlem oranlarına sahip olmasını zorlar.

Algoritma keşfi

Keşfettiğiniz algoritmalar ile önce neyi başarmaya çalıştığınızı belirleyerek, çözüm arama kapsamını daraltabilirsiniz. Olası yöntemler arasında regresyon, sınıflandırma, kümeleme, öneriler ve anormallik tespiti için algoritmalar bulunur ancak bunlarla sınırlı değildir. Algoritma seçimini yönlendirmek için Algoritma Gezgini'ni de kullanabilirsiniz.

Regresyon: Regresyon algoritmaları, sürekli sayısal değerleri tahmin etmeye yönelik makine öğrenme teknikleridir. Denetimli öğrenme görevleridir, bu nedenle etiketli eğitim örnekleri gerektirirler.

Sınıflandırma: Sınıflandırma algoritmaları, girdi verilerinin hangi kategoriye ait olduğunu tahmin etmeye yönelik makine öğrenme teknikleridir. Denetimli öğrenme görevleridir, bu nedenle etiketli eğitim örnekleri gerektirirler.

Kümeleme: Kümeleme algoritmaları, verileri gruplardaki noktaların benzer özelliklere sahip olduğu birkaç gruba bölmek için makine öğrenimi teknikleridir. Denetimsiz öğrenme görevleridir ve etiketli eğitim örnekleri gerektirmezler.

Öneri motorları: Öneri motorları, kullanıcının bir öğeye veya ürüne olan ilgisini gösteren bir tercihi veya derecelendirmeyi tahmin etmek için oluşturulur. Bu sistemi oluşturmak için kullanılan algoritmalar, kullanıcılar, öğeler veya her ikisi arasında benzerlikler bulur.

Anomali tespiti: Anormallik tespiti, beklenen davranışa uymayan olağandışı olayları veya kalıpları belirlemek için kullanılan bir tekniktir. Tanımlanan öğelere genellikle anormallikler veya aykırı değerler denir.

Hiperparametre optimizasyonu: Parametreler ve hiperparametreler bazen birbirinin yerine kullanılsa da, aralarında ayrımlar vardır. Parametreler, algoritmanın eğitim sırasında öğrendiği özelliklerdir. Doğrusal regresyon için bu parametreler ağırlıklar ve önyargılardır. Rastgele ormanlar için, her düğümdeki değişkenler ve eşiklerdir.
Hiperparametreler, eğitimden önce ayarlanması gereken özelliklerdir. k-ortalama kümeleme için, k değerini tanımlamanız gerekir. Sinir ağları için bir örnek, öğrenme oranıdır. Hiperparametre optimizasyonu, en yüksek doğruluk ve en düşük RMSE (kök-ortalama-kare hatası) gibi performans ölçütünüzü optimize etmek için hiperparametreler için mümkün olan en iyi değerleri bulma sürecidir. Farklı değer kombinasyonları için bir model eğitirsiniz ve hangi modellerin en iyi çözümü bulduğunu değerlendirirsiniz. En iyi kombinasyonları arama yöntemleri arasında grid araması, rastgele arama, kaba-ince ve bayes optimizasyonu yer alır.

Grid arama: Grid aramasında, her bir hiperparametre için değerler belirtirsiniz ve bu değerlerin tüm kombinasyonları değerlendirilir. Örneğin, rastgele orman için hiperparametreleri değerlendirmek için, ağaç hiperparametresi sayısı için üç seçenek sağlayabilirsiniz: 10, 20 ve 50. Her ağacın maksimum derinliği için ayrıca üç seçenek sağlarsınız: limit yok, 10 ve 20. Bu seçim sonuçları, dokuz olası kombinasyonun her biri için rastgele bir orman modelinin oluşturulmasıyla sonuçlanır: (10, limitsiz), (10, 10), (10, 20), (20, limitsiz), (20, 10), (20, 20), (50, limitsiz), (50, 10) ve (50, 20).

En iyi performansı sağlayan kombinasyon, son modeliniz için kullandığınız kombinasyondur. Bu yöntemin kullanımı basittir. Sağladığınız değerlerin en iyi kombinasyonunu bulabilir ve deneylerin her birini paralel olarak çalıştırabilirsiniz. Bununla birlikte, pek çok model üretildiği için hesaplama açısından da pahalıdır. Bir hiper parametre önemli değilse, gereksiz yere farklı olasılıkları keşfedebilirsiniz.

Rastgele arama: Rastgele aramada, her bir hiperparametre için aralıklar veya seçenekler belirlersiniz ve her birinin rastgele değerleri seçilir. Rastgele orman örneğinden devam ederek, ağaç sayısının 10 - 50 ve maksimum_derinlik için limitsiz, 10 veya 20 olmasını sağlayabilirsiniz. Bu sefer tüm permütasyonları hesaplamak yerine, sayıyı belirtebilirsiniz. çalıştırmak istediğiniz yinelemelerin sayısı. Sadece beş tane istiyorsun. (19, 20), (32 limitsiz), (40, limitsiz), (10, 20), (27, 10) gibi bir şeyi test edebilirsiniz.

Bu yöntemin kullanımı kolaydır, verimlidir ve genel performansı yalnızca birkaç hiperparametre etkilediğinde grid aramasından daha iyi performans gösterebilir. Deneylerin her birini paralel olarak çalıştırabilirsiniz. Ancak, rastgele örnekleme içerir, bu nedenle yalnızca o alanı ararsa en iyi kombinasyonu bulur.

Kaba-ince (Coarse-to-fine): Hem grid araması hem de rastgele arama için kaba-ince tekniğini de kullanabilirsiniz. Bu teknik, geniş aralıklarla veya tüm olası seçeneklerle daha geniş bir değişken yelpazesini keşfetmeyi içerir. İlk aramanızdan elde ettiğiniz sonuçları aldıktan sonra, umut verici görünen kalıpları veya bölgeleri bulmak için sonuçları keşfedersiniz. Eğer öyleyse, işlemi tekrarlayabilir, ancak aramanızı daraltabilirsiniz.

Rastgele orman örneği için, maksimum derinlik sınırı olmadığında ve ağaç hiperparametresi sayısı 10 veya 20 olduğunda sonuçların umut verici olduğunu fark edebilirsiniz. Arama işlemi tekrarlanır ancak maksimum derinlik hiperparametresini sabit tutar ve ayrıntı düzeyini artırır. ağaç seçeneklerinin sayısı, test değerleri 12, 14, 16, 18, daha iyi bir sonuç bulup bulamayacağınızı görmek için.

Bu yöntem, performans metriğini geliştirerek daha fazla optimize edilmiş hiperparametreler bulabilir. Ancak, keşfedilecek en iyi bölgeleri bulmak için sonuçların değerlendirilmesi zahmetli olabilir.

Bayes optimizasyonu: Bayes optimizasyonu, bir sonraki en iyiyi seçmek için hiperparametre kombinasyonları ile önceden elde edilen başarı bilgisini kullanır. Bu teknik, hiperparametrelerin özellikler ve performansın hedef değişken olduğu bir model oluşturarak bir makine öğrenimi yaklaşımı kullanır. Her deneyden sonra yeni bir veri noktası eklenir ve yeni bir model oluşturulur. Benzer kombinasyonların benzer sonuçlara sahip olduğunu varsayar ve umut verici sonuçların bulunduğu bölgeleri keşfetmeye öncelik verir.

Bununla birlikte, belirsizliği büyük kazanç olasılığı olarak da dikkate alır. Büyük keşfedilmemiş alanlar varsa, o alanlara da öncelik verir. Yalnızca bir hiper parametreyi, yani ağaç sayısını alarak, algoritma önce 10'u deneyebilir ve iyi bir performans elde edebilir. Daha sonra 32'yi dener ve performans önemli ölçüde daha iyidir.

Bayes optimizasyonu, performansı tahmin etmek için ilk iki veri noktasına dayalı bir model oluşturur. Modelin yalnızca iki veri noktasıyla doğrusal olması muhtemeldir, bu nedenle seçtiği bir sonraki değer, ağaç sayısı arttıkça performansın artması beklentisiyle 40'tır. Öyle değil.

Şimdiye kadar en iyi sonucu gördüğü yerde 32 civarında bir gelişme olabileceğini öne süren başka bir model oluşturuyor. Bununla birlikte, 10 ile 32 arasında hala keşfedilmemiş büyük bir boşluk vardır ve büyük belirsizlik nedeniyle 21'i seçer. Yine, model bu yeni verilerle ince ayar yapılır ve başka bir değer seçilir.

Bu yöntem, performans metriğini geliştirerek daha fazla optimize edilmiş hiperparametreler bulabilir. Parametre sayısı yüksek olduğunda ve her deney hesaplama açısından pahalı olduğunda, optimum çözümü aramak için harcanan zamanı azaltabilir. Ancak, sonraki hiperparametre değerleri kombinasyonu önceki çalıştırmalar tarafından belirlendiği için her denemeyi paralel olarak çalıştıramazsınız. Ayrıca ayarlama gerektirir: her bir hiperparametre ve uygun bir çekirdek için bir ölçek seçme.

Toplu öğrenme (Ensemble learning): Topluluklar, daha doğru bir çözüm sağlamak için her biri veriler içinde farklı modeller bulan çeşitli makine öğrenimi modellerini birleştirir. Bu teknikler, daha fazla trend yakaladıkları için performansı artırabilir. Nihai tahmin birçok modelden bir fikir birliği olduğu için fazla takmayı da azaltabilirler.

Torbalama (Bagging): Torbalama veya önyükleme toplamaları, modelleri paralel olarak oluşturma ve son tahmin olarak tahminlerinin ortalamasını alma yöntemidir. Bu modeller aynı algoritma ile oluşturulabilir. Örneğin, rastgele orman algoritması birçok karar ağacı oluşturur. Doğrusal regresyon modeli ve destek vektör makinesi (SVM) modeli gibi farklı türde modeller de oluşturabilirsiniz.

Artırma (Boosting): Boosting, önceki modellerin başarısını değerlendirerek modelleri sırayla oluşturur. Sonraki model, mevcut modellerin kötü performans gösterdiği örnekleri tahmin etmek için öğrenme eğilimlerine öncelik verir. Üç yaygın teknik; AdaBoost, Gradient Boosting ve XGBoosted'dir.

İstifleme (Stacking): İstifleme, modeller oluşturmayı ve çıktılarını özellikler olarak nihai bir modelde kullanmayı içerir. Örneğin, amacınız bir sınıflandırıcı oluşturmak ve bir KNN modeli ve bir Naïve Bayes modeli oluşturuyorsunuz. İkisi arasında seçim yapmak yerine, iki tahminini nihai bir lojistik regresyon modeline aktarabilirsiniz. Bu son model, iki ara modelden daha iyi sonuçlar verebilir.

4.2. Grid Arama

Makine öğrenimi modellerinin çoğu, modelin öğrenme şeklini değiştirecek şekilde ayarlanabilen parametreler içerir. Örneğin, sklearn'den gelen lojistik regresyon modeli, modelin karmaşıklığını etkileyen düzenlileştirmeyi kontrol eden bir C parametresine sahiptir. C için en iyi değeri nasıl seçeriz? En iyi değer, modeli eğitmek için kullanılan verilere bağlıdır.

Bir yöntem, farklı değerleri denemek ve ardından en iyi puanı veren değeri seçmektir. Bu teknik grid araması olarak bilinir. İki veya daha fazla parametre için değer seçmemiz gerekseydi, değer kümelerin tüm kombinasyonları değerlendirilir, böylece bir değerler gridsı oluşturulur.

Örneğe girmeden önce değiştirdiğimiz parametrenin ne işe yaradığını bilmekte fayda var. Daha yüksek C değerleri modele, eğitim verilerinin gerçek dünya bilgisine benzediğini ve eğitim verilerine daha fazla ağırlık verdiği söylenir. C'nin daha düşük değerleri ise tam tersini yapar.

Varsayılan Parametreleri Kullanma:
Önce sadece temel parametreleri kullanarak grid araması yapmadan ne tür sonuçlar üretebileceğimize bir bakalım. Başlamak için önce birlikte çalışacağımız veri setini yüklemeliyiz.

```
from sklearn import datasets
iris = datasets.load_iris()
```

Modeli oluşturmak için bir dizi bağımsız değişken X ve bir bağımlı değişken y olmalıdır.

```
X = iris['data']
y = iris['target']
```

Şimdi iris çiçeklerini sınıflandırmak için lojistik modeli yükleyeceğiz.

```
from sklearn.linear_model import LogisticRegression
```

Modelin oluşturulması, modelin bir sonuç bulmasını sağlamak için max_iter değerini daha yüksek bir değere ayarlamak gerekir. Lojistik regresyon modelinde C için varsayılan değerin 1 olduğunu unutmayın, bunu daha sonra karşılaştıracağız. Aşağıdaki örnekte, iris veri setine bakılır ve lojistik regresyonda C için değişen değerlere sahip bir model eğitmeye çalışılır.

```
logit = LogisticRegression(max_iter = 10000)
```

Modeli oluşturduktan sonra model verilere uydurulur.

```
print(logit.fit(X,y))
```

Modeli değerlendirmek için skor yöntemini çalıştırıyoruz.
print(logit.score(X,y))

Python kod örneği:
```
from sklearn import datasets
from sklearn.linear_model import LogisticRegression
iris = datasets.load_iris()
X = iris['data']
y = iris['target']
logit = LogisticRegression(max_iter = 10000)
print(logit.fit(X,y))
print(logit.score(X,y))
```

Varsayılan ayar olan C = 1 ile 0,973 puan elde ettik. Farklı 0,973 değerlerine sahip bir grid araması uygulayarak daha iyisini yapıp yapamayacağımızı görelim.

Grid Arama Uygulaması:
Daha önceki adımların aynısını izlenir, ancak bu sefer C için bir değer aralığı belirlenir. Aranan parametreler için hangi değerlerin ayarlanacağını bilmek, alan bilgisi ve pratiğin bir kombinasyonunu alacaktır.

C için varsayılan değer 1 olduğundan, onu çevreleyen bir dizi değer ayarlanacaktır.
C = [0.25, 0.5, 0.75, 1, 1.25, 1.5, 1.75, 2]

Daha sonra C'nin değerlerini değiştirmek için bir for döngüsü oluşturulur ve her değişiklikte model değerlendirilir.

İlk önce skoru içinde saklamak için boş bir liste oluşturacağız.
```
scores = []
```

C'nin değerlerini değiştirmek için, değerler aralığında döngüye girmeli ve her seferinde parametre güncellenmelidir.

```
for choice in C:
  logit.set_params(C=choice)
  logit.fit(X, y)
  scores.append(logit.score(X, y))
```

Bir listede saklanan puanlarla, en iyi C seçiminin ne olduğunu değerlendirilebilir.
print(scores)

Python kod örneği:

```
from sklearn import datasets
from sklearn.linear_model import LogisticRegression
iris = datasets.load_iris()
X = iris['data']
y = iris['target']
logit = LogisticRegression(max_iter = 10000)
C = [0.25, 0.5, 0.75, 1, 1.25, 1.5, 1.75, 2]
scores = []
for choice in C:
  logit.set_params(C=choice)
  logit.fit(X, y)
  scores.append(logit.score(X, y))
print(scores)
```

Sonuçların açıklanması:
C'nin düşük değerlerinin temel parametre 1'den daha kötü performans gösterdiğini görebiliriz. Ancak, C değerini 1,75'e yükselttikçe modelin doğruluğu arttı. C'yi bu miktarın üzerine çıkarmanın model doğruluğunu artırmaya yardımcı olmadığı görülüyor.

Denetimli öğrenmenin amacı, yeni veriler üzerinde iyi performans gösteren bir model oluşturmaktır. Yeni verileriniz varsa, modelinizin bu veriler üzerinde nasıl performans gösterdiğini görmek iyi bir fikirdir. Sorun şu ki, yeni verileriniz olmayabilir, ancak bu deneyimi veri kümesinde eğitim ve test bölme gibi bir prosedürle simüle edebilirsiniz.

En İyi Uygulamalar Üzerine Not:
Lojistik regresyon modelimizi, onu eğitmek için kullanılan aynı verileri kullanarak puanladık. Model bu verilere çok yakınsa, görünmeyen verileri tahmin etmede iyi olmayabilir. Bu istatistiksel hata, aşırı uydurma olarak bilinir.

Eğitim verilerinin puanları tarafından yanıltılmamak için, verilerimizin bir kısmını bir kenara ayırabilir ve özellikle modeli test etmek amacıyla kullanabiliriz. Yanlış yönlendirilmeyi ve fazla uydurmayı önlemek için eğitim/test ayırma işlevinin iyi bilinmesi gerekmektedir.

4.3. AUC - ROC Curve

Sınıflandırmada birçok farklı değerlendirme ölçütü vardır. En popüler olanı, modelin ne sıklıkla doğru olduğunu ölçen doğruluktur. Bu harika bir ölçümdür çünkü anlaşılması kolaydır ve en doğru tahminleri almak genellikle istenir. Başka bir değerlendirme metriği kullanmayı düşünebileceğiniz bazı durumlar vardır.

Diğer bir yaygın metrik, alıcı çalışma karakteristiği (ROC: receiver operating characteristic) eğrisinin altındaki alan olan AUC'dir. Alıcı işletim karakteristik eğrisi, farklı sınıflandırma eşiklerinde yanlış pozitif (FP: false positive) oranına karşı gerçek pozitif (TP: true positive) oranı gösterir. Eşikler, ikili sınıflandırmada iki sınıfı ayıran farklı olasılık kesimleridir. Bir modelin sınıfları ne kadar iyi ayırdığını bize söylemek için olasılığı kullanır.

Imbalanced Data

Verilerimizin çoğunun tek bir değerde olduğu dengesiz bir veri setimiz olduğunu varsayalım. Çoğunluk sınıfını tahmin ederek model için yüksek doğruluk elde edebiliriz.

Kod örneği:

```
import numpy as np
from sklearn.metrics import accuracy_score, confusion_matrix, roc_auc_score, roc_curve

n = 10000
ratio = .95
n_0 = int((1-ratio) * n)
n_1 = int(ratio * n)

y = np.array([0] * n_0 + [1] * n_1)
# below are the probabilities obtained from a hypothetical model that always predicts the majority class
# probability of predicting class 1 is going to be 100%
y_proba = np.array([1]*n)
y_pred = y_proba > .5

print(f'accuracy score: {accuracy_score(y, y_pred)}')
cf_mat = confusion_matrix(y, y_pred)
print('Confusion matrix')
print(cf_mat)
print(f'class 0 accuracy: {cf_mat[0][0]/n_0}')
print(f'class 1 accuracy: {cf_mat[1][1]/n_1}')
```

Çok yüksek bir doğruluk elde etmemize rağmen, model veriler hakkında hiçbir bilgi sağlamadı, bu yüzden kullanışlı değil. Sınıf 1'i zamanın %100'ünde doğru bir şekilde tahmin ederken, sınıf 0'ı zamanın %0'ında yanlış tahmin ederiz. Doğruluk pahasına, iki sınıfı bir şekilde ayırabilen bir modele sahip olmak daha iyi olabilir.

Kod örneği:

```
# below are the probabilities obtained from a hypothetical model that doesn't always predict the mode
y_proba_2 = np.array(
   np.random.uniform(0, .7, n_0).tolist() +
   np.random.uniform(.3, 1, n_1).tolist()
)
y_pred_2 = y_proba_2 > .5

print(f'accuracy score: {accuracy_score(y, y_pred_2)}')
cf_mat = confusion_matrix(y, y_pred_2)
print('Confusion matrix')
print(cf_mat)
print(f'class 0 accuracy: {cf_mat[0][0]/n_0}')
print(f'class 1 accuracy: {cf_mat[1][1]/n_1}')
```

İkinci tahmin seti için birincisi kadar yüksek bir doğruluk puanımız yok ama her sınıf için doğruluk daha dengeli. Doğruluğu bir değerlendirme metriği olarak kullanarak, bize veriler hakkında hiçbir şey söylemese de ilk modeli ikinciden daha yüksek değerlendiririz.

Bu gibi durumlarda, AUC gibi başka bir değerlendirme metriğinin kullanılması tercih edilir.

```
import matplotlib.pyplot as plt

def plot_roc_curve(true_y, y_prob):
   """
   plots the roc curve based of the probabilities
   """

   fpr, tpr, thresholds = roc_curve(true_y, y_prob)
   plt.plot(fpr, tpr)
   plt.xlabel('False Positive Rate')
   plt.ylabel('True Positive Rate')
```

Example: Model 1

plot_roc_curve(y, y_proba)

print(f'model 1 AUC score: {roc_auc_score(y, y_proba)}')

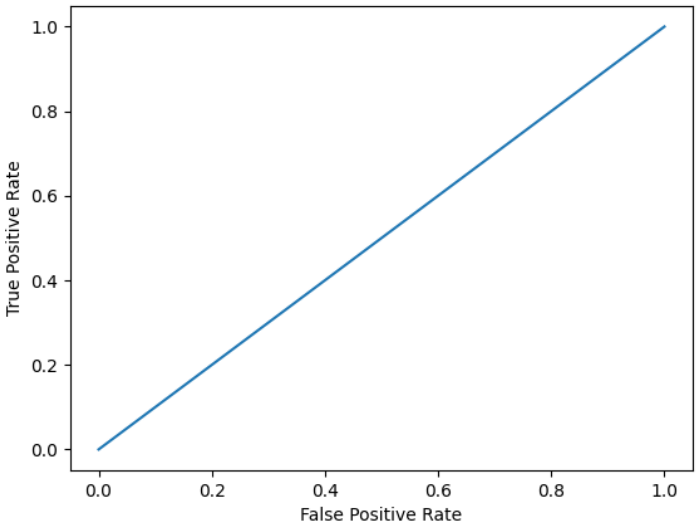

model 1 AUC score: 0.5

Example: Model 2

plot_roc_curve(y, y_proba_2)

print(f'model 2 AUC score: {roc_auc_score(y, y_proba_2)}')

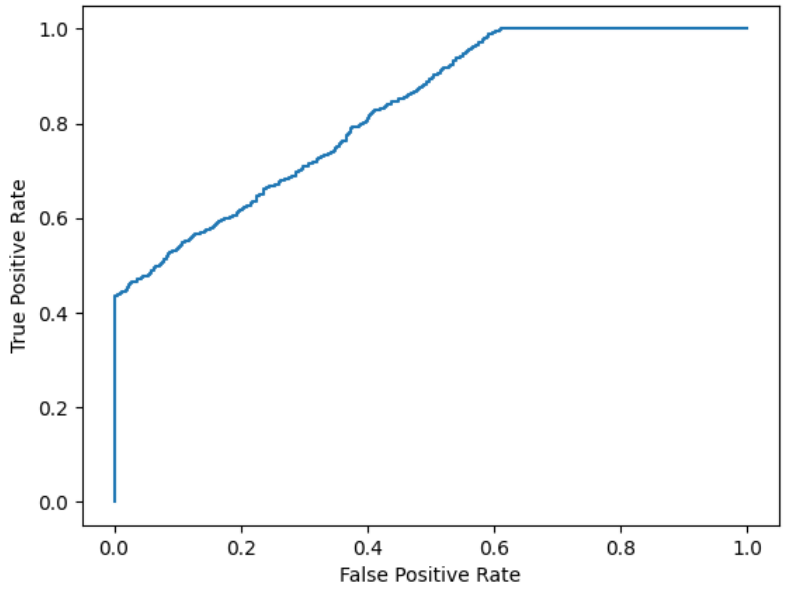

model 2 AUC score: 0.8270551578947367

Yaklaşık 0,5'lik bir AUC puanı, modelin iki sınıf arasında bir ayrım yapamadığı ve eğrinin 1 eğimli bir çizgi gibi görüneceği anlamına gelir. 1'e yakın bir AUC puanı, modelin, iki sınıfı ayırın ve eğri grafiğin sol üst köşesine yaklaşacaktır.

Olasılıklar

AUC, sınıf tahminlerinin olasılıklarını kullanan bir metrik olduğundan, benzer doğruluklara sahip olsalar bile, daha yüksek AUC puanına sahip bir modelde, daha düşük puana sahip bir modelden daha emin olabiliriz. Aşağıdaki verilerde, varsayımsal modellerden iki olasılık grubumuz var. Birincisi, iki sınıfı tahmin ederken "güvenli" olmayan olasılıklara sahiptir (olasılıklar .5'e yakındır). İkincisi, iki sınıfı tahmin ederken daha "güvenli" olan olasılıklara sahiptir (olasılıklar 0 veya 1'in uç noktalarına yakındır).

Kod örneği:

```
import numpy as np

n = 10000
y = np.array([0] * n + [1] * n)
#
y_prob_1 = np.array(
   np.random.uniform(.25, .5, n//2).tolist() +
   np.random.uniform(.3, .7, n).tolist() +
   np.random.uniform(.5, .75, n//2).tolist()
)
y_prob_2 = np.array(
   np.random.uniform(0, .4, n//2).tolist() +
   np.random.uniform(.3, .7, n).tolist() +
   np.random.uniform(.6, 1, n//2).tolist()
)

print(f'model 1 accuracy score: {accuracy_score(y, y_prob_1>.5)}')
print(f'model 2 accuracy score: {accuracy_score(y, y_prob_2>.5)}')

print(f'model 1 AUC score: {roc_auc_score(y, y_prob_1)}')
print(f'model 2 AUC score: {roc_auc_score(y, y_prob_2)}')
```

Kod örneği: Plot model 1

```
plot_roc_curve(y, y_prob_1)
```

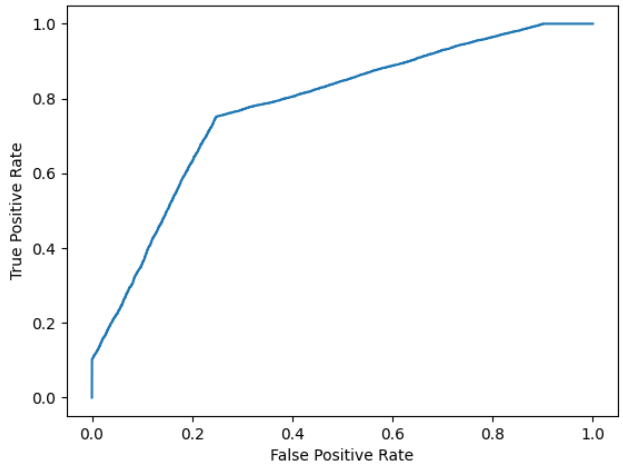

Kod örneği: Plot model 2

fpr, tpr, thresholds = roc_curve(y, y_prob_2)

plt.plot(fpr, tpr)

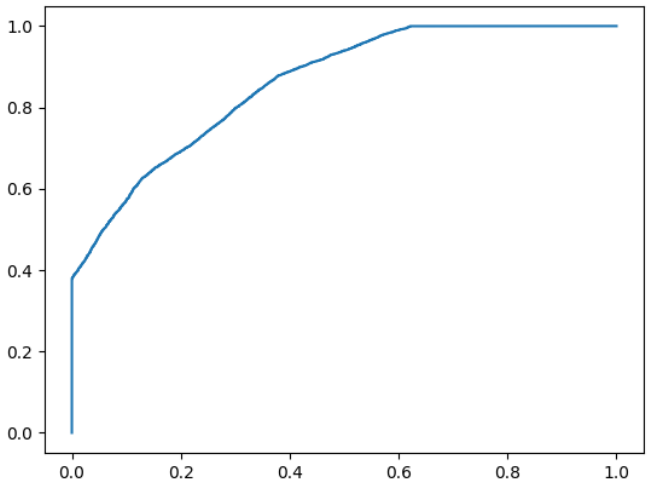

İki modelin doğrulukları benzer olsa da, AUC puanı daha yüksek olan model, tahmin edilen olasılığı hesaba kattığı için daha güvenilir olacaktır. Gelecekteki verileri tahmin ederken size daha yüksek doğruluk vermesi daha olasıdır.

4.4. Karışıklık matrisi

Karışıklık matrisi, diğer sınıflandırma ölçütleri için temel oluşturur. Modelin performansını tam olarak tanımlayan bir matristir. Bir karışıklık matrisi, her sınıfın doğru ve yanlış sınıflandırmalarının derinlemesine bir dökümünü verir.

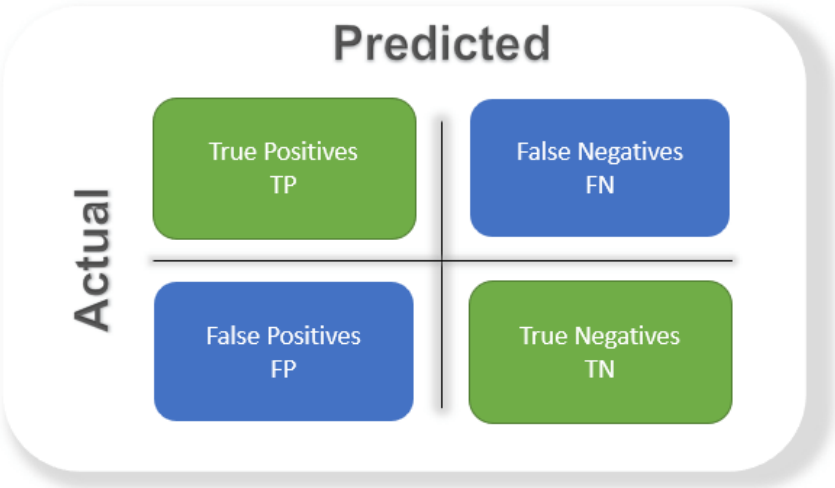

Gerçek pozitifler – pozitif tahminlerin aslında pozitif olduğu bir senaryo.
Gerçek olumsuzlar – olumsuz tahminler aslında olumsuzdur.
Yanlış pozitifler – pozitif tahminler aslında negatiftir.
Yanlış negatifler – negatif tahminlerin aslında pozitif olduğu bir senaryo.

Yukarıdaki dört terimin tanımından çıkarılacak sonuç, gerçek pozitifleri ve gerçek negatifleri çoğaltmanın önemli olduğudur. Yanlış pozitifler ve yanlış negatifler, gerçek dünya uygulamalarında maliyetli olabilecek yanlış sınıflandırmayı temsil eder. Bir modelin tıbbi dağıtımında yanlış teşhis örneklerini düşünün.

Bir model, sağlıklı bir kişinin kanser olduğunu yanlış tahmin edebilir. Ayrıca, aslında kanserli birini kansersiz olarak sınıflandırabilir. Her iki sonuç da hastaların teşhis konulduktan (veya yanlış teşhis konulduktan sonra) sağlıkları, tedavi planları ve masraflar açısından hoş olmayan sonuçlar doğuracaktır. Bu nedenle, yanlış negatifleri ve yanlış pozitifleri en aza indirmek önemlidir.

Görüntüdeki yeşil şekiller, modelin doğru tahmini yaptığı zamanı temsil eder. Mavi olanlar, modelin yanlış tahminlerde bulunduğu senaryoları temsil ediyor. Matrisin satırları gerçek sınıfları, sütunlar ise tahmin edilen sınıfları temsil eder.

Doğruluğu karışıklık matrisinden hesaplayabiliriz. Doğruluk, "doğru" diyagonaldeki değerlerin ortalaması alınarak verilir.

Doğruluk = (Gerçek Pozitif + Gerçek Negatif) / Toplam Örnek
Bu şu anlama gelir: Doğruluk = Toplam Doğru Tahmin Sayısı / Toplam Sayı

Gözlemler
Karışıklık matrisi, yukarıda bahsedilen sınıflandırmanın dört olası sonucunu görselleştirdiği için, doğruluğun yanı sıra, kesinlik, hatırlama (Geri Çağırma) ve nihayetinde F-skoru hakkında fikir sahibiyiz. Matristen kolayca hesaplanabilirler. Kesinlik, geri çağırma ve F-skoru aşağıdaki bölümde tanımlanmıştır.

F-puanı
F puanı, puanı belirlemek için bir testin hem kesinliğini hem de geri çağrılmasını içeren bir ölçümdür. Bu gönderi, onu hatırlama ve kesinliğin harmonik ortalaması olarak tanımlar.

F-skoru, F-ölçü veya F1 skoru olarak da bilinir.

Kesinlik, bir sınıflandırıcı tarafından tahmin edilen toplam pozitif sonuçlara bölünen gerçek pozitiflerin sayısını ifade eder. Basitçe söylemek gerekirse, kesinlik, tüm olumlu tahminlerin gerçekte ne kadarının doğru olduğunu anlamayı amaçlar.

Kesinlik = Gerçek Pozitifler / (Doğru Pozitifler + Yanlış Pozitifler)

Öte yandan hatırlama (Geri çağırma), pozitif olarak tahmin edilmesi gereken tüm örneklere bölünen gerçek pozitiflerin sayısıdır. Hatırlama, gerçek pozitif tahminlerin ne kadarının doğru olarak tanımlandığını algılama amacına sahiptir.

Geri Çağırma = Doğru Pozitifler / (Doğru Pozitifler + Yanlış Negatifler)

Karışıklı matrisi, modeldeki hataların nerede yapıldığını değerlendirmek için sınıflandırma problemlerinde kullanılan bir tablodur.

Satırlar, sonuçların olması gereken gerçek sınıfları temsil eder. Sütunlar yaptığımız tahminleri temsil eder. Bu tabloyu kullanarak hangi tahminlerin yanlış olduğunu görmek kolaydır.

Örnek: Bir Karışıklık Matrisi Oluşturma
Karışıklık matrisleri, lojistik bir regresyondan yapılan tahminlerle oluşturulabilir.

Şimdilik NumPy kullanılarak gerçek ve tahmin edilen değerler üretilir.
import numpy

Daha sonra "gerçek" ve "tahmin edilen" değerler için sayıların üretilmesi gerekecektir.
actual = numpy.random.binomial(1, 0.9, size = 1000)
predicted = numpy.random.binomial(1, 0.9, size = 1000)

Karışıklık matrisini oluşturmak için sklearn modülünden metriklerin içe aktarılması gerekiyor.
from sklearn import metrics.

Metrikler içe aktarıldığında, gerçek ve tahmin edilen değerler üzerinde karışıklık matrisi işlevi kullanılabilir.
confusion_matrix = metrics.confusion_matrix(actual, predicted)

Daha yorumlanabilir bir görsel görüntü oluşturmak için tabloyu bir karışıklık matrisi görüntüsüne dönüştürilmesi gerekiyor.
cm_display = metrics.ConfusionMatrixDisplay(confusion_matrix = confusion_matrix, display_labels = [False, True])

Ekranı görselleştirmek, pyplot'un matplotlib'den içe aktarılması gerektirr.
import matplotlib.pyplot as plt

Son olarak grafiği görüntülemek için pyplot'tan plot() ve show() fonksiyonları kullanılır.
cm_display.plot()
plt.show()

Tüm örneğin çalıştırılması:
```
import matplotlib.pyplot as plt
import numpy
from sklearn import metrics
actual = numpy.random.binomial(1,.9,size = 1000)
predicted = numpy.random.binomial(1,.9,size = 1000)
confusion_matrix = metrics.confusion_matrix(actual, predicted)
cm_display = metrics.ConfusionMatrixDisplay(confusion_matrix =
confusion_matrix, display_labels = [False, True])
cm_display.plot()
plt.show()
```

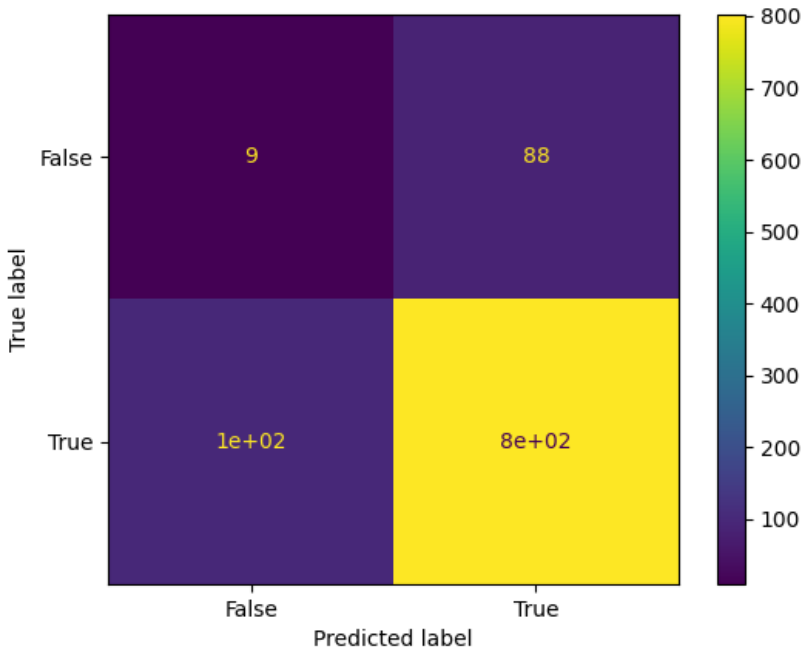

Sonuçların Açıklanması: Oluşturulan Karışıklık Matrisi dört farklı kadrana sahiptir.

- True Negative (Top-Left Quadrant)
- False Negative (Top-Right Quadrant)
- False Positive (Bottom-Left Quadrant)
- True Positive (Bottom-Right Quadrant)

Doğru, değerlerin doğru bir şekilde tahmin edildiği anlamına gelir; Yanlış, bir hata veya yanlış tahmin olduğu anlamına gelir.
Artık bir Karışıklık Matrisi yaptığımıza göre, modelin kalitesini ölçmek için farklı ölçüler hesaplayabiliriz. İlk olarak, Doğruluk'a bakalım.

Oluşturulan Metrikler
Matris, sınıflandırma modelini değerlendirmemize yardımcı olan birçok yararlı ölçüm sağlar. Farklı ölçüler şunları içerir: Doğruluk, Kesinlik, Duyarlılık (Geri Çağırma), Özgüllük ve aşağıda açıklanan F-skoru.

Kesinlik (Accuracy): Doğruluk, modelin ne sıklıkla doğru olduğunu ölçer.
Nasıl hesaplanır: (Doğru Olumlu + Doğru Olumsuz) / Toplam Tahminler
(True Positive + True Negative) / Total Predictions

Python Örneği: Accuracy = metrics.accuracy_score(actual, predicted)

Kesinlik (Precision): Öngörülen pozitiflerin yüzde kaçı gerçekten pozitiftir?
Nasıl Hesaplanır: True Positive / (True Positive + False Positive)
Kesinlik, doğru tahmin edilen olumsuz durumları değerlendirmez.
Pyhon kod örneği: Precision = metrics.precision_score(actual, predicted)

Sensitivity (Recall)
Of all the positive cases, what percentage are predicted positive?
Sensitivity (sometimes called Recall) measures how good the model is at predicting positives.
This means it looks at true positives and false negatives (which are positives that have been incorrectly predicted as negative).

Hassasiyet - Duyarlılık(Geri Çağırma - Hatırlama) (Sensitivity - Recall)
Tüm pozitif vakaların yüzde kaçının pozitif olduğu tahmin ediliyor?
Duyarlılık (bazen Geri Çağırma olarak da adlandırılır), modelin pozitifleri tahmin etmede ne kadar iyi olduğunu ölçer. Bu, gerçek pozitiflere ve yanlış negatiflere (yanlış bir şekilde negatif olarak tahmin edilen pozitiflere) baktığı anlamına gelir.

Nasıl Hesaplanır: True Positive / (True Positive + False Negative)
Duyarlılık, modelin bir şeyin olumlu olduğunu ne kadar iyi tahmin ettiğini anlamada iyidir.
Python kod örneği: *Sensitivity_recall = metrics.recall_score(actual, predicted)*

Özgüllük (Specificity)
Model, olumsuz sonuçları tahmin etmede ne kadar iyi? Özgüllük duyarlılığa benzer, ancak olumsuz sonuçlar açısından bakar.
Nasıl hesaplanır: True Negative / (True Negative + False Positive)
Geri Çağırmanın tam tersi olduğu için, ters konum etiketini alarak "recall_score function" işlevini kullanırız.
Python kod örneği: *Specificity = metrics.recall_score(actual, predicted, pos_label=0)*

F-score
F-score, kesinlik ve duyarlılığın "harmonik ortalamasıdır". Hem yanlış pozitif hem de yanlış negatif durumları dikkate alır ve dengesiz veri kümeleri için iyidir.
Nasıl hesaplanır : 2 * ((Precision * Sensitivity) / (Precision + Sensitivity))
Bu puan True Negative değerlerini dikkate almaz.
Python kod örneği: *F1_score = metrics.f1_score(actual, predicted)*

Bütün hesaplamalar tek bir Python komutunda:
```
#metrics
print({"Accuracy":Accuracy,"Precision":Precision,"Sensitivity_recall":Sensitivity_recall,"Specificity":Specificity,"F1_score":F1_score})
```

4.5. Çapraz Doğrulama tekniği

Çapraz doğrulama, bir eğitim veri kümesinin ve bağımsız bir veri kümesinin kullanımını içerir. Bu iki küme, orijinal veri kümesinin bölümlenmesinden kaynaklanır. Kümeler bir algoritmayı değerlendirmek için kullanılır.

İlk olarak, veri kümesi eşit büyüklükte örnek gruplarına bölünür. Bu gruplara katmanlar denir. Değerlendirilecek model, biri hariç tüm gruplarda eğitilir. Eğitimden sonra hariç tutulan üzerinde model test edilir. Bu işlem daha sonra kat sayısına bağlı olarak tekrar tekrar yapılır. Tekrarlamanın nedeni, her katın dışlanması ve test seti olarak hareket etmesidir. Son olarak, algoritmanın bir problem üzerinde ne kadar etkili olduğuna dair bir tahmin elde etmek için tüm katmanlardaki ortalama performans ölçülür.

Popüler bir çapraz doğrulama tekniği, k-katlı çapraz doğrulamadır. Yukarıda açıklanan aynı adımları kullanır. k, (kullanıcı tarafından belirlenen bir sayıdır), kat sayısı anlamına gelir. k değeri, veri kümesinin boyutuna göre değişebilir, ancak örnek olarak, 4 katlı çapraz doğrulama senaryosunu kullanalım.

Model dört kez eğitilecek ve test edilecektir. Diyelim ki ilk turda kıvrımlar 1,2 ve 3. katmanlarda olacak. Test 4. katmanda yapılacak. İkinci tur için 1,2 ve 4. Katmanlarında antrenman yapabilir ve 3. katmanda test yapabilir. 1,3 ve 4 numaralı katmanlarda antrenman yapabilir ve 2. katmanda test edebilir.

Son turda 2. ve 4. katmandada test yapılacak ve 1. katmandada test edilecek. Antrenman ve test verileri arasındaki değişim bu yöntemi çok etkili kılıyor. Ancak, holdout tekniğiyle karşılaştırıldığında, çapraz doğrulamanın çalışması daha uzun sürer ve daha fazla hesaplama kaynağı kullanır.

Modelleri ayarlarken, görünmeyen verilerde genel model performansını artırmayı hedefliyoruz. Hiperparametre ayarı, test setlerinde çok daha iyi performansa yol açabilir. Bununla birlikte, parametreleri test kümesine optimize etmek, modelin görünmeyen veriler üzerinde daha kötü performans göstermesine neden olan bilgi sızıntısına neden olabilir. Bunu düzeltmek için çapraz doğrulama yapabiliriz.
CV'yi daha iyi anlamak için iris veri seti üzerinde farklı yöntemler uygulayacağız. Önce verileri yükleyelim ve ayıralım.

```
from sklearn import datasets

X, y = datasets.load_iris(return_X_y=True)
```

Çapraz doğrulama için birçok yöntem vardır, k-kat çapraz doğrulamaya bakarak başlayacağız.

K-Fold
Modelde kullanılan eğitim verileri, modeli doğrulamak için kullanılmak üzere k adet daha küçük kümeye bölünür. Model daha sonra eğitim setinin k-1 katları üzerinde eğitilir. Kalan kat daha sonra modeli değerlendirmek için bir doğrulama seti olarak kullanılır.
Farklı iris çiçek türlerini sınıflandırmaya çalışacağımız için bir sınıflandırıcı model almamız gerekecek, bu alıştırma için bir DecisionTreeClassifier kullanacağız. Ayrıca sklearn'den CV modüllerini içe aktarmamız gerekecek.

```
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import KFold, cross_val_score
```

Yüklenen verilerle artık değerlendirme için bir model oluşturabilir ve sığdırabiliriz.
```
clf = DecisionTreeClassifier(random_state=42)
```

Şimdi modelimizi değerlendirelim ve her k-katlamada nasıl performans gösterdiğini görelim.
```
k_folds = KFold(n_splits = 5)

scores = cross_val_score(clf, X, y, cv = k_folds)
```
Tüm kıvrımlar için puanların ortalamasını alarak CV'nin genel olarak nasıl performans gösterdiğini görmek de iyi bir uygulamadır.

Kod örneği: Run k-fold CV:
```
from sklearn import datasets
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import KFold, cross_val_score

X, y = datasets.load_iris(return_X_y=True)

clf = DecisionTreeClassifier(random_state=42)

k_folds = KFold(n_splits = 5)

scores = cross_val_score(clf, X, y, cv = k_folds)

print("Cross Validation Scores: ", scores)
print("Average CV Score: ", scores.mean())
print("Number of CV Scores used in Average: ", len(scores))
```

Tabakalı K-Fold (K-Katlama):
Sınıfların dengesiz olduğu durumlarda, hem tren hem de doğrulama setlerindeki dengesizliği hesaba katacak bir yola ihtiyacımız var. Bunu yapmak için hedef sınıfları katmanlaştırabiliriz, yani her iki küme de tüm sınıfların eşit bir oranına sahip olacaktır.

Kod örneği:

```
from sklearn import datasets
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import StratifiedKFold, cross_val_score

X, y = datasets.load_iris(return_X_y=True)

clf = DecisionTreeClassifier(random_state=42)

sk_folds = StratifiedKFold(n_splits = 5)

scores = cross_val_score(clf, X, y, cv = sk_folds)

print("Cross Validation Scores: ", scores)
print("Average CV Score: ", scores.mean())
print("Number of CV Scores used in Average: ", len(scores))
```

Kat sayısı aynı da, tabakalı sınıflar olsa emin olunmasından ortalama CV temel aynık-katından artar.
Leave-One-Out (LOO)

Eğitim veri setindeki k-kat LeaveOneOut gibi bölmelerin sayısını seçmek yerine, doğrulamak için 1 gözlem ve eğitmek için n-1 gözlem kullanın. Bu yöntem, kapsamlı bir tekniktir.
Kod örneği: Run LOO CV:

```
from sklearn import datasets
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import LeaveOneOut, cross_val_score

X, y = datasets.load_iris(return_X_y=True)

clf = DecisionTreeClassifier(random_state=42)

loo = LeaveOneOut()

scores = cross_val_score(clf, X, y, cv = loo)
```

```
print("Cross Validation Scores: ", scores)
print("Average CV Score: ", scores.mean())
print("Number of CV Scores used in Average: ", len(scores))
```

Yapılan çapraz doğrulama puanlarının sayısının veri setindeki gözlem sayısına eşit olduğunu görebiliriz. Bu durumda iris veri setinde 150 gözlem vardır.
Ortalama CV puanı %94'tür.

Leave-P-Out (LPO)
P-Out, doğrulama setimizde kullanmak üzere p sayısını seçebilmemiz açısından, Birini Bırakma (Leave-One-Out (fikrinden nüanslı bir farktır.

Kod örneği: Run LPO CV

```
from sklearn import datasets
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import LeavePOut, cross_val_score

X, y = datasets.load_iris(return_X_y=True)

clf = DecisionTreeClassifier(random_state=42)

lpo = LeavePOut(p=2)

scores = cross_val_score(clf, X, y, cv = lpo)

print("Cross Validation Scores: ", scores)
print("Average CV Score: ", scores.mean())
print("Number of CV Scores used in Average: ", len(scores))
```

Gördüğümüz gibi, bu kapsamlı bir yöntem, bir p = 2 olsa bile, Birini Bırakma'dan çok daha fazla puan hesaplıyoruz, ancak kabaca aynı ortalama CV puanına ulaşıyor.

Karışık Böl (Shuffle Split)

KFold'dan farklı olarak ShuffleSplit, trend veya doğrulama setlerinde kullanılmamak üzere verilerin bir yüzdesini dışarıda bırakır. Bunu yapmak için tren ve test boyutlarının yanı sıra bölmelerin sayısına karar vermeliyiz.

Kod örneği: Run Shuffle Split CV

```
from sklearn import datasets
from sklearn.tree import DecisionTreeClassifier
```

```
from sklearn.model_selection import ShuffleSplit, cross_val_score

X, y = datasets.load_iris(return_X_y=True)

clf = DecisionTreeClassifier(random_state=42)

ss = ShuffleSplit(train_size=0.6, test_size=0.3, n_splits = 5)

scores = cross_val_score(clf, X, y, cv = ss)

print("Cross Validation Scores: ", scores)
print("Average CV Score: ", scores.mean())
print("Number of CV Scores used in Average: ", len(scores))
```

Bitiş Notları
Bunlar, modellere uygulanabilecek CV yöntemlerinden sadece birkaçıdır. Çoğu modelin kendi sınıfına sahip olduğu daha birçok çapraz doğrulama sınıfı vardır. Daha fazla CV seçeneği için sklearns çapraz doğrulamasına göz atın.

4.6. Veri Gürültüsü

Makine öğrenimi veri setinde iki tür gürültü olabilir: tahmin özniteliklerinde (öznitelik gürültüsü) ve hedef öznitelikte (sınıf gürültüsü). Bir veri setinde gürültünün varlığı, öğrenme algoritmalarının performansını düşüren model karmaşıklığını ve öğrenme süresini artırabilir.

4.7. Kayıp Veri

Eğer veride bazı örneklerin bazı özellikleri kayıpsa izlenecek iki yol vardır:

- Kayıp özelliklere sahip örnekler veriden tamamen çıkartılır.
- Kayıp verilerle çalısabilecek sekilde algoritma düzenlenir.

Eğer kayıplı örneklerin sayısı birinci seçenek uygulanamayacak kadar çoksa ikinci seçenek uygulanmalıdır. Kayıp bilgiye sahip özellik vektörü için kazanç hesaplanırken kayıplı örnekler hariç tutularak bilgi kazancı normal sekilde hesaplanır ve daha sonra F katsayısıyla çarpılır. F, kayıpsız verinin tamamına oranıdır.

$IG(X) = F.(H(X) - H(V, X))$.

Kayıp bilgiye sahip özellik vektörü içinde en sık tekrarlanan değerin kayıp bilgi yerine yazılması da önerilen yöntemlerdendir.

Eksik değerler ortaya çıktığında veri noktalarını kolayca atamayız. Sınıflandırılacak bir test noktası da eksik değişkenlere sahip olabilir. Sınıflandırma ağaçlarının, eksik değerlerini tamamlamanın güzel bir yolu vardır. Sınıflandırma ağaçları, bir yedek ayrım bularak sorunu çözer. Başka bir değişkene dayalı başka bir ayrım bulmak için, sınıflandırma ağaçları diğer tüm değişkenleri kullanarak tüm bölünmelere bakar ve optimum bölünmeye en çok benzeyen eğitim veri noktaları bölümünü veren birini arar. En iyi bölünmenin sonucunu tahmin etmeye çalışırlar.

4.8. Maliyet hesabı

Zaman
Bellek
Hassasiyet
Karşılaştırma
Aşırı uyum
Korolasyon

5. Sınıflandırma Algoritmaları

Bir Makine Öğrenimindeki bir sınıflandırıcı, ayrık veya sürekli özellik değerlerinin bir vektörünü giren ve tek bir ayrık değer olan sınıfı çıkaran bir sistemdir. Bir dizi öğenin sınıfını veya kategorisini tahmin etmek için sınıflandırma algoritmaları kullanılır.
Sınıflandırma algoritmaları:

Diğer sınıflandırma tekniklerinden bazıları aşağıda verilmiştir:

- K-En Yakın Komşu Algoritması (K-Nearest Neighbour Algorithm)
- Lojistik Regresyon (Logistic Regression)
- Destek Vektör Makineleri (Support Vector Machines)
- Karar Ağaçları (Decision Tree)
- Rasgele Orman Kümeleri (Random Forests)
- Yapay Sinir Ağları (Artifical Neural Networks)
- Naive Bayes

5.1. Karar Ağaçları

Karar ağacı algoritması, denetimli öğrenme kategorisine girer. Hem regresyon hem de sınıflandırma problemlerini çözmek için kullanılılar. Karar ağacı, her yaprak düğümün bir sınıf etiketine karşılık geldiği ve özniteliklerin ağacın iç düğümünde temsil edildiği sorunu çözmek için ağaç temsilini kullanır. Karar ağacını kullanarak herhangi bir boole fonksiyonunu ayrık öznitelikler üzerinde temsil edebiliriz. Karar ağacı, istatistik, veri madenciliği ve makine öğrenmesinde kullanılan öngörülü modelleme yaklaşımlarından biridir.

Karar ağaçları metotu, sınıflama işlemidir. Giriş verisinin bir kümeleme algoritması yardımıyla tekrar tekrar gruplara bölünmesine dayanır. Grubun tüm elemanları aynı sınıf etiketine sahip olana kadar kümeleme işlemi derinlemesine devam eder.

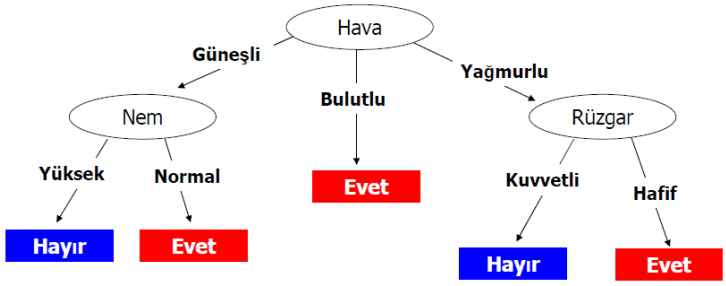

Karar ağaçları çok boyutlu (özellikli) veriyi belirlenmiş şartlara bağlı olarak parçalara böler.

Karar ağacı tipleri ikiye ayrılır:

- Entropiye dayalı sınıflandırma ağaçları (ID3, C4.5)
- Regresyon ağaçları (CART).

Karar Ağacı Algoritması:

Karar ağaçları eğiticili öğrenme için çok yaygın bir yöntemdir. Algoritmanın adımları:

1) Veri yığınından öğrenme kümesi oluşturulur.
2) Öğrenme kümesindeki örnekleri en iyi ayıran nitelikler belirlenir.
3) Seçilen nitelikler ile ağacın düğümleri oluşturulur ve herbir düğümde alt düğümler veya ağacın yapraklarını oluşturulur. Alt düğümlere ait alt veri kümesinin örneklerini belirlenir
4) 3. adımda oluşturulan her alt veri kümesi için
    - Örneklerin hepsi aynı sınıfa aitse
    - Örnekleri bölecek nitelik kalmamışsa
    - Kalan niteliklerin değerini taşıyan örnek yoksa işlemi sonlandır. Diğer durumda alt veri kümesini ayırmak için 2. adımdan devam edilir.

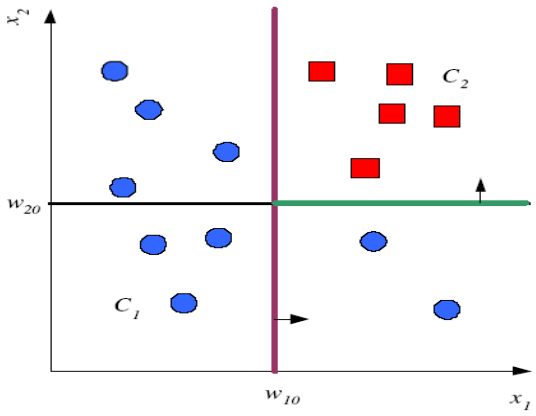

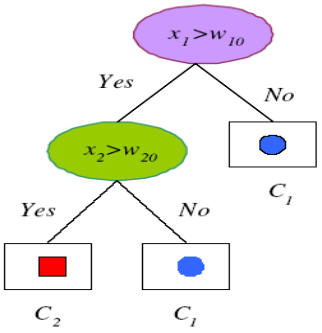

Ezber (Overfitting: Aşırı Uyum): Tüm makine öğrenmesi yöntemlerinde verinin ana hatlarının modellenmesi esas alındığı için öğrenme modelinde ezberden (overfitting: ağırı uyum) kaçınılmalıdır. **Tüm karar ağaçları önlem alınmazsa ezber yapar**. Bu yüzden ağaç olusturulurken veya olusturulduktan sonra budama yapılmalıdır.

Ağaç Budama:
Budama, sınıflandırmaya katkısı olmayan bölümlerin karar ağacından çıkarılması işlemidir. Bu sayede karar ağacı hem sade hem de anlaşılabilir hale gelir. İki çesit budama yöntemi vardır: Ön budama, sonradan budama.

Ön budama islemi ağaç oluşturulurken yapılır. Bölünen nitelikler, değerleri belli bir eşik değerinin (hata toleransının) üstünde değilse o noktada ağaç bölümleme işlemi durdurulur ve o an elde bulunan kümedeki baskın sınıf etiketi, yaprak olarak oluşturulur.

Sonradan Budama: Sonradan budama islemi ağaç olusturulduktan sonra devreye girer. Alt ağaçları silerek yaprak oluşturma, alt ağaçları yükseltme, dal kesme şeklinde yapılabilir.

Aşırı uyumu önlemek için ağacı büyütme durdurulabilir, ancak durdurma kriteri miyop olma eğilimindedir. Bu nedenle standart yaklaşım, "dolu" bir ağaç oluşturmak ve ardından budama yapmaktır. Düğümdeki noktalar için yanlış bir sınıflandırma yapma olasılığı olduğu da unutulmamalıdır. Tüm ağaç için yanlış sınıflandırma olasılığını elde etmek için, toplam olasılık formülüne göre yaprak düğüm içi hata oranının ağırlıklı toplamı hesaplanır.

Aşırı uyuma karşı hiçbir savunma yoktur. Aşırı büyümüş ağaç er ya da geç budanacaktır. Ne zaman durulacağına karar vermenin birkaç yolu vardır:

- Tüm terminal düğümleri saf olana kadar devam edilir.
- Her bir terminal düğümündeki veri sayısı belirli bir eşikten, örneğin 5'ten, hatta 1'den büyük olmayana kadar devam edilir.
- Ağaç yeterince büyük olduğu sürece, ilk ağacın boyutu kritik değildir.

Buradaki anahtar, ilk ağacı yeniden budamadan önce yeterince büyük yapmaktır!

Sınıflandırma Ağaçları:

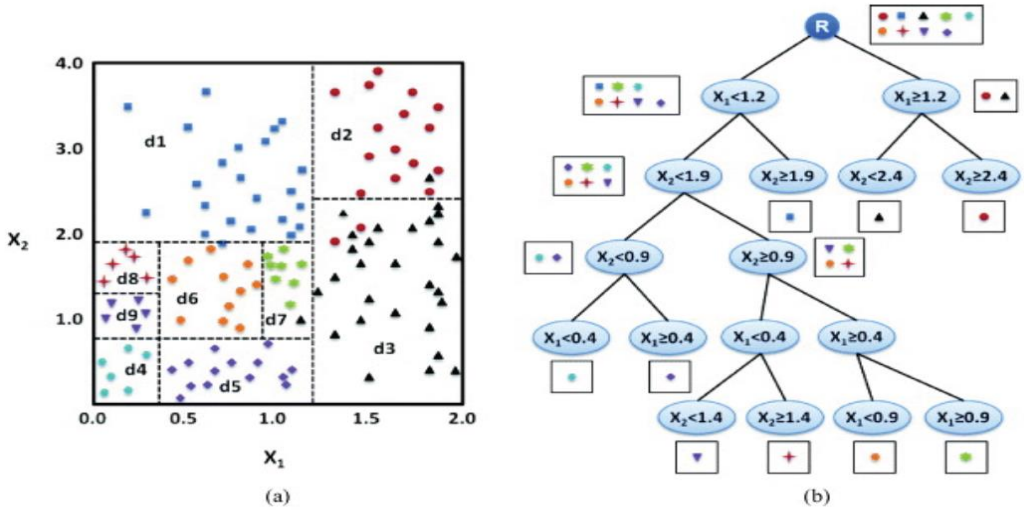

Öznitelik seçim ölçüsü:

Karar Ağacında en büyük zorluk, her seviyede kök düğüm için özniteliğin tanımlanmasıdır. Bu işlem öznitelik seçimi olarak bilinir. İki popüler öznitelik seçim ölçüsü bulunmaktadır:

1) Bilgi Kazancı
2) Gini İndeksi

Bilgi Kazancı:

Eğitim örneklerini daha küçük alt kümelere bölmek için karar ağacında bir düğüm kullandığımızda entropi değişir. Bilgi kazancı, entropideki bu değişimin bir ölçüsüdür.

Tanım: Diyelim ki S bir örnekler kümesi, A bir nitelik, Sv, S'nin A = v ile alt kümesi ve Değerler (A), A'nın tüm olası değerlerinin kümesidir, o zaman

$$Gain(S, A) = Entropy(S) - \sum_{veValues(A)} \frac{|S_v|}{|S|}.Entropy(S_v)$$

Örnek:

X = {a,a,a,b,b,b,b,b} kümesi için

Toplam örnek: 8

b: 5 örnekleri

a: 3'ün örnekleri

$$Entropy H(X) = -\left[\left(\frac{3}{8}\right) log_2 \frac{3}{8} + \left(\frac{5}{8}\right) log_2 \frac{5}{8}\right]$$

```
= -[0.375 * (-1.415) + 0.625 * (-0.678)]
=-(-0.53-0.424)
= 0.954
```

$$Log_2(a) = b \; ise \; 2^b = a \; dır.$$
$$Log_{10}(2^b) = Log_{10}(a)$$

$$b = \frac{1}{0.3} Log_{10}(a)$$

Bilgi Kazanımını Kullanarak Karar Ağacı Oluşturma

Gereklilikler:

- Kök düğümle ilişkili tüm eğitim örnekleriyle başlanır
- Her bir düğümün hangi öznitelikle etiketleneceğini seçmek için bilgi kazancı kullanılır.
- Not: Hiçbir kökten yaprağa yol, aynı ayrık özniteliği iki kez içermemelidir
- Her alt ağacı, ağaçta o yolda sınıflandırılacak eğitim örneklerinin alt kümesinde yinelemeli olarak oluşturulur.

Sınır vakaları:

- Tüm pozitif veya tüm negatif eğitim örnekleri kalırsa, o düğümü buna göre "evet" veya "hayır" olarak etiketlenr.
- Hiçbir öznitelik kalmazsa, o düğümde kalan eğitim örneklerinin çoğunluk oyu ile etiketlenir.
- Örnek kalmadıysa, ebeveynin eğitim örnekleri çoğunluk oyu ile etiketlenir.

Örnek:

Şimdi aşağıdaki veriler için Bilgi kazanımını kullanarak bir Karar Ağacı çizelim.

Eğitim seti: 3 özellik ve 2 sınıf

X	Y	Z	C
1	1	1	I
1	1	0	I
0	0	1	II
1	0	0	II

Burada 3 özellik ve 2 çıktı sınıf var. Bilgi kazanımını kullanarak bir karar ağacı oluşturmak. Her bir özellik alınr ve her bir özellik için bilgi kazancı hesaplanır.

ID3 Algoritması:

Sadece kategorik veri ile çalısan bir yöntemdir. Her iterasyonun ilk adımında veri örneklerine ait sınıf bilgilerini tasıyan vektörün entropisi belirlenir. Daha sonra özellik vektörlerinin sınıfa bağımlı entropileri hesaplanarak ilk adımda hesaplanan entropiden çıkartılır. Bu sekilde elde edilen değer ilgili özellik vektörüne ait kazanç değeridir. En büyük kazanca sahip özellik vektörü ağacın o iterasyonda belirlenen dallanmasını gerçeklestirir.

Örnek:

2 özellik vektörü (V1 ve V2) ile S sınıf vektörüne sahip 4 örnekli veri kümesi verilmistir. ID3 algoritması ile ilk dallanma hangi özellik üzerinde gerçeklesir ?

- H(S) - H(V1,S)
- H(S) - H(V2,S)

V1	V2	S
A	C	E
B	C	F
B	D	E
B	D	F

Sınıf Entropisi

$$H(S) = -\left(\frac{1}{2}\log_2\frac{1}{2} + \frac{1}{2}\log_2\frac{1}{2}\right) = 1$$

V1 Entropisi

$$H(V1) = \frac{1}{4}H(A) + \frac{3}{4}H(B)$$

$$= \frac{1}{4}0 - \frac{3}{4}\left(\frac{1}{3}\log_2\frac{1}{3} + \frac{2}{3}\log_2\frac{2}{3}\right) = 0 + \frac{3}{4}0{,}9183 = 0{,}6887$$

V2 Entropisi

$$H(V2) = \frac{1}{2}H(C) + \frac{1}{2}H(D) = \frac{1}{2} + \frac{1}{2} = 1$$

V1 seçilir...

C4.5 Algoritması:

ID3 algoritmasının nümerik özellik içeren veriye uygulanabilen seklidir. ID3'ten tek farkı nümerik özelliklerin kategorik hale getirilebilmesini sağlayan bir esikleme yöntemini içermesidir. Temel mantık nümerik özellik vektöründeki tüm değerler ikili olarak ele alınarak ortalamaları esik olarak denenir. Hangi esik değeriyle bilgi kazanımı en iyi ise o değer seçilir. Seçilen esiğe göre özellik vektörü kategorize edilir ve ID3 uygulanır.

Örnek:

Kredilendirmede “Mükemmel”, “İyi” ve “Kötü” değerleri alabilen bir özelliğimiz vardır. Toplam 14 gözlem var. Bunlardan 7'si Normal Sorumluluk sınıfına, 7'si ise Yüksek Sorumluluk Sınıfına aittir. Yani kendi başına eşit bir bölünmedir. En üst satırda özetlersek, kredi notu özelliği için Mükemmel değerine sahip 4 gözlem olduğunu görebiliriz. Ayrıca, “Mükemmel” Kredi Notu için hedef değişkenimin nasıl bölündüğünü de görülebiliyor. Kredi notu için “Mükemmel” değeri alan gözlemler için Normal Sorumluluk sınıfına ait 3 adet ve Yüksek Sorumluluk sınıfına ait sadece 1 adet gözlem bulunmaktadır. Benzer şekilde diğer Kredi Notu değerleri için de beklenmedik durum tablosundan bu değerler bulunabilir.

Credit Rating	Liability		
	Normal	High	Total
Excellent	3	1	4
Good	4	2	6
Poor	0	4	4
Total	7	7	14

Bu örnek için, beklenmedik durum tablosunu, hedef değişkeninin entropisini kendi başına hesaplamak için kullanılacak ve ardından özellik, kredi notu hakkında ek bilgiler verilen hedef değişkenin entropisi hesaplanacak. Bu, "Kredi Notu"nun hedef değişkenin "Yükümlülük" için ne kadar ek bilgi sağladığını hesaplanmasına olanak sağlayacak.

$$E(Liability) = -\frac{7}{14}\log_2\left(\frac{7}{14}\right) - \frac{7}{14}\log_2\left(\frac{7}{14}\right)$$

$$= -\frac{1}{2}\log_2\left(\frac{1}{2}\right) - \frac{1}{2}\log_2\left(\frac{1}{2}\right)$$

$$= 1$$

Hedef değişkenin entropisi, “Normal” ve “Yüksek” sınıf etiketi arasındaki eşit bölünme nedeniyle maksimum düzensizlikte 1'dir. Bir sonraki adım, kredi puanı hakkında ek bilgi verilen hedef değişken Yükümlülük'ün entropisini hesaplamaktır. Bunun için her Kredi Puanı değeri için Sorumluluk entropisi hesaplanacak ve her bir değerde sonuçlanan gözlemlerin

oranının ağırlıklı ortalaması kullanılarak bunlar eklenecektir. Neden ağırlıklı ortalama kullanıldığı, bunu karar ağaçları bağlamında tartışıldığında daha da netleşecektir.

$$E(Liability \mid CR = Excellent) = -\frac{3}{4}\log_2\left(\frac{3}{4}\right) - \frac{1}{4}\log_2\left(\frac{1}{4}\right) \approx 0.811$$

$$E(Liability \mid CR = Good) = -\frac{4}{6}\log_2\left(\frac{4}{6}\right) - \frac{2}{6}\log_2\left(\frac{2}{6}\right) \approx 0.918$$

$$E(Liability \mid CR = Poor) = -0\log_2(0) - \frac{4}{4}\log_2\left(\frac{4}{4}\right) = 0$$

Weighted Average:

$$E(Liability \mid CR) = \frac{4}{14} \times 0.811 + \frac{6}{14} \times 0.918 + \frac{4}{14} \times 0 = 0.625$$

Credit Rating	Liability		
	Normal	High	Total
Excellent	3	1	4
Good	4	2	6
Poor	0	4	4
Total	7	7	14

Kredi Derecelendirme özelliği verilen hedef değişken için entropi elde edildi. Artık bu özelliğin ne kadar bilgilendirici olduğunu görmek için Kredi Notundan Yükümlülük Bilgi Kazancı hesaplanmalıdır.

Inf ormation Gain:

$$IG(Liability, CR) = E(Liability) - E(Liability \mid CR)$$

$$= 1 - 0.625 = 0.375$$

Kredi Notunu bilmek, hedef değişkenimiz olan Sorumluluk etrafındaki belirsizliği azaltmamıza yardımcı oldu! İyi bir özelliğin yapması gereken de bu değil mi? Hedef değişkenimiz hakkında bize bilgi verir misiniz? İşte tam olarak bu, karar ağaçlarının, her bir bölünmede hedef değişkeni tahmin etmeye yaklaşmak ve aynı zamanda ağacı bölmeyi ne zaman durduracağını belirlemek için düğümlerini hangi özelliğin üzerine böleceğini belirlemek için entropi ve bilgi kazancını nasıl ve neden kullandığıdır! (elbette maksimum derinlik gibi hiper parametrelere ek olarak).

Gini yöntemi

Makine öğrenmesi karar ağacı algoritmasında örnekleri bölmenin birçok yolu vardır, bunlardan biride eğitimde GINI yöntemidir.

Gini yöntemi formülü kullanır: Gini = $1 - (x/n)^2 - (y/n)^2$

Burada n örnek sayısı, x olumlu sayısı, y olumsuzların sayısıdır. 40 oyunda 4'u kazanılmış, 36'u kaybedilmiş ise Gini indeksini hesaplayınız.

Gini= 1-(4/40)^2-(36/40)^2=1-1/100-81/100=18/100=0.18

Yorum: %18'nin bir yöne %82'nin ise diğer yöne gideceğini anlamına gelir.

Örnek: Karar Ağacı

Bir kişiye verilen bir kredinin bir zararla sonuçlanıp sonuçlanmayacağını tahmin etmek için bir karar ağacı oluşturulmuştur. Tüm veri kümesi 30 örnekten oluşmaktadır. 16'sı silinen sınıfa, diğer 14'ü silinmeyen sınıfa aittir. İki değer alabilen “Bakiye” -> “< 50K” veya “>50K” ve üç değer alabilen “Konut” -> “KENDİ”, “KİRALIK” veya “DİĞER” olmak üzere iki özelliğimiz var. Entropi ve Bilgi Kazanımı kavramlarını kullanarak bir karar ağacı algoritmasının hangi özniteliğin ilk olarak bölüneceğine ve hangi özelliğin daha fazla bilgi sağladığına veya hedef değişkenimiz hakkındaki belirsizliği ikisinden daha fazla azalttığına nasıl karar vereceğini göstereceğim.

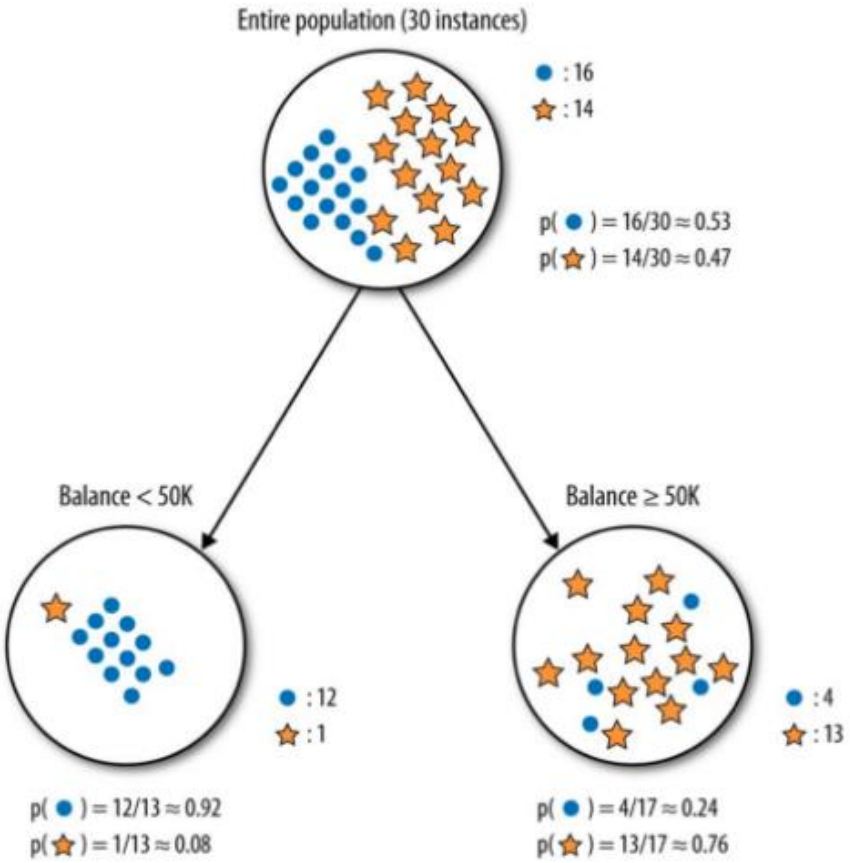

Özellik 1: Denge

Noktalar, sınıf hakkı olan veri noktalarıdır ve yıldızlar, silinmeyenlerdir. Ana düğümü öznitelik dengesine bölmek bize 2 alt düğüm verir. Sol düğüm, silme sınıfından 12/13 (0.92 olasılık) gözlem ile toplam gözlemlerin 13'ünü ve sınıfın yazılmayan sınıfından sadece 1/13 (0.08 olasılık) gözlemi alır. Sağ düğüm, silinmeyen sınıftan 13/17(0.76 olasılık) ve silinen sınıftan 4/17 (0.24 olasılık) ile toplam gözlemin 17'sini alır.

Ana düğümün entropisini hesaplayalım ve Denge üzerinde bölerek ağacın ne kadar belirsizliği azaltabileceğini görelim.

$$E(Parent) = -\frac{16}{30}\log_2\left(\frac{16}{30}\right) - \frac{14}{30}\log_2\left(\frac{14}{30}\right) \approx 0.99$$

$$E(Balance < 50K) = -\frac{12}{13}\log_2\left(\frac{12}{13}\right) - \frac{1}{13}\log_2\left(\frac{1}{13}\right) \approx 0.39$$

$$E(Balance > 50K) = -\frac{4}{17}\log_2\left(\frac{4}{17}\right) - \frac{13}{17}\log_2\left(\frac{13}{17}\right) \approx 0.79$$

Weighted Average of entropy for each node:

$$E(Balance) = \frac{13}{30} \times 0.39 + \frac{17}{30} \times 0.79$$
$$= 0.62$$

Information Gain:

$$IG(Parent, Balance) = E(Parent) - E(Balance)$$
$$= 0.99 - 0.62$$
$$= 0.37$$

Özelliğe göre bölme, “Denge” hedef değişkenimiz üzerinde 0.37'lik bir bilgi kazanımına yol açar. Aynı şeyi nasıl karşılaştırdığını görmek için “Konut” özelliği için yapalım.

Özellik 2: Konut

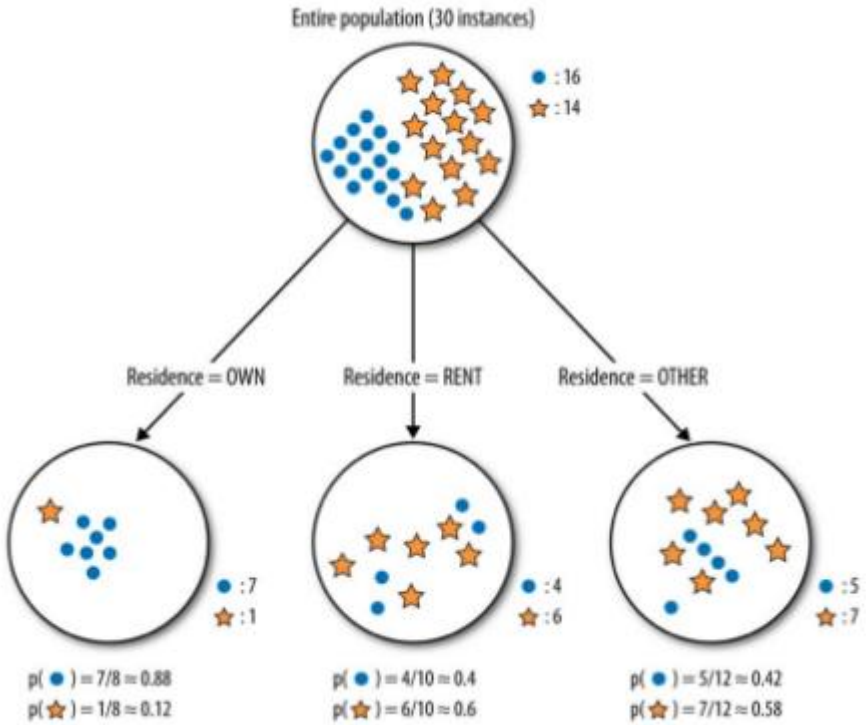

Ağacı Residence'ta bölmek bize 3 alt düğüm verir. Sol alt düğüm, silinen sınıftan 7/8 (0.88 olasılık) gözlem ile toplam gözlemlerin 8'ini ve silinmeyen sınıftan sadece 1/8 (0.12 olasılık) gözlem alır. Orta alt düğümler, silinen sınıftan 4/10 (0,4 olasılık) ve silinmeyen sınıftan 6/10(0,6 olasılık) gözlem ile toplam gözlemlerin 10'unu alır. Sağ alt düğüm, silme sınıfından 5/12 (0.42 olasılık) gözlem ve silinmeyen sınıftan 7/12 (0.58) gözlem ile toplam gözlemlerin 12'sini alır. Ana düğümün entropisini zaten biliyoruz. "Konut"tan elde edilen bilgi kazancını hesaplamak için bölmeden sonraki entropiyi hesaplamamız yeterlidir.

$$E(Residence = OWN) = -\frac{7}{8}\log_2\left(\frac{7}{8}\right) - \frac{1}{8}\log_2\left(\frac{1}{8}\right) \approx 0.54$$

$$E(Residence = RENT) = -\frac{4}{10}\log_2\left(\frac{4}{10}\right) - \frac{6}{10}\log_2\left(\frac{6}{10}\right) \approx 0.97$$

$$E(Residence = OTHER) = -\frac{5}{12}\log_2\left(\frac{5}{12}\right) - \frac{7}{12}\log_2\left(\frac{7}{12}\right) \approx 0.98$$

Weighted Average of entropies for each node:

$$E(Residence) = \frac{8}{30} \times 0.54 + \frac{10}{30} \times 0.97 + \frac{12}{30} \times 0.98 = 0.86$$

Weighted Average of entropies for each node:

$$E(Residence) = \frac{8}{30} \times 0.54 + \frac{10}{30} \times 0.97 + \frac{12}{30} \times 0.98 = 0.86$$

Information Gain:

$$\begin{aligned} IG(Parent, Residence) &= E(Parent) - E(Residence) \\ &= 0.99 - 0.86 \\ &= 0.13 \end{aligned}$$

Denge özelliğinden gelen bilgi kazanımı, Konut'tan elde edilen bilgiden neredeyse 3 kat daha fazla! Geri dönüp grafiklere bir göz atarsanız, Denge'de bölünen alt düğümlerin, Yerleşim düğümlerinden daha saf göründüğünü görebilirsiniz. Bununla birlikte, ikamet için en soldaki düğüm de çok saftır, ancak ağırlıklı ortalamaların devreye girdiği yer burasıdır. Bu düğüm çok saf olmasına rağmen, toplam gözlemlerin en az miktarına sahiptir ve bir sonuç, Yığındaki bölmeden toplam entropiyi hesapladığımızda saflığının küçük bir kısmına katkıda bulunur. Bu önemlidir çünkü bir özelliğin genel bilgi gücünü arıyoruz ve sonuçlarımızın bir özellikteki nadir bir değer tarafından çarpıtılmasını istemiyoruz.

Kendi başına Balance özelliği, hedef değişkenimiz hakkında Konuttan daha fazla bilgi sağlar. Hedef değişkenimizde daha fazla düzensizliği azaltır. Bir karar ağacı algoritması, Balance kullanarak verilerimizde ilk bölmeyi yapmak için bu sonucu kullanır. Bundan sonra, karar ağacı algoritması, bir sonraki hangi özelliği böleceğine karar vermek için her bölmede bu süreci kullanacaktır. Gerçek dünya senaryosunda, ikiden fazla özellik ile ilk bölme en bilgilendirici özellik üzerinde yapılır ve daha sonra her bölmede, her bir ek özellik için bilgi kazancının yeniden hesaplanması gerekir, çünkü her birinden elde edilen bilgi kazancı ile aynı olmaz. özellik kendi başına. Entropi ve bilgi kazancı, sonuçları değiştirecek bir veya daha fazla bölme yapıldıktan sonra hesaplanmalıdır. Bir karar ağacı, önceden tanımlanmış bir derinliğe ulaşana ya da hiçbir ek bölünme, genellikle hiper parametre olarak da belirlenebilen belirli bir eşiğin ötesinde daha yüksek bir bilgi kazanımına neden olana kadar derinleştikçe ve derinleştikçe bu işlemi tekrarlar!

Example: Decision Tree - Classification

Predictors | Target

Outlook	Temp	Humidity	Windy	Play Golf
Rainy	Hot	High	False	No
Rainy	Hot	High	True	No
Overcast	Hot	High	False	Yes
Sunny	Mild	High	False	Yes
Sunny	Cool	Normal	False	Yes
Sunny	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Rainy	Mild	High	False	No
Rainy	Cool	Normal	False	Yes
Sunny	Mild	Normal	False	Yes
Rainy	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Sunny	Mild	High	True	No

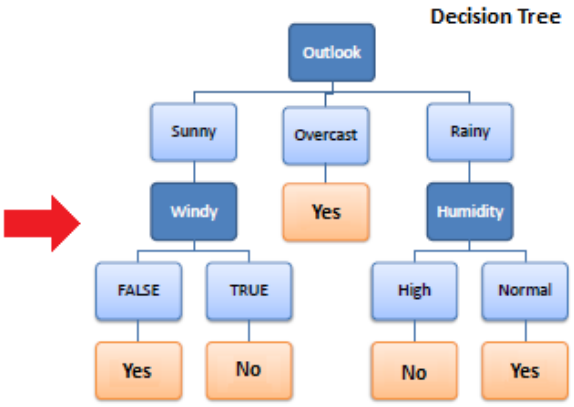

Bir karar ağacı, bir kök düğümden yukarıdan aşağıya oluşturulur ve verileri benzer değerlere sahip (homojen) örnekler içeren alt kümelere ayırmayı içerir. ID3 algoritması, bir örneğin homojenliğini hesaplamak için entropiyi kullanır. Örnek tamamen homojen (Olma olasılığı 1 ise olmma olasılığı sıfırdır. Tüm olasıklar toplamı bire eşit olmak zorundadır) ise entropi sıfırdır ve örnek eşit olarak bölünmüşse entropisi birdir.

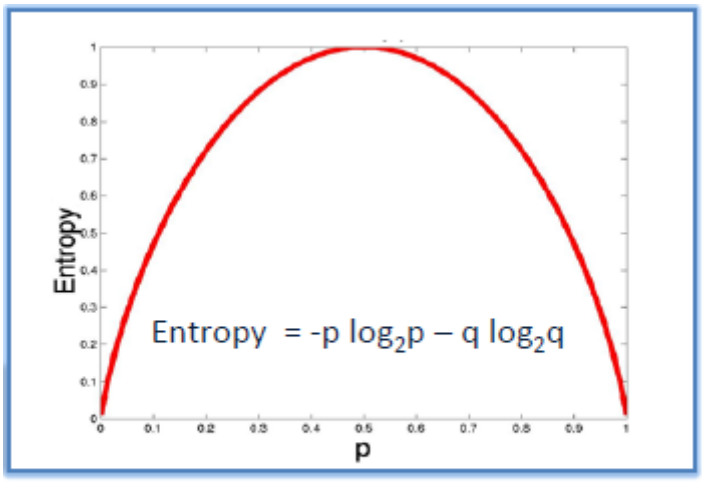

$$\text{Entropy} = -0.5 \log_2 0.5 - 0.5 \log_2 0.5 = 1$$

y=Log2(x)=Log10(x)/0.3

Log10(2)=0.3, Log10(3)=0.477, Log10(5)=0.7, Log10(7)=0.845

Bir karar ağacı oluşturmak için aşağıdaki gibi sıklık tablolarını kullanarak iki tür entropi hesaplamamız gerekir:

a) Bir özelliğin sıklık tablosunu kullanan entropi:

$$E(S) = \sum_{i=1}^{c} - p_i \log_2 p_i$$

Play Golf	
Yes	No
9	5

Entropy(PlayGolf) = Entropy (5,9)
= Entropy (0.36, 0.64)
= - (0.36 $\log_2$ 0.36) - (0.64 $\log_2$ 0.64)
= 0.94

5/14=0.36
9/14=0.64

b) İki özelliğin sıklık tablosunu kullanan entropi:

$$E(T, X) = \sum_{c \in X} P(c) E(c)$$

		Play Golf		
		Yes	No	
Outlook	Sunny	3	2	5
	Overcast	4	0	4
	Rainy	2	3	5
				14

E(PlayGolf, Outlook) = **P**(Sunny)***E**(3,2) + **P**(Overcast)***E**(4,0) + **P**(Rainy)***E**(2,3)
= (5/14)*0.971 + (4/14)*0.0 + (5/14)*0.971
= 0.693

Information Gain

Bilgi kazancı, bir veri kümesi bir özniteliğe bölündükten sonra entropideki azalmaya dayanır. Bir karar ağacı oluşturmak, en yüksek bilgi kazancını (yani en homojen dalları) döndüren özniteliği bulmakla ilgilidir.

Adım 1: Hedefin entropisini hesaplanır.

Entropy(PlayGolf) = Entropy (5,9)

= Entropy (0.36, 0.64)

= - (0.36 $\log_2$ 0.36) - (0.64 $\log_2$ 0.64)

= 0.94

Adım 2: Veri kümesi daha sonra farklı niteliklere bölünür. Her dal için entropi hesaplanır. Daha sonra, bölme için toplam entropi elde etmek için orantılı olarak eklenir. Ortaya çıkan entropi, bölünmeden önceki entropiden çıkarılır. Sonuç, Bilgi Kazanımı veya entropideki azalmadır.

		Play Golf	
		Yes	No
Outlook	Sunny	3	2
	Overcast	4	0
	Rainy	2	3
Gain = 0.247			

		Play Golf	
		Yes	No
Temp.	Hot	2	2
	Mild	4	2
	Cool	3	1
Gain = 0.029			

		Play Golf	
		Yes	No
Humidity	High	3	4
	Normal	6	1
Gain = 0.152			

		Play Golf	
		Yes	No
Windy	False	6	2
	True	3	3
Gain = 0.048			

$$Gain(T,X) = Entropy(T) - Entropy(T,X)$$

G(PlayGolf, Outlook) = **E**(PlayGolf) – **E**(PlayGolf, Outlook)

= 0.940 – 0.693 = 0.247

Adım 3: Karar düğümü olarak en büyük bilgi kazancına sahip öznitelik seçilir, veri seti dallarına bölünür ve aynı işlemi her dalda tekrarlanır.

★		Play Golf	
		Yes	No
Outlook	Sunny	3	2
	Overcast	4	0
	Rainy	2	3
Gain = 0.247			

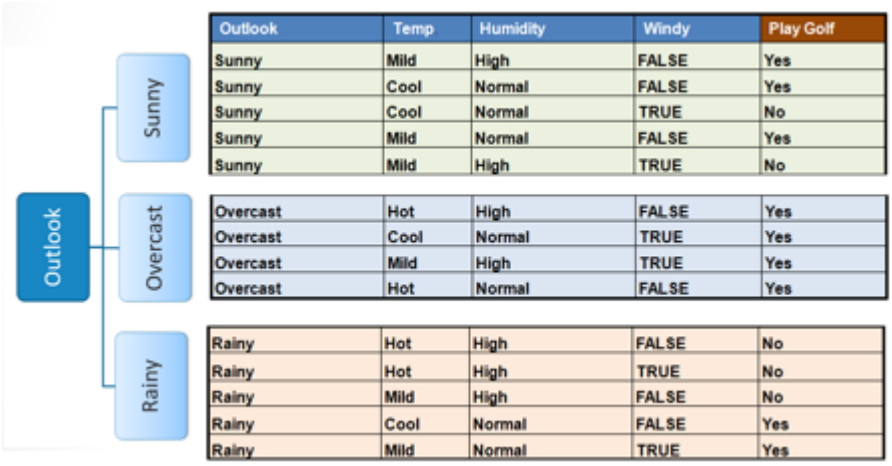

Outlook	Temp	Humidity	Windy	Play Golf
Sunny	Mild	High	FALSE	Yes
Sunny	Cool	Normal	FALSE	Yes
Sunny	Cool	Normal	TRUE	No
Sunny	Mild	Normal	FALSE	Yes
Sunny	Mild	High	TRUE	No
Overcast	Hot	High	FALSE	Yes
Overcast	Cool	Normal	TRUE	Yes
Overcast	Mild	High	TRUE	Yes
Overcast	Hot	Normal	FALSE	Yes
Rainy	Hot	High	FALSE	No
Rainy	Hot	High	TRUE	No
Rainy	Mild	High	FALSE	No
Rainy	Cool	Normal	FALSE	Yes
Rainy	Mild	Normal	TRUE	Yes

Step 4a: Entropisi 0 olan bir dal, bir yaprak düğümdür.

Temp	Humidity	Windy	Play Golf
Hot	High	FALSE	Yes
Cool	Normal	TRUE	Yes
Mild	High	TRUE	Yes
Hot	Normal	FALSE	Yes

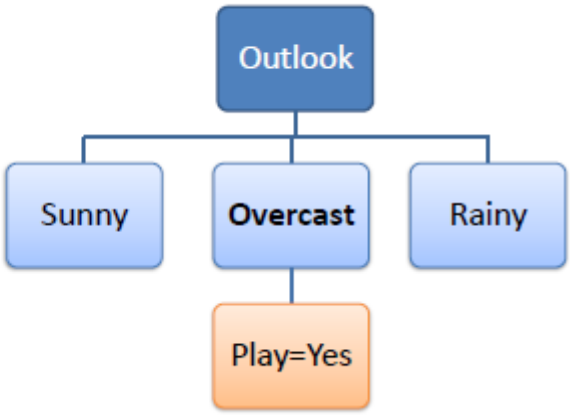

Adım 4b: Entropisi 0'dan büyük olan bir dalın daha fazla bölünmesi gerekir.

Temp	Humidity	Windy	Play Golf
Mild	High	FALSE	Yes
Cool	Normal	FALSE	Yes
Mild	Normal	FALSE	Yes
Cool	Normal	TRUE	No
Mild	High	TRUE	No

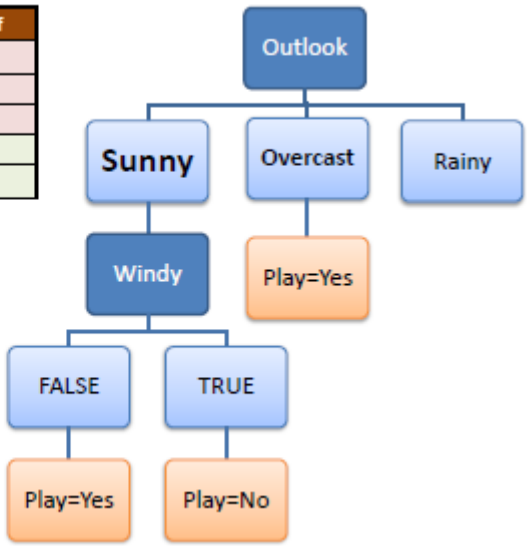

Adım 5: ID3 algoritması, tüm veriler sınıflandırılana kadar yaprak olmayan dallarda özyinelemeli olarak çalıştırılır.

Karar Ağacından Karar Kurallarına

Bir karar ağacı, kök düğümden yaprak düğümlere tek tek eşlenerek kolayca bir dizi kurala dönüştürülebilir.

R_1: IF (Outlook=Sunny) AND (Windy=FALSE) THEN Play=Yes

R_2: IF (Outlook=Sunny) AND (Windy=TRUE) THEN Play=No

R_3: IF (Outlook=Overcast) THEN Play=Yes

R_4: IF (Outlook=Rainy) AND (Humidity=High) THEN Play=No

R_5: IF (Outlook=Rain) AND (Humidity=Normal) THEN Play=Yes

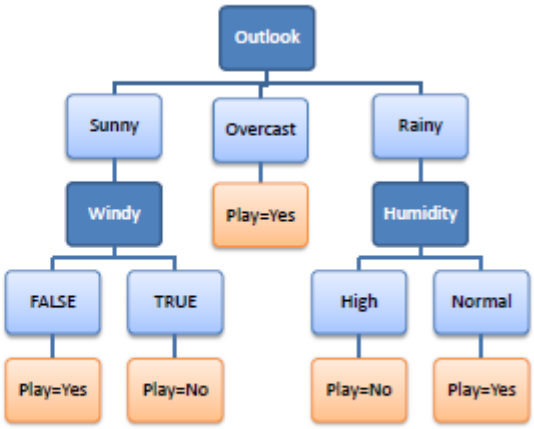

Uygulama:

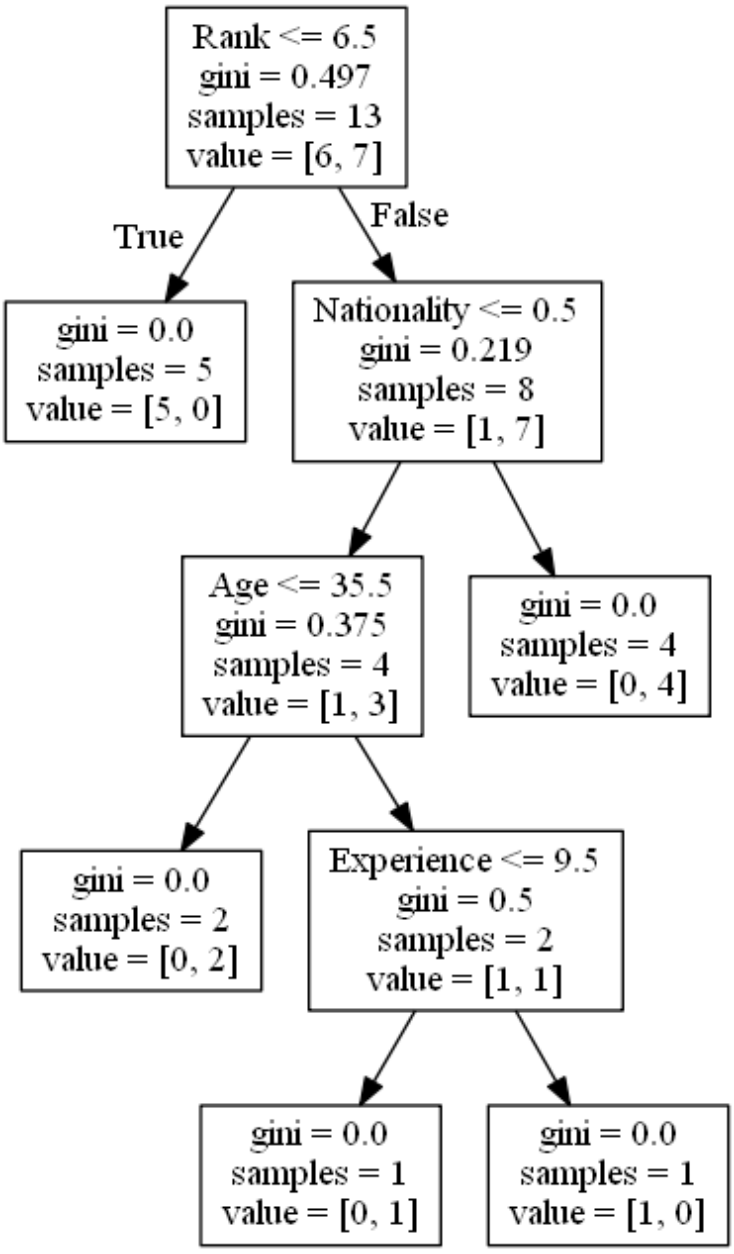

Karar Ağacı bir Akış Şemasıdır ve önceki deneyimlere dayalı kararlar vermenize yardımcı olabilir.

Örnekte, bir kişi bir komedi şovuna gidip gitmeyeceğine karar vermeye çalışacaktır. Neyse ki örnek kişimiz kasabada her komedi şovu olduğunda kayıt olmuş ve komedyen hakkında bazı bilgileri kaydetmiş, gidip gitmediğini de kaydetmiştir.

Age	Experience	Rank	Nationality	Go
36	10	9	UK	NO
42	12	4	USA	NO
23	4	6	N	NO
52	4	4	USA	NO
43	21	8	USA	YES
44	14	5	UK	NO
66	3	7	N	YES
35	14	9	UK	YES
52	13	7	N	YES
35	5	9	N	YES
24	3	5	USA	NO
18	3	7	UK	YES
45	9	9	UK	YES

Şimdi, bu veri setine dayanarak Python, herhangi bir yeni şovun katılmaya değer olup olmadığına karar vermek için kullanılabilecek bir karar ağacı oluşturabilir.

Nasıl çalışır?
İlk önce ihtiyacınız olan modülleri içe aktarılır ve veri seti pandalarla okunur.

Örnek: Veri setini okunur ve yazdırılır.

```
import pandas
from sklearn import tree
import pydotplus
from sklearn.tree import DecisionTreeClassifier
import matplotlib.pyplot as plt
import matplotlib.image as pltimg
df = pandas.read_csv("shows.csv")
print(df)
```

Bir karar ağacı oluşturmak için tüm verilerin sayısal olması gerekir.

Sayısal olmayan 'Milliyet' ve 'Git' sütunlarını sayısal değerlere dönüştürülmesi gerekiyor. Pandalar, değerlerin nasıl dönüştürüleceği hakkında bilgi içeren bir sözlük alan bir map() yöntemine sahiptir.

{'UK': 0, 'USA': 1, 'N': 2}
Değerleri dönüştürmek anlamına gelir: 'UK' to 0, 'USA' to 1, and 'N' to 2.
Örnek: Karekter değerlerinin sayısal değerlere değiştirilmesi.

```
d = {'UK': 0, 'USA': 1, 'N': 2}
df['Nationality'] = df['Nationality'].map(d)
d = {'YES': 1, 'NO': 0}
df['Go'] = df['Go'].map(d)
print(df)
```

Ardından, özellik sütunlarını hedef sütundan ayırmamız gerekir.
Özellik sütunları, tahmin etmeye çalıştığımız sütunlardır ve hedef sütun, tahmin etmeye çalıştığımız değerlerin bulunduğu sütundur.

Örnek: X, özellik sütunlarıdır, y hedef sütundur.

```
features = ['Age', 'Experience', 'Rank', 'Nationality']
X = df[features]
y = df['Go']
print(X)
print(y)
```

Artık gerçek karar ağacını oluşturabilir, onu ayrıntılarımıza sığdırabilir ve bilgisayara bir .png dosyası kaydedebiliriz.

Örnek: Bir Karar Ağacı oluşturulması, bir resim olarak kaydedilmesi ve resmin gösterilmesi.

```
dtree = DecisionTreeClassifier()
dtree = dtree.fit(X, y)
data = tree.export_graphviz(dtree, out_file=None, feature_names=features)
graph = pydotplus.graph_from_dot_data(data)
graph.write_png('mydecisiontree.png')
img=pltimg.imread('mydecisiontree.png')
imgplot = plt.imshow(img)
plt.show()
```

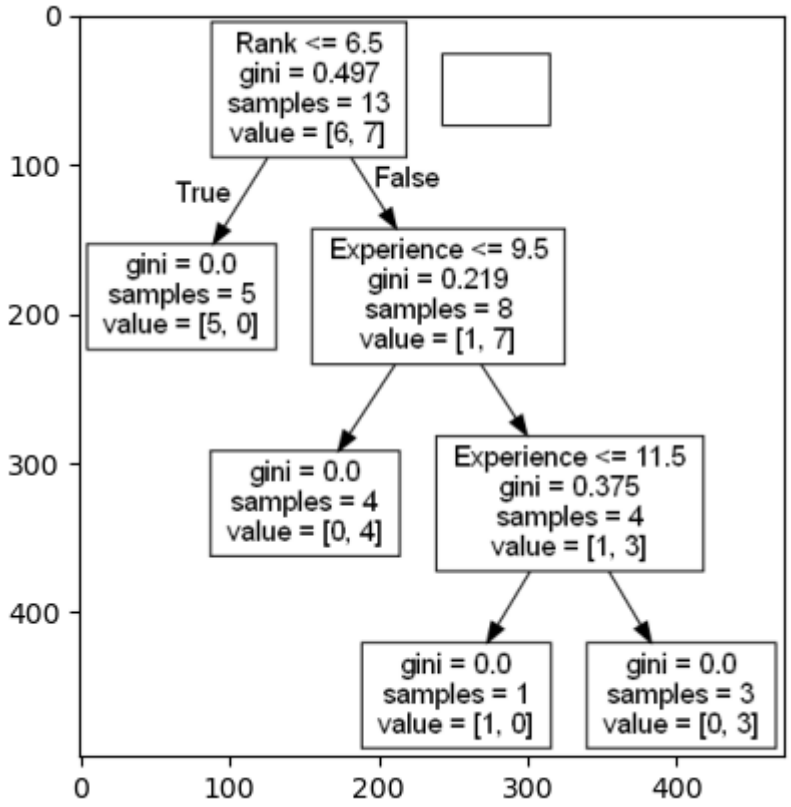

Sonuç Açıklaması:

Karar ağacı, bir komedyeni görmek isteyip istememe ihtimalinizi hesaplamak için önceki kararlarınızı kullanır. Karar ağacının farklı yönlerini okuyalım:

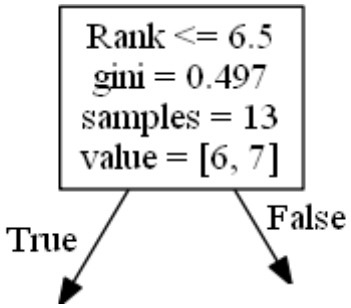

Rank:

Rank <= 6.5, rankı 6.5 veya daha düşük olan her komedyenin True okunu (solda) izleyeceği ve geri kalanının False oku (sağda) izleyeceği anlamına gelir.

gini = 0.497, bölmenin kalitesini ifade eder ve her zaman 0.0 ile 0.5 arasında bir sayıdır; burada 0.0, tüm örneklerin aynı sonucu aldığı anlamına gelir ve 0,5, bölmenin tam olarak ortada yapıldığı anlamına gelir.

Samples(numuneler) = 13, kararda bu noktada 13 komedyen kaldığı anlamına gelir, bu ilk adım olduğu için hepsi bu kadar.
Value(değer)= [6, 7] bu 13 komedyenden 6'sının "HAYIR" ve 7'sinin "DEVAM" alacağı anlamına gelir.

Gini:
Örnekleri bölmenin birçok yolu vardır, bu eğitimde GINI yöntemini kullanıyoruz.
Gini yöntemi şu formülü kullanır:
Gini = $1 - (x/n)^2 - (y/n)^2$

Burada x, olumlu yanıtların ("GO") sayısıdır, n örnek sayısıdır ve y, bize bu hesaplamayı veren olumsuz yanıtların ("HAYIR") sayısıdır.

$1 - (7 / 13)^2 - (6 / 13)^2 = 0.497$

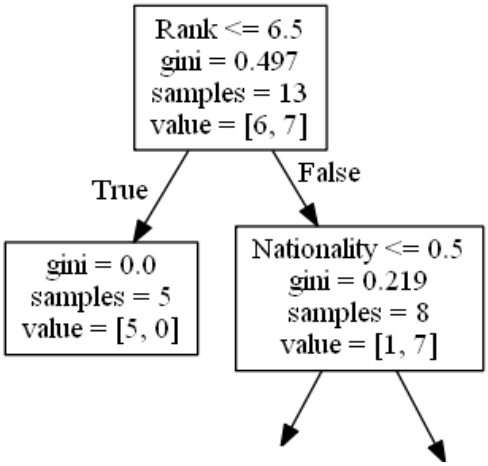

Bir sonraki adım iki kutu içerir, bir kutu 'Rank' 6.5 veya daha düşük olan komedyenler için ve bir kutu geri kalanıyla birlikte.

True - 5 durumunda Komedyen Burada Bitiyor.
gini = 0.0, tüm numunelerin aynı sonucu aldığı anlamına gelir.
numuneler = 5, bu branşta 5 komedyen kaldığı anlamına gelir (5 komedyen, Rütbesi 6.5 veya daha düşük).
değer = [5, 0], 5'in "HAYIR" ve 0'ın "DEVAM" alacağı anlamına gelir.

Yanlış - 8 durumunda Komedyen Devam Ediyor:

Uyruk:
Uyruk <= 0,5, uyruk değeri 0,5'ten az olan komedyenlerin soldaki oku (yani Birleşik Krallık'tan herkes,) izleyeceği ve geri kalanların sağdaki oku izleyeceği anlamına gelir.
gini = 0.219, numunelerin yaklaşık %22'sinin bir yöne gideceği anlamına gelir.

numuneler = 8, bu branşta 8 komedyen kaldığı anlamına gelir (8 komedyen, Rütbesi 6.5'ten yüksek).
değer = [1, 7], bu 8 komedyenden 1'inin "HAYIR" ve 7'sinin "DEVAM" alacağı anlamına gelir.

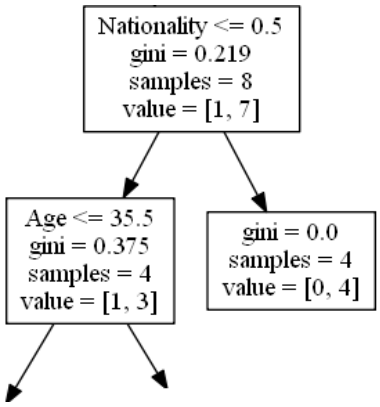

True - 4 durumunda Komedyen Devam.

Yaş:
Yaş <= 35.5, 35,5 veya daha küçük yaştaki komedyenlerin soldaki oku, geri kalanların da sağdaki oku izleyeceği anlamına gelir.
gini = 0.375, numunelerin yaklaşık %37,5'inin bir yöne gideceği anlamına gelir.
numuneler = 4, bu dalda 4 komedyen kaldığı anlamına gelir (İngiltere'den 4 komedyen).
değer = [1, 3], bu 4 komedyenden 1'inin "HAYIR" ve 3'ünün "DEVAM" alacağı anlamına gelir.

False - 4 Komedyen durumu Burada Bitiriyor.
gini = 0.0, tüm numunelerin aynı sonucu aldığı anlamına gelir.
numuneler = 4, bu branşta 4 komedyen kaldığı anlamına gelir (İngiltere'den olmayan 4 komedyen).
değer = [0, 4], bu 4 komedyenden 0'ın "HAYIR" ve 4'ünün "DEVAM" alacağı anlamına gelir.

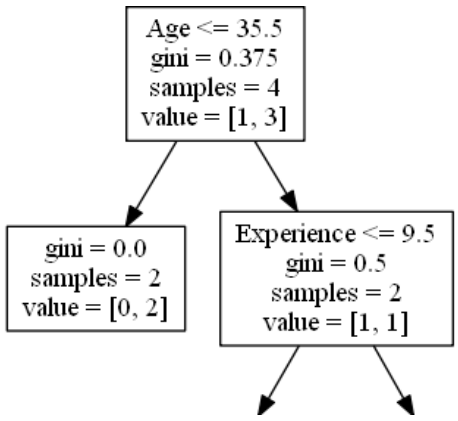

True - 2 durumunda Komedyen Burada Bitiyor.
gini = 0.0, tüm numunelerin aynı sonucu aldığı anlamına gelir.

numuneler = 2, bu branşta 2 komedyen kaldığı anlamına gelir (2 komedyen 35.5 yaşında veya daha genç).
değer = [0, 2], bu 2 komedyenden 0'ın "HAYIR" alacağı ve 2'nin "DEVAM" alacağı anlamına gelir.
Yanlış - 2 durumunda Komedyen Devam:
Deneyim:
Deneyim <= 9.5, 9,5 yıl veya daha az deneyime sahip komedyenlerin soldaki oku, geri kalanların ise sağdaki oku izleyeceği anlamına gelir.
gini = 0,5, numunelerin %50'sinin bir yöne gideceği anlamına gelir.
numuneler = 2, bu branşta 2 komedyen kaldığı anlamına gelir (2 35,5 yaşından büyük komedyen).
değer = [1, 1], bu 2 komedyenden 1'inin "HAYIR" ve 1'inin "DEVAM" alacağı anlamına gelir.

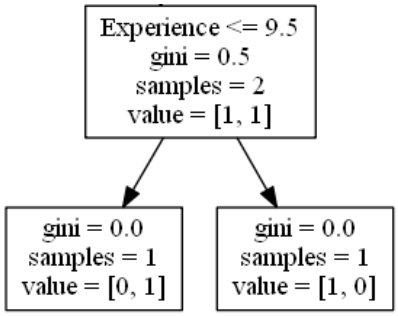

True - 1 durumunda Komedyen Burada Bitiyor.
gini = 0.0, tüm numunelerin aynı sonucu aldığı anlamına gelir.
numuneler = 1, bu branşta 1 komedyen kaldığı anlamına gelir (1 komedyen 9,5 yıl veya daha az deneyime sahip).
değer = [0, 1], 0'ın "HAYIR" alacağı ve 1'in "DEVAM" alacağı anlamına gelir.
Yanlış - 1 Komedyen Burada Bitiyor:
gini = 0.0, tüm numunelerin aynı sonucu aldığı anlamına gelir.
numuneler = 1, bu branşta 1 komedyen kaldığı anlamına gelir (1 komedyen 9,5 yıldan fazla deneyime sahip).
değer = [1, 0], 1'in "HAYIR" alacağı ve 0'ın "DEVAM" alacağı anlamına gelir.

Tahmin Değerleri:
Yeni değerleri tahmin etmek için Karar Ağacını kullanabiliriz.
Örnek: 40 yaşında, 10 yıllık deneyime sahip ve komedi sıralaması 7 olan bir Amerikalı komedyenin oynadığı bir gösteriye gitmeli miyim?
Örnek: Yeni değerleri tahmin etmek için tahmin() yöntemini kullanın.
print(dtree.predict([[40, 10, 7, 1]]))
Örnek: Komedi sıralaması 6 olsaydı cevap ne olurdu?
print(dtree.predict([[40, 10, 6, 1]]))

Farklı Sonuçlar
Karar Ağacı'nı aynı verilerle besleseniz bile yeterince çalıştırırsanız size farklı sonuçlar verdiğini göreceksiniz.
Bunun nedeni, Karar Ağacı'nın bize %100 kesin bir cevap vermemesidir. Bir sonucun olasılığına dayanır ve cevap değişecektir.

5.2. Önyükleme Toplama (Torbalama - Bagging)

Karar Ağaçları gibi yöntemler, yeni veriler üzerinde yanlış tahminlere yol açabilecek şekilde, eğitim setine fazla uymaya meyilli olabilir.

Bootstrap Aggregation (torbalama), sınıflandırma veya regresyon sorunları için fazla uydurmayı çözmeye çalışan bir birleştirme yöntemidir. Torbalama, makine öğrenimi algoritmalarının doğruluğunu ve performansını iyileştirmeyi amaçlar. Bunu, orijinal bir veri kümesinin rastgele alt kümelerini değiştirme ile alarak yapar ve her alt kümeye bir sınıflandırıcı (sınıflandırma için) veya geriletici (gerileme için) uyar. Her alt küme için tahminler daha sonra sınıflandırma için çoğunluk oyu veya regresyon için ortalama alma yoluyla toplanır, bu da tahmin doğruluğunu artırır.

Bir Temel Sınıflandırıcıyı Değerlendirmek:
Torbalamanın model performansını nasıl iyileştirebileceğini görmek için, temel sınıflandırıcının veri kümesinde nasıl performans gösterdiğini değerlendirerek başlamalıyız. Karar ağaçlarının ne olduğunu bilmiyorsanız, ilerlemeden önce karar ağaçları dersini gözden geçirin, çünkü torbalama kavramın bir devamıdır.
Sklearn'in şarap veri setinde bulunan farklı şarap sınıflarını tanımlamaya çalışacağız.
Gerekli modülleri içe aktararak başlayalım.

```
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
from sklearn.tree import DecisionTreeClassifier
```

Daha sonra verileri yüklememiz ve X (giriş özellikleri) ve y (hedef) içinde saklamamız gerekiyor. as_frame parametresi True olarak ayarlanır, böylece verileri yüklerken özellik adlarını kaybetmeyiz. (0.23'ten eski sklearn sürümü, desteklenmediği için as_frame argümanını atlamalıdır)

```
data = datasets.load_wine(as_frame = True)

X = data.data
y = data.target
```

Modelimizi görünmeyen veriler üzerinde doğru bir şekilde değerlendirmek için X ve y'yi tren ve test setlerine ayırmamız gerekiyor. Verileri bölme hakkında bilgi için, Eğitim/Test dersine bakın.
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 22)

Hazırlanan verilerimizle artık bir temel sınıflandırıcıyı somutlaştırabilir ve onu eğitim verilerine sığdırabiliriz.
dtree = DecisionTreeClassifier(random_state = 22)
dtree.fit(X_train,y_train)
DecisionTreeClassifier(random_state=22)

Artık görünmeyen test setinin şarap sınıfını tahmin edebilir ve model performansını değerlendirebiliriz.
y_pred = dtree.predict(X_test)

print("Train data accuracy:",accuracy_score(y_true = y_train, y_pred =
dtree.predict(X_train)))
print("Test data accuracy:",accuracy_score(y_true = y_test, y_pred = y_pred))

Sonuç:
Train data accuracy: 1.0
Test data accuracy: 0.8222222222222222

Kod Örneği:
Gerekli veriler içe aktarılır ve temel sınıflandırıcı performansı değerlendirilir.
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
from sklearn.tree import DecisionTreeClassifier

data = datasets.load_wine(as_frame = True)
X = data.data
y = data.target
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 22)

dtree = DecisionTreeClassifier(random_state = 22)
dtree.fit(X_train,y_train)
y_pred = dtree.predict(X_test)

print("Train data accuracy:",accuracy_score(y_true = y_train, y_pred =

dtree.predict(X_train)))
print("Test data accuracy:",accuracy_score(y_true = y_test, y_pred = y_pred))

Temel sınıflandırıcı, geçerli parametrelerle test veri kümesinde %91 doğruluk elde ederek veri kümesinde oldukça iyi performans gösterir (random_state parametre kümeniz yoksa farklı sonuçlar oluşabilir).
Artık test veri kümesi için temel bir doğruluğa sahip olduğumuza göre, Torbalama Sınıflandırıcısının tek bir Karar Ağacı Sınıflandırıcısını nasıl gerçekleştirdiğini görebiliriz.

Torbalama Sınıflandırıcısı Oluşturma
Torbalama için n_estimators parametresini ayarlamamız gerekiyor, bu, modelimizin bir araya toplayacağı temel sınıflandırıcıların sayısıdır.
Bu örnek veri kümesi için tahmin edicilerin sayısı nispeten düşüktür, genellikle çok daha büyük aralıkların keşfedildiği durumdur. Hiperparametre ayarı genellikle bir grid araması ile yapılır, ancak şimdilik tahminci sayısı için seçilmiş bir dizi değer kullanacağız.
Gerekli modeli import ederek başlıyoruz.
from sklearn.ensemble import BaggingClassifier

Şimdi, her toplulukta kullanmak istediğimiz tahminci sayısını temsil eden bir değerler aralığı oluşturalım.
estimator_range = [2,4,6,8,10,12,14,16]

Torbalama Sınıflandırıcısının farklı n_estimators değerleriyle nasıl performans gösterdiğini görmek için, değer aralığı üzerinde yineleme yapmanın ve her topluluktan elde edilen sonuçları saklamanın bir yoluna ihtiyacımız var. Bunu yapmak için, daha sonraki görselleştirmeler için modelleri ve puanları ayrı listelerde saklayan bir for döngüsü oluşturacağız.
Not: BaggingClassifier'daki temel sınıflandırıcı için varsayılan parametre DicisionTreeClassifier'dır, bu nedenle torbalama modelini başlatırken bunu ayarlamamız gerekmez.

```
models = []
scores = []

for n_estimators in estimator_range:
    # Create bagging classifier
    clf = BaggingClassifier(n_estimators = n_estimators, random_state = 22)
    # Fit the model
    clf.fit(X_train, y_train)
    # Append the model and score to their respective list
```

models.append(clf)
scores.append(accuracy_score(y_true = y_test, y_pred = clf.predict(X_test)))

Depolanan modeller ve puanlarla artık model performansındaki gelişmeyi görselleştirebiliriz.
import matplotlib.pyplot as plt

 # Generate the plot of scores against number of estimators
plt.figure(figsize=(9,6))
plt.plot(estimator_range, scores)

 # Adjust labels and font (to make visable)
plt.xlabel("n_estimators", fontsize = 18)
plt.ylabel("score", fontsize = 18)
plt.tick_params(labelsize = 16)

 # Visualize plot

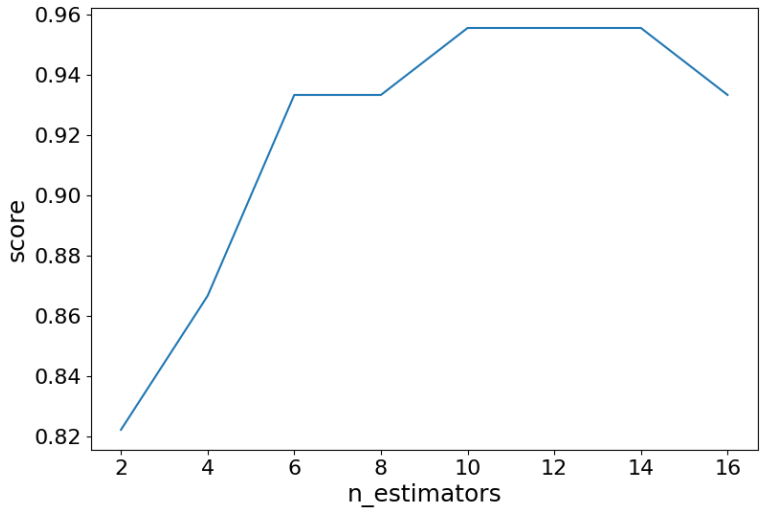

Kod örneği:
Gerekli verileri içe aktarın ve BaggingClassifier performansını değerlendirin.

import matplotlib.pyplot as plt
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
from sklearn.ensemble import BaggingClassifier

```
data = datasets.load_wine(as_frame = True)

X = data.data
y = data.target

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 22)

estimator_range = [2,4,6,8,10,12,14,16]

models = []
scores = []

for n_estimators in estimator_range:

    # Create bagging classifier
    clf = BaggingClassifier(n_estimators = n_estimators, random_state = 22)

    # Fit the model
    clf.fit(X_train, y_train)

    # Append the model and score to their respective list
    models.append(clf)
    scores.append(accuracy_score(y_true = y_test, y_pred = clf.predict(X_test)))

# Generate the plot of scores against number of estimators
plt.figure(figsize=(9,6))
plt.plot(estimator_range, scores)

# Adjust labels and font (to make visable)
plt.xlabel("n_estimators", fontsize = 18)
plt.ylabel("score", fontsize = 18)
plt.tick_params(labelsize = 16)

# Visualize plot
plt.show()
```

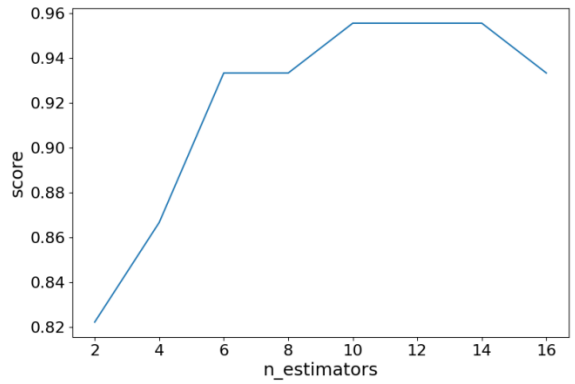

Sonuçların Açıklanması:
Tahminci sayısı için farklı değerleri yineleyerek model performansında %82,2'den %95,5'e bir artış görebiliriz. 14 tahminciden sonra doğruluk düşmeye başlar, yine farklı bir rastgele_durum (random_state) ayarlarsanız, gördüğünüz değerler değişecektir. Bu nedenle, istikrarlı sonuçlar elde etmek için çapraz doğrulama kullanmak en iyi uygulamadır. Bu durumda, şarabın türünü belirlemeye gelince doğrulukta %13,3'lük bir artış görüyoruz.

Başka Bir Değerlendirme Şekli:
Önyükleme, sınıflandırıcılar oluşturmak için rastgele gözlem alt kümelerini seçtiğinden, seçim sürecinde dışarıda bırakılan gözlemler vardır. Bu "torbadan çıkmış" gözlemler, daha sonra, bir test setine benzer şekilde modeli değerlendirmek için kullanılabilir. Torba dışı tahminin ikili sınıflandırma problemlerindeki hatayı olduğundan fazla tahmin edebileceğini ve yalnızca diğer ölçümlere tamamlayıcı olarak kullanılması gerektiğini unutmayın.
Son alıştırmada 12 tahmincinin en yüksek doğruluğu verdiğini gördük, bu yüzden modelimizi oluşturmak için bunu kullanacağız. Bu sefer, çanta dışı puanı olan modeli değerlendirmek için oob_score parametresini true olarak ayarlıyoruz.

Kod örneği:
Torba dışı metriğe sahip bir model oluşturulur.

```
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.ensemble import BaggingClassifier

data = datasets.load_wine(as_frame = True)

X = data.data
y = data.target

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 22)

oob_model = BaggingClassifier(n_estimators = 12, oob_score = True,random_state = 22)
```

oob_model.fit(X_train, y_train)

print(oob_model.oob_score_)

OOB'de kullanılan örnekler ve test seti farklı olduğu ve veri seti nispeten küçük olduğu için doğrulukta bir fark vardır. Tamamen aynı olmaları nadirdir, yine OOB, hatayı tahmin etmek için hızlı araçlar kullanılmalıdır, ancak tek değerlendirme metriği değildir.

Out-of-bag error (OOB):
Torbadan çıkma tahmini olarak da adlandırılan torba dışı hata, rastgele ormanların, artırılmış karar ağaçlarının ve önyükleme toplamayı kullanan diğer makine öğrenimi modellerinin tahmin hatasını ölçme yöntemidir. Torbalama, modelin öğreneceği eğitim örnekleri oluşturmak için alt örneklemeyi değiştirme ile kullanır.

Torbalama Sınıflandırıcısından Karar Ağaçları Oluşturma:
Karar Ağacı dersinde görüldüğü gibi modelin oluşturduğu karar ağacının grafiğini çıkarmak mümkündür. Toplu sınıflandırıcıya giren bireysel karar ağaçlarını da görmek mümkündür. Bu, torbalama modelinin tahminlerine nasıl ulaştığı konusunda daha sezgisel bir anlayış kazanmamıza yardımcı olur.

Not: Bu, yalnızca ağaçların nispeten sığ ve dar olduğu ve görselleştirilmesini kolaylaştıran daha küçük veri kümelerinde işlevseldir.

Plot_tree işlevini sklearn.tree'den içe aktarmamız gerekecek. Farklı ağaçlar, görselleştirmek istediğiniz tahmin ediciyi değiştirerek grafik haline getirilebilir.

Kod örneği:
Torbalama Sınıflandırıcısından Karar Ağaçları Oluşturulur.
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.ensemble import BaggingClassifier
from sklearn.tree import plot_tree

X = data.data
y = data.target

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 22)

clf = BaggingClassifier(n_estimators = 12, oob_score = True,random_state = 22)

clf.fit(X_train, y_train)

plt.figure(figsize=(30, 20))

plot_tree(clf.estimators_[0], feature_names = X.columns)

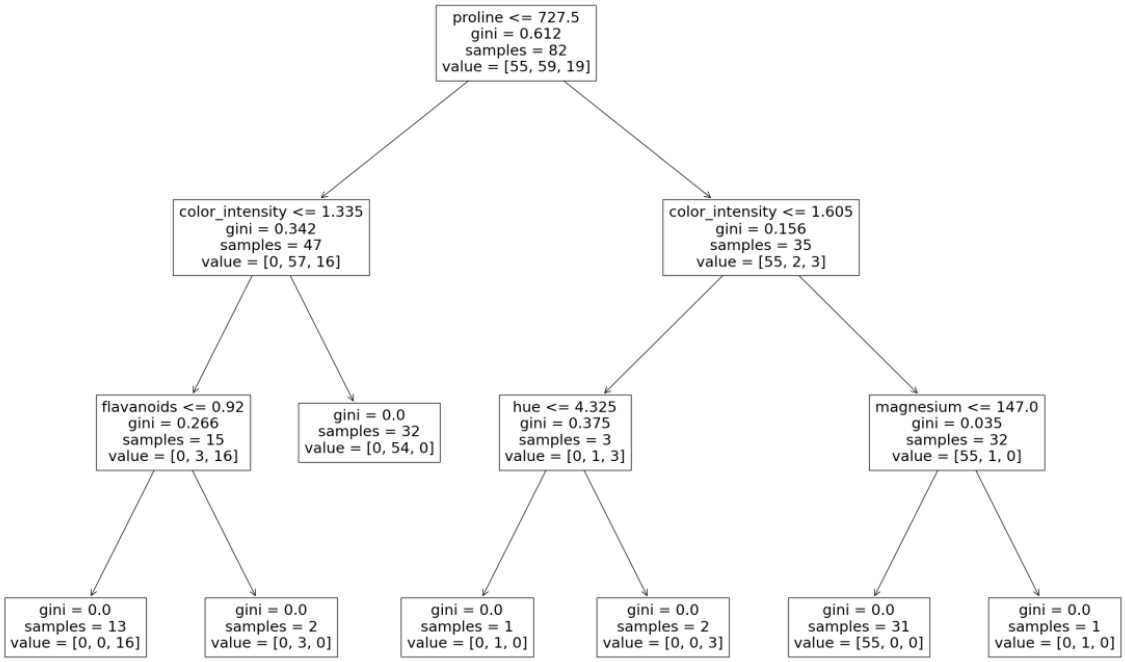

Burada sadece nihai tahmine oy vermek için kullanılan ilk karar ağacını görebiliriz. Yine, sınıflandırıcının indeksini değiştirerek toplanan ağaçların her birini görebilirsiniz.

5.3. K-NN En Yakın Komşu

1967 yılında T. M. Cover ve P. E. Hart tarafından önerilen, örnek veri noktasının bulunduğu sınıfın ve en yakın komşunun, K değerine göre belirlendiği bir sınıflandırma yöntemidir. Denetimli öğrenmede sınıflandırma ve regresyon için kullanılan algoritmalardan biridir. En basit makine öğrenmesi algoritması olarak kabul edilir.

KNN amacı, yeni bir örnek geldiğinde var olan öğrenme verisi üzerinde sınıflandırma yaparak onun en yakın K komşusuna bakarak örneğin sınıfına karar verir.

K-NN algoritması sınıflandırma algoritmasıdır. Sınıflandırmak, belirli bir veri kümesini farklı sınıflara ayırma işlemidir. Sınıflandırma hem yapılandırılmış hem de yapılandırılmamış veri türleri üzerinde uygulanabilir.

KNN algoritması sınıflandırılmak istenen bir veriyi daha önceki verilerle olan yakınlık ilişkisine göre sınıflandıran bir algoritmadır. Algoritma adının içinde bulunduğu "K" algoritmaya dahil edilecek veri kümesindeki veri sayısını ifade etmektedir. Yani algoritmada "k" adet komşu aranır. Bir tahmin yapmak istediğimizde, tüm veri setinde en yakın komşuları arar. Algoritmanın çalışmasında bir K değeri belirlenir. Bu K değerinin anlamı bakılacak eleman sayısıdır. Bir değer geldiğinde en yakın K kadar eleman alınarak gelen değer arasındaki uzaklık hesaplanır. İlgili uzaklılardan en yakın k komşu ele alınır. Öznitelik değerlerine göre k komşu veya komşuların sınıfına atanır. Seçilen sınıf, tahmin edilmesi beklenen gözlem değerinin sınıfı olarak kabul edilir. Yani yeni veri etiketlenmiş (label) olur.

K-NN non-parametric (parametrik olmayan), lazy (tembel) bir öğrenme algoritmasıdır. lazy kavramını anlamaya çalışırsak "eager learning" aksine "lazy learning"'in bir eğitim aşaması yoktur. Eğitim verilerini öğrenmez, bunun yerine eğitim veri kümesini "ezberler". Uzaklık hesaplama işleminde genelde Öklid fonksiyonu kullanılır.

Öklid fonksiyonuna alternatif olarak Manhattan, Minkowski ve Hamming fonksiyonlarıda kullanılabilir. Uzaklık hesaplandıktan sonra sıralanır ve gelen değer uygun olan sınıfa atanır.

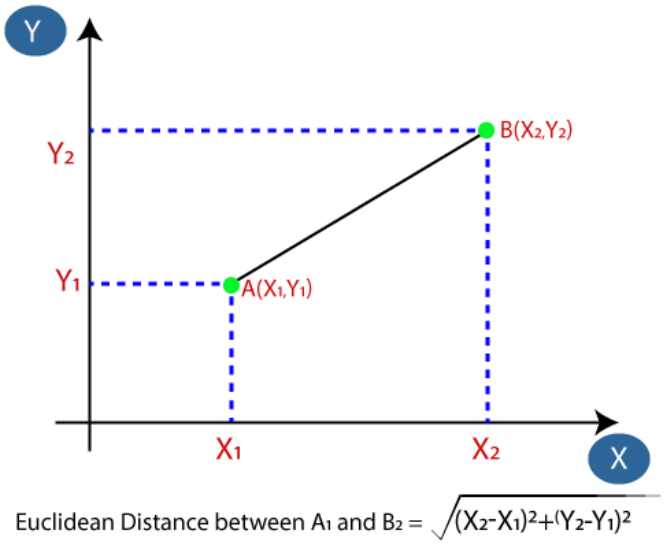

Bir tahmin yapmak için KNN algoritması, lojistik veya doğrusal regresyonda olduğu gibi bir eğitim veri kümesinden öngörücü bir model hesaplamaz. Aslında, KNN'nin tahmine dayalı bir model oluşturmasına gerek yoktur. Bu nedenle, KNN için gerçek bir öğrenme aşaması yoktur. Bu yüzden genellikle tembel bir öğrenme yöntemi olarak kategorize edilir. Bir tahmin yapabilmek için, KNN herhangi bir eğitim aşaması olmadan bir sonuç üretmek için veri setini kullanır.

KNN, bir tahmin yapmak için tüm veri kümesini depolar. KNN herhangi bir tahmine dayalı modeli hesaplamaz ve tembel öğrenme algoritmaları ailesinin bir parçasıdır. KNN, bir girdi gözlemi ile veri kümesindeki farklı gözlemler arasındaki benzerliği hesaplayarak tam zamanında (anında) tahminler yapar.

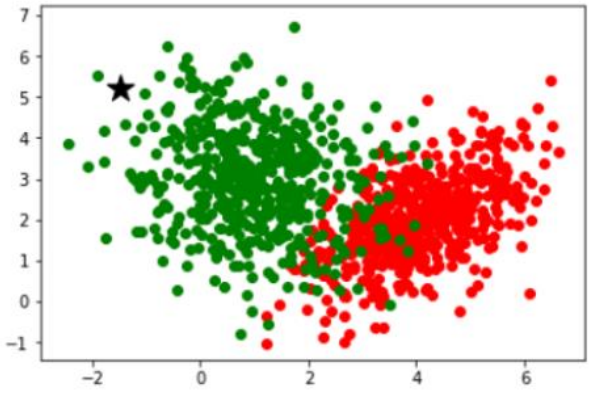

Yukarıdaki şekilde, kırmızı veya yeşil olarak sınıflandırılan veri noktalarında siyah bir veri noktası kırmızı ya da yeşil olabilecek iki sınıfı göstermektedir. Siyah noktanın ne olduğu KNN algoritması tarafından nasıl hesaplanır?

KNN algoritmaları, sınıflandırılacak veri noktasına en yakın komşu olan bir k sayısına karar verir. K değeri 5 ise, o veri noktasına en yakın 5 Komşuyu arayacaktır. Bu örnekte, k = 4. KNN en yakın 4 komşuyu bulur. Bu veri noktasının bu komşulara yakın olması nedeniyle sadece bu sınıfa ait olacağı görülmektedir.

K-en yakın komşu sınıflandırıcı algoritmalarının basit versiyonu, en yakın komşu sınıfı bularak hedef etiketini tahmin etmektir. Sınıflandırılacak noktaya en yakın sınıf, Öklid mesafesi kullanılarak hesaplanır.

Mesafe, benzerliği ölçmek için kullanılır. İki örnek arasındaki mesafeyi ölçmenin birçok yolu vardır.

- Manhattan Distance, |X1-X2| + |Y1-Y2|
- Euclidean Distance, √((x1−x2)²)+√(y1−y2)²

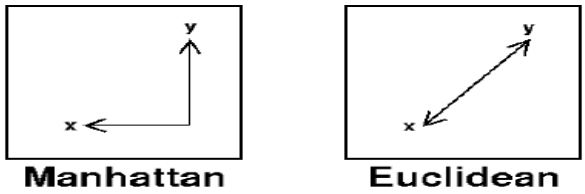

Mesafe Ölçüm yöntemleri:

Minkowsky:

$$D(\boldsymbol{x},\boldsymbol{y}) = \left(\sum_{i=1}^{m} |x_i - y_i|^r\right)^{1/r}$$

Euclidean:

$$D(\boldsymbol{x},\boldsymbol{y}) = \sqrt{\sum_{i=1}^{m} (x_i - y_i)^2}$$

Manhattan / city-block:

$$D(\boldsymbol{x},\boldsymbol{y}) = \sum_{i=1}^{m} |x_i - y_i|$$

Camberra:

$$D(\boldsymbol{x},\boldsymbol{y}) = \sum_{i=1}^{m} \frac{|x_i - y_i|}{|x_i + y_i|}$$

Chebychev:

$$D(\boldsymbol{x},\boldsymbol{y}) = \max_{i=1}^{m} |x_i - y_i|$$

Quadratic:

$$D(\boldsymbol{x},\boldsymbol{y}) = (\boldsymbol{x}-\boldsymbol{y})^T Q(\boldsymbol{x}-\boldsymbol{y}) = \sum_{j=1}^{m}\left(\sum_{i=1}^{m}(x_i - y_i)q_{ji}\right)(x_j - y_j)$$

Q is a problem-specific positive definite $m \times m$ weight matrix

Mahalanobis:

$$D(\boldsymbol{x},\boldsymbol{y}) = [\det V]^{1/m}(\boldsymbol{x}-\boldsymbol{y})^{\mathrm{T}} V^{-1}(\boldsymbol{x}-\boldsymbol{y})$$

V is the covariance matrix of $A_1..A_m$, and A_j is the vector of values for attribute j occuring in the training set instances $1..n$.

Correlation:

$$D(\boldsymbol{x},\boldsymbol{y}) = \frac{\sum_{i=1}^{m}(x_i - \overline{x_i})(y_i - \overline{y_i})}{\sqrt{\sum_{i=1}^{m}(x_i - \overline{x_i})^2 \sum_{i=1}^{m}(y_i - \overline{y_i})^2}}$$

$\overline{x_i} = \overline{y_i}$ and is the average value for attribute i occuring in the training set.

Chi-square:

$$D(\boldsymbol{x},\boldsymbol{y}) = \sum_{i=1}^{m} \frac{1}{sum_i}\left(\frac{x_i}{size_{\boldsymbol{x}}} - \frac{y_i}{size_{\boldsymbol{y}}}\right)^2$$

sum_i is the sum of all values for attribute i occuring in the training set, and $size_{\boldsymbol{x}}$ is the sum of all values in the vector $\boldsymbol{x}$.

Kendall's Rank Correlation:

$$D(\boldsymbol{x},\boldsymbol{y}) = 1 - \frac{2}{n(n-1)}\sum_{i=1}^{m}\sum_{j=1}^{i-1}\mathrm{sign}(x_i - x_j)\mathrm{sign}(y_i - y_j)$$

sign(x)=-1, 0 or 1 if $x < 0$, $x = 0$, or $x > 0$, respectively.

Figure 1. Equations of selected distance functions. ($\boldsymbol{x}$ and $\boldsymbol{y}$ are vectors of m attribute values).

Mesafe ölçüsünün de yalnızca sürekli değişkenler için geçerli olduğu unutulmamalıdır. Kategorik değişkenler durumunda Hamming mesafesi kullanılmalıdır. Veri setinde sayısal ve kategorik değişkenlerin bir karışımı olduğunda, 0 ile 1 arasındaki sayısal değişkenlerin standardizasyonu konusunu da gündeme getirir.

Hamming Distance

$$D_H = \sum_{i=1}^{k} |x_i - y_i|$$

$$x = y \Rightarrow D = 0$$

$$x \neq y \Rightarrow D = 1$$

X	Y	Distance
Male	Male	0
Male	Female	1

K'nin önemi nedir?

K değeri büyüdükçe tahmine duyulan güveni artırır. Öte yandan K çok büyük bir değere sahipse, kararlar çarpık olabilir.

K nasıl seçilir?

Algoritma, yeni bir veri noktasının diğer tüm eğitim veri noktalarına olan mesafesini hesaplar. Mesafe herhangi bir türde olabilir, örneğin Öklid, Manhattan, vb. Algoritma daha sonra k'ye en yakın veri noktalarını seçer, burada k herhangi bir tam sayı olabilir. Sayısal değerlerin hangi özelliği temsil ettiğine bakılmaksızın, seçimini diğer veri noktalarına yakınlığına göre yapar. Son olarak, veri noktasını benzer veri noktalarının bulunduğu sınıfa atar.

Seçilen veri kümesine uyan K değerini seçmek için, KNN algoritması farklı K değerleri ile defalarca çalıştırılr. Sonra, algoritma, yeni değerler için hassas tahminler yapma yeteneğini korurken karşılaşılan hata sayısını azaltan K'yi seçilir.

- K'ye karar vermek, K-en yakın Komşular'ın en kritik kısmıdır.
- K değeri küçükse, gürültü sonuca daha fazla bağımlı olacaktır. Bu gibi durumlarda modelin aşırı uyumu çok fazladır.
- K'nin değeri ne kadar büyükse, KNN'nin arkasındaki prensibi yok edecektir.
- Çapraz doğrulamayı kullanarak K'nin optimum değeri bulunabilir.

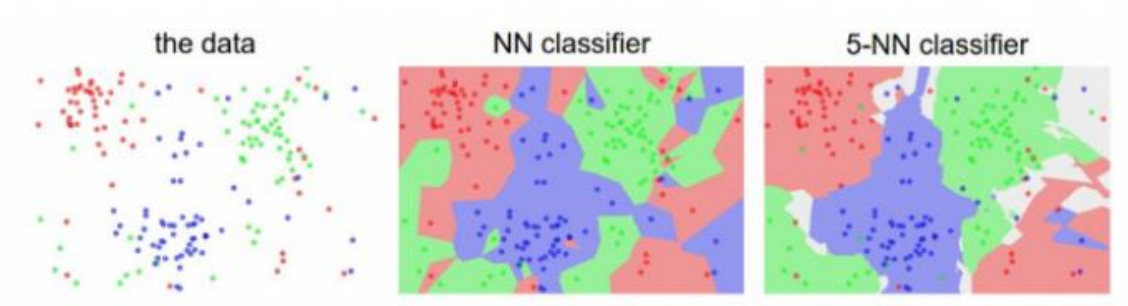

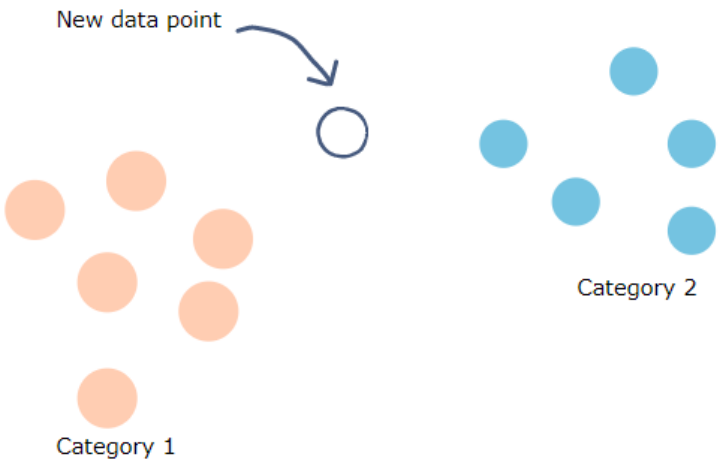

KNN algoritması sözde kod uygulaması

- İstenilen verileri yüklenir.
- k parametresi belirlenir. Bu parametre verilen bir noktaya en yakın komşuların sayısıdır. Örneğin: k=2 olsun. Bu durumda en yakın 2 komşuya göre sınıflandırma yapılacaktır.
- Örnek veri setine katılacak olan yeni verinin, mevcut verilere göre uzaklığı tek tek hesaplanır. İlgili uzaklık fonksiyonları yardımıyla.
- İlgili uzaklılardan en yakın k komşu ele alınır. Öznitelik değerlerine göre k komşu veya komşuların sınıfına atanır.
- Seçilen sınıf, tahmin edilmesi beklenen gözlem değerinin sınıfı olarak kabul edilir. Yani yeni veri etiketlenmiş (label) olur.

KNN, anlaşılması oldukça basit bir algoritmadır. Bunun başlıca nedeni, tahmin yapabilmek için bir modele ihtiyaç duymamasıdır. Bunun tersi, tahminini yapabilmek için tüm gözlemlerini hafızasında tutması gerektiğidir. Bu nedenle, girdi veri kümesinin boyutuna dikkat etmeniz gerekir. Ayrıca, mesafenin hesaplanması için yöntemin seçimi ve komşuların K sayısı hemen belli olmayabilir. Kullanım durumunuz için tatmin edici bir sonuç elde etmek için birkaç kombinasyon denemeniz ve algoritmayı ayarlamanız gerekebilir.

Örnek:

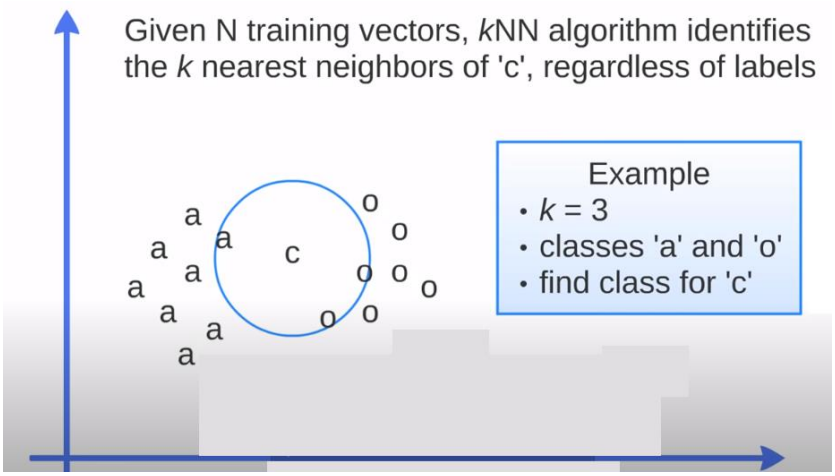

	Girdi Öznitelikleri		Çıktı Özniteliği
Öğrencinin Adı	Sayfa Sayısı	Soru Sayısı	Başarı Durumu
Selin	2100	1500	BAŞARILI
Mert	2280	1600	BAŞARILI
Caner	800	400	BAŞARISIZ
Şenay	2400	1750	BAŞARILI
Efe	250	350	BAŞARISIZ
Burak	180	220	BAŞARISIZ
Esra	1800	1200	?

Öklid uzaklığı kullanılarak altı adet öğrencinin Esra adlı öğrenciye olan uzaklıkları:

Öğrencinin Adı	Sayfa Sayısı	Soru Sayısı	Başarı Durumu	Uzaklık Hesaplaması	Sonuç
Selin	2100	1500	BAŞARILI	$\sqrt{(2100-1800)^2+(1500-1200)^2}$	424.2
Mert	2280	1600	BAŞARILI	$\sqrt{(2280-1800)^2+(1600-1200)^2}$	624.8
Caner	800	400	BAŞARISIZ	$\sqrt{(800-1800)^2+(400-1200)^2}$	1280
Şenay	2400	1750	BAŞARILI	$\sqrt{(2400-1800)^2+(1750-1200)^2}$	813.9
Efe	250	350	BAŞARISIZ	$\sqrt{(250-1800)^2+(350-1200)^2}$	1767
Burak	180	220	BAŞARISIZ	$\sqrt{(180-1800)^2+(220-1200)^2}$	1893
Esra	1800	1200	?		

Örneğin K=3 seçersek ilk 3 öğrencinin başarı durumuna bakacağız.

Öğrencinin Adı	Başarı Durumu	Sonuç	Sıra No
Selin	BAŞARILI	424.2	1
Mert	BAŞARILI	624.8	2
Şenay	BAŞARILI	813.9	3
Caner	BAŞARISIZ	1280	4
Efe	BAŞARISIZ	1767	5
Burak	BAŞARISIZ	1893	6
Esra	?		

Sonuç BAŞARILI

Örneğin K=6 seçersek ilk 6 öğrencinin başarı durumuna bakacağız.

Öğrencinin Adı	Başarı Durumu	Sonuç	Sıra No
Selin	BAŞARILI	424.2	1
Mert	BAŞARILI	624.8	2
Şenay	BAŞARILI	813.9	3
Caner	BAŞARISIZ	1280	4
Efe	BAŞARISIZ	1767	5
Burak	BAŞARISIZ	1893	6
Esra	?		

Sonuç ?

Bu yüzden **K** parametresinin **çift** olarak seçilmesi tercih edilmemektedir.

Örnek:

KNN, eğitim seti yardımıyla veri noktasını belirli bir kategoriye sınıflandırmaya çalıştığımız parametrik olmayan denetimli bir öğrenme tekniğidir. Basit bir deyişle, tüm eğitim durumlarının bilgilerini yakalar ve yeni durumları benzerliğe göre sınıflandırır.

Yeni bir örnek (x) için, en benzer K durum (komşular) için tüm eğitim seti aranarak ve bu K durumlar için çıktı değişkeni özetlenerek tahminler yapılır. Sınıflandırmada bu, mod (veya en yaygın) sınıf değeridir.

KNN algoritması nasıl çalışır?

Diyelim ki bazı müşterilerin boy, kilo ve tişört bedenleri var ve yeni bir müşterinin Tişört bedenini sadece sahip olduğumuz boy ve kilo bilgisine göre tahmin etmemiz gerekiyor. Boy, kilo ve tişört beden bilgilerini içeren veriler aşağıda gösterilmiştir.

Height (in cms)	Weight (in kgs)	T Shirt Size
158	58	M
158	59	M
158	63	M
160	59	M
160	60	M
163	60	M
163	61	M
160	64	L
163	64	L
165	61	L
165	62	L
165	65	L
168	62	L
168	63	L
168	66	L
170	63	L
170	64	L
170	68	L

Adım 1: Uzaklık fonksiyonuna göre Benzerliği hesaplayın

Pek çok uzaklık fonksiyonu vardır ama en yaygın olarak kullanılan ölçü Ökliddir. Esas olarak veriler sürekli olduğunda kullanılır. Manhattan mesafesi de sürekli değişkenler için çok yaygındır.

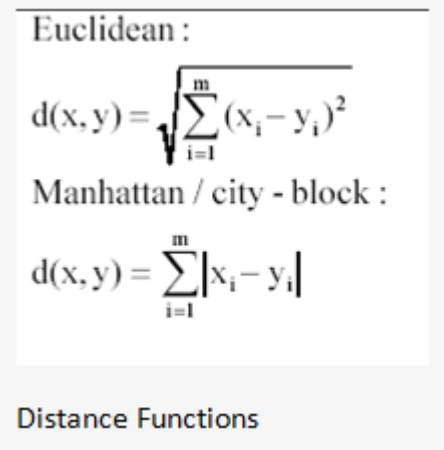

Mesafe ölçümü kullanma fikri, yeni örnek ve eğitim durumları arasındaki mesafeyi (benzerliği) bulmak ve ardından boy ve ağırlık açısından yeni müşteriye en yakın k-müşterileri bulmaktır.

'Monica' adlı yeni müşteri 161cm boyunda ve 61kg ağırlığındadır. İlk gözlem ile yeni gözlem (monica) arasındaki Öklid uzaklığı aşağıdaki gibidir:

=SQRT((161-158)^2+(61-58)^2)

Benzer şekilde, yeni vaka ile tüm eğitim vakalarının mesafesini hesaplayacağız ve mesafe açısından sıralamayı hesaplayacağız. En küçük mesafe değeri 1 olarak sıralanır ve en yakın komşu olarak kabul edilir.

Step 2 : Find K-Nearest Neighbors

Let k be 5. Then the algorithm searches for the 5 customers closest to Monica, i.e. most similar to Monica in terms of attributes, and see what categories those 5 customers were in. If 4 of them had ‘Medium T shirt sizes’ and 1 had ‘Large T shirt size’ then your best guess for Monica is ‘Medium T shirt. See the calculation shown in the snapshot below –

2. Adım : K-En Yakın Komşuları Bulunması

K=5 olsun. Ardından algoritma, özellikler açısından Monica'ya en yakın, yani Monica'ya en çok benzeyen 5 müşteriyi arar ve bu 5 müşterinin hangi kategorilerde olduğunu görür. 4 tanesi 'Orta T shirt bedenleri' ve 1 tanesi ise 'Büyük T gömlek bedeni' vardı, o zaman Monica için en iyi tahmininiz 'Orta T gömlek. Aşağıdaki anlık görüntüde gösterilen hesaplamaya bakın

=SQRT((A21-A6)^2+(B21-B6)^2)

	A	B	C	D	E
1	Height (in cms)	Weight (in kgs)	T Shirt Size	Distance	
2	158	58	M	4.2	
3	158	59	M	3.6	
4	158	63	M	3.6	
5	160	59	**M**	2.2	**3**
6	160	60	**M**	1.4	**1**
7	163	60	**M**	2.2	**3**
8	163	61	**M**	2.0	**2**
9	160	64	**L**	3.2	**5**
10	163	64	L	3.6	
11	165	61	L	4.0	
12	165	62	L	4.1	
13	165	65	L	5.7	
14	168	62	L	7.1	
15	168	63	L	7.3	
16	168	66	L	8.6	
17	170	63	L	9.2	
18	170	64	L	9.5	
19	170	68	L	11.4	
20					
21	**161**	**61**			

Aşağıdaki grafikte ikili bağımlı değişken (T-shirt bedeni) mavi ve turuncu renkte görüntülenmektedir. 'Orta boy tişört' mavi renkte ve 'Büyük boy tişört' turuncu renktedir. Yeni müşteri bilgileri sarı daire içinde sergilenir. Dört mavi vurgulanmış veri noktası ve bir turuncu vurgulanmış veri noktası sarı daireye yakındır. bu nedenle yeni vaka için tahmin, Orta T-shirt boyutu olan mavi vurgulu veri noktasıdır.

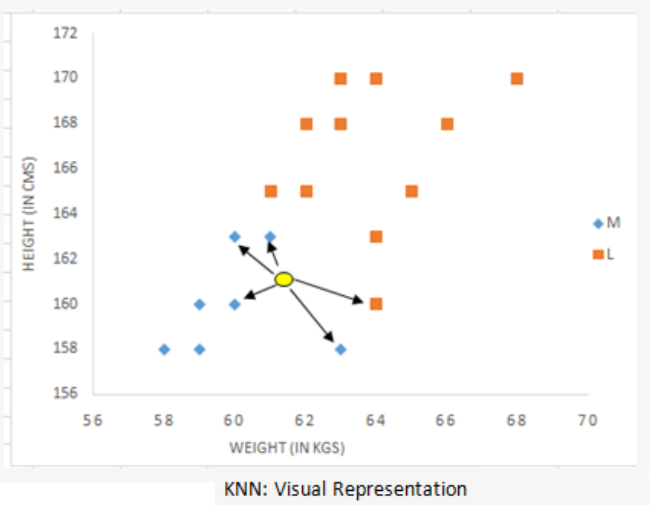

KNN: Visual Representation

KNN Varsayımları:

1. Standardizasyon

Eğitim verilerindeki bağımsız değişkenler farklı birimlerde ölçüldüğünde, mesafeyi hesaplamadan önce değişkenleri standardize etmek önemlidir. Örneğin, bir değişken cm cinsinden yüksekliği temel alıyorsa ve diğeri kg cinsinden ağırlığı temel alıyorsa, uzunluk mesafe hesaplamasını daha fazla etkileyecektir. Bunları karşılaştırılabilir hale getirmek için, aşağıdaki yöntemlerden herhangi biriyle yapılabilecekleri standartlaştırmamız gerekir:

$$Xs = \frac{X - mean}{s.d.}$$

$$Xs = \frac{X - mean}{max - min}$$

$$Xs = \frac{X - min}{\max - min}$$

Standardization

Standardizasyondan önce yükseklik hakim olduğundan, standardizasyondan sonra 5. en yakın değer değişmiştir. Bu nedenle, K-en yakın komşu algoritmasını çalıştırmadan önce tahmin edicileri standart hale getirmek önemlidir.

	A	B	C	D	E
1	Height (in cms)	Weight (in kgs)	T Shirt Size	Distance	
2	-1.39	-1.64	M	1.3	
3	-1.39	-1.27	M	1.0	
4	-1.39	0.25	M	1.0	
5	-0.92	-1.27	**M**	0.8	**4**
6	-0.92	-0.89	**M**	0.4	**1**
7	-0.23	-0.89	**M**	0.6	**3**
8	-0.23	-0.51	**M**	0.5	**2**
9	-0.92	0.63	L	1.2	
10	-0.23	0.63	L	1.2	
11	0.23	-0.51	**L**	0.9	**5**
12	0.23	-0.13	L	1.0	
13	0.23	1.01	L	1.8	
14	0.92	-0.13	L	1.7	
15	0.92	0.25	L	1.8	
16	0.92	1.39	L	2.5	
17	1.39	0.25	L	2.2	
18	1.39	0.63	L	2.4	
19	1.39	2.15	L	3.4	
20					
21	**-0.7**	**-0.5**			

Knn after standardization

2. Aykırı Değer

Düşük k-değeri aykırı değerlere duyarlıdır ve daha yüksek bir K-değeri, daha fazla seçmenin tahmine karar vereceğini düşündüğü için aykırı değerlere karşı daha dirençlidir.

KNN neden parametrik değildir?

Parametrik olmayan, temel alınan veri dağılımı üzerinde herhangi bir varsayımda bulunmamak anlamına gelir. Parametrik olmayan yöntemler, modelde sabit sayıda parametreye sahip değildir. Benzer şekilde KNN'de model parametreleri aslında eğitim veri seti ile birlikte büyür - her eğitim durumunu modelde bir "parametre" olarak düşünebilirsiniz.

KNN ve K-ortalama: Birçok insan bu iki istatistiksel teknik - K-ortalama ve K-en yakın komşu arasında kafa karıştırır. Aşağıdaki farklardan bazılarına bakın:

- K-ortalama denetimsiz bir öğrenme tekniğidir (bağımlı değişken yoktur), KNN denetimli bir öğrenme algoritmasıdır (bağımlı değişken vardır)
- K-ortalama, veri noktalarını her kümedeki noktalar birbirine yakın olacak şekilde K-kümelerine ayırmaya çalışan bir kümeleme tekniğidir, K-en yakın komşu ise bir noktanın sınıflandırmasını belirlemeye çalışır, K sınıflandırmasını en yakın noktalara birleştirmeye çalışır.

KNN regresyon için kullanılabilir mi?

Evet, regresyon için K-en yakın komşu kullanılabilir. Başka bir deyişle, bağımlı değişken sürekli olduğunda K-en yakın komşu algoritması uygulanabilir. Bu durumda, tahmin edilen değer, en yakın k komşusunun değerlerinin ortalamasıdır.

KNN'nin Artıları ve Eksileri

Artıları:

- Anlaması kolay
- Veriler hakkında varsayım yok
- Hem sınıflandırma hem de regresyona uygulanabilir
- Çok sınıflı problemlerde kolayca çalışır

Eksileri:

- Yoğun Bellek / Hesaplama açısından pahalı
- Veri ölçeğine duyarlı
- Nadir olay (çarpık) hedef değişkeni üzerinde iyi çalışmıyor
- Çok sayıda bağımsız değişken olduğunda mücadele
- Herhangi bir problem için, küçük bir k değeri, tahminlerde büyük bir varyansa yol açacaktır. Alternatif olarak, k değerini büyük bir değere ayarlamak, büyük bir model yanlılığına yol açabilir.

KNN'de kategorik değişkenler nasıl ele alınır?
Kategorik bir değişkenden kukla değişkenler oluşturun ve orijinal kategorik değişken yerine bunları dahil edin. Regresyondan farklı olarak, (k-1) yerine k kukla oluşturun. Örneğin, "Departman" adlı kategorik bir değişkenin 5 benzersiz düzeyi/kategorisi vardır. Böylece 5 kukla değişken oluşturacağız. Her kukla değişkenin departmanına karşı 1 ve 0'a sahiptir.

En iyi K değeri nasıl bulunur?
Çapraz doğrulama, optimal K değerini bulmanın akıllı bir yoludur. Model oluşturma sürecinden eğitim setinin bir alt kümesini dışarıda tutarak doğrulama hata oranını tahmin eder.

Çapraz doğrulama (diyelim ki 10 kat doğrulama), eğitim setinin rastgele olarak yaklaşık eşit büyüklükte 10 gruba veya katlara bölünmesini içerir. Verilerin %90'ı modeli eğitmek için, kalan %10'u ise onu doğrulamak için kullanılır. Yanlış sınıflandırma oranı daha sonra %10 doğrulama verisi üzerinden hesaplanır. Bu prosedür 10 kez tekrarlanır. Farklı gözlem grupları, 10 defadan her biri bir doğrulama seti olarak ele alınır. Daha sonra ortalaması alınan doğrulama hatasının 10 tahminiyle sonuçlanır.

K-Nearest Neighbor(KNN) Algorithm for Machine Learning

- K-Nearest Neighbor, Denetimli Öğrenme tekniğine dayalı en basit Makine Öğrenimi algoritmalarından biridir.
- K-NN algoritması, yeni durum/veriler ile mevcut durumlar arasındaki benzerliği varsayar ve yeni durumu mevcut kategorilere en çok benzeyen kategoriye koyar.
- K-NN algoritması mevcut tüm verileri saklar ve benzerliğe göre yeni bir veri noktasını sınıflandırır. Bu, yeni veriler göründüğünde, K-NN algoritması kullanılarak kolayca bir grup paketi kategorisine sınıflandırılabileceği anlamına gelir.
- K-NN algoritması Sınıflandırmanın yanı sıra Regresyon için de kullanılabilir ancak çoğunlukla Sınıflandırma problemleri için kullanılır.
- K-NN, parametrik olmayan bir algoritmadır, yani temel veriler üzerinde herhangi bir varsayımda bulunmaz.
- Eğitim setinden hemen öğrenmediği için veri setini sakladığı ve sınıflandırma anında veri seti üzerinde bir işlem yaptığı için tembel öğrenen algoritması olarak da adlandırılır.
- KNN algoritması eğitim aşamasında sadece veri setini saklar ve yeni veri aldığında bu veriyi yeni veriye çok benzeyen bir kategoride sınıflandırır.

Örnek: Diyelim ki elimizde kedi ve köpeğe benzeyen bir yaratığın görüntüsü var ama onun kedi mi yoksa köpek mi olduğunu bilmek istiyoruz. Bu tanımlama için, benzerlik ölçüsü üzerinde çalıştığı için KNN algoritmasını kullanabiliriz. KNN modelimiz, yeni veri setinin kedi ve köpek resimlerine benzer özelliklerini bulacak ve en benzer özelliklere dayanarak onu kedi veya köpek kategorisine yerleştirecektir.

Uygulama:

KNN, sınıflandırma veya regresyon görevleri için kullanılabilen basit, denetimli bir makine öğrenimi (ML) algoritmasıdır ve ayrıca eksik değer atamasında sıklıkla kullanılır. Belirli bir veri noktasına en yakın gözlemlerin bir veri kümesindeki en "benzer" gözlemler olduğu fikrine dayanır ve bu nedenle öngörülemeyen noktaları mevcut en yakın noktaların değerlerine göre sınıflandırabiliriz. Kullanıcı, K'yi seçerek algoritmada kullanmak üzere yakındaki gözlemlerin sayısını seçebilir.

Burada, sınıflandırma için KNN algoritmasının nasıl uygulayacağı ve farklı K değerlerinin sonuçları nasıl etkilediği gösterilecektir.

Nasıl çalışır?
K, kullanılacak en yakın komşu sayısıdır. Sınıflandırma için, yeni bir gözlemin hangi sınıfa gireceğini belirlemek için çoğunluk oyu kullanılır. Daha büyük K değerleri genellikle aykırı değerlere karşı daha sağlamdır ve çok küçük değerlerden daha kararlı karar sınırları üretir (K=3, K=1'den daha iyi olur, bu da istenmeyen sonuçlar doğurabilir.

Örnek: Bazı veri noktalarını görselleştirerek başlayalım.

```
import matplotlib.pyplot as plt
x = [4, 5, 10, 4, 3, 11, 14 , 8, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]
classes = [0, 0, 1, 0, 0, 1, 1, 0, 1, 1]

plt.scatter(x, y, c=classes)
plt.show()
```

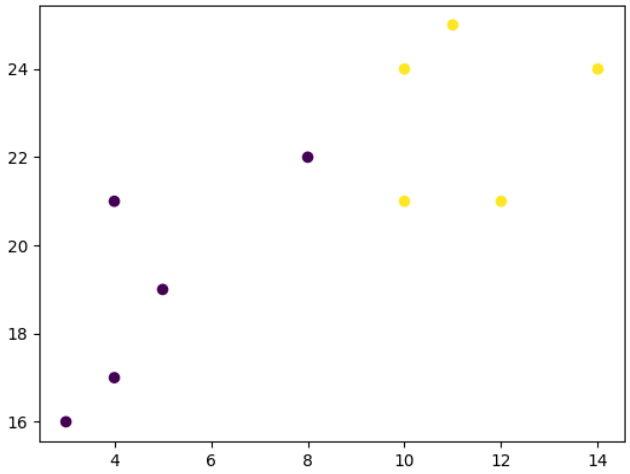

Şimdi KNN algoritmasını K=1 ile uyumlu hale getirelim:

```
from sklearn.neighbors import KNeighborsClassifier
data = list(zip(x, y))
knn = KNeighborsClassifier(n_neighbors=1)
knn.fit(data, classes)
```

Ve yeni bir veri noktası sınıflandırılmak için kullanılır.

Kod örneği:

```
new_x = 8
new_y = 21
new_point = [(new_x, new_y)]
prediction = knn.predict(new_point)

plt.scatter(x + [new_x], y + [new_y], c=classes + [prediction[0]])
plt.text(x=new_x-1.7, y=new_y-0.7, s=f"new point, class: {prediction[0]}")
plt.show()
```

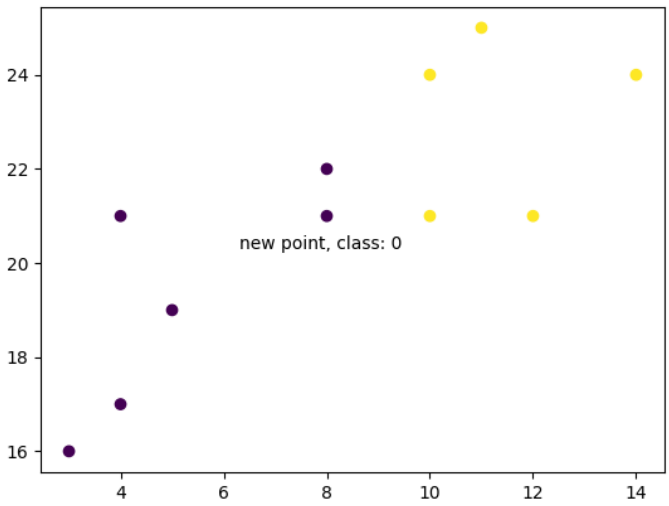

Şimdi aynı şeyi yapıyoruz, ancak tahmini değiştiren daha yüksek bir K değeriyle.

Kod örneği:

```
knn = KNeighborsClassifier(n_neighbors=5)
knn.fit(data, classes)
prediction = knn.predict(new_point)
plt.scatter(x + [new_x], y + [new_y], c=classes + [prediction[0]])
plt.text(x=new_x-1.7, y=new_y-0.7, s=f"new point, class: {prediction[0]}")
plt.show()
```

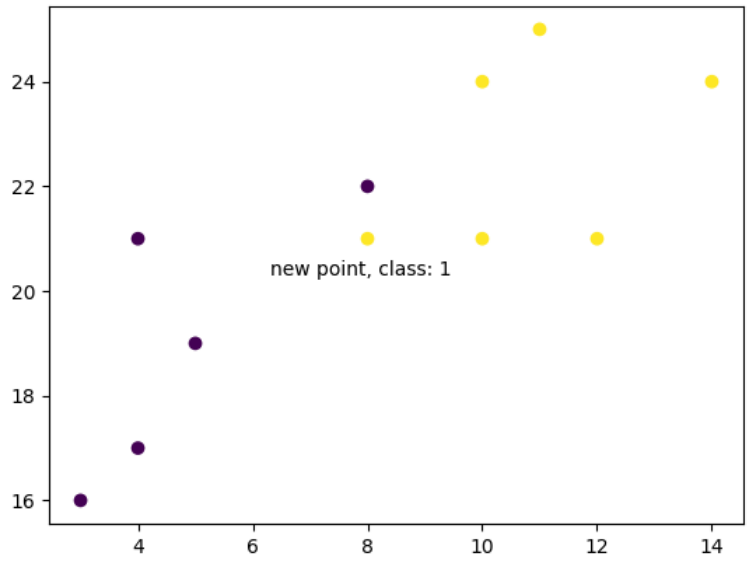

Örneğin açıklanması:
İhtiyaç duyulaan modüller içe aktarılır. scikit-learn, Python'da makine öğrenimi için popüler bir kütüphanedir.

import matplotlib.pyplot as plt
from sklearn.neighbors import KNeighborsClassifier

Bir veri kümesindeki değişkenlere benzeyen diziler oluşturulur. İki girdi özelliği (x ve y) ve ardından bir hedef sınıf (sınıf) var. Hedef sınıfla önceden etiketlenmiş girdi özellikleri, yeni veri sınıfını tahmin etmek için kullanılacaktır. Burada yalnızca iki giriş özelliği kullanırken, bu yöntemin herhangi bir sayıda değişkenle çalışacağını unutmayın:

x = [4, 5, 10, 4, 3, 11, 14 , 8, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]
classes = [0, 0, 1, 0, 0, 1, 1, 0, 1, 1]
Turn the input features into a set of points:
data = list(zip(x, y))
print(data)

Sonuç:
[(4, 21), (5, 19), (10, 24), (4, 17), (3, 16), (11, 25), (14, 24), (8, 22), (10, 21), (12, 21)]

Girdi özniteliklerini ve hedef sınıfı kullanarak, en yakın 1 komşuyu kullanarak modele bir KNN modeli sığdırıyoruz.
knn = KNeighborsClassifier(n_neighbors=1)
knn.fit(data, classes)

Ardından, yeni, öngörülemeyen veri noktalarının sınıfını tahmin etmek için aynı KNN nesnesini kullanabiliriz. İlk önce yeni x ve y özellikleri yaratırız ve ardından 0 veya 1 sınıfı elde etmek için yeni veri noktasında knn.predict() öğesini çağırırız:

new_x = 8
new_y = 21
new_point = [(new_x, new_y)]
prediction = knn.predict(new_point)
print(prediction)

Sonuç: [0]

Tüm verileri yeni nokta ve sınıfla birlikte çizdiğimizde, 1 sınıfı ile mavi olarak etiketlendiğini görebiliriz. Metin açıklaması yalnızca yeni noktanın konumunu vurgulamak içindir:

plt.scatter(x + [new_x], y + [new_y], c=classes + [prediction[0]])
plt.text(x=new_x-1.7, y=new_y-0.7, s=f"new point, class: {prediction[0]}")
plt.show()

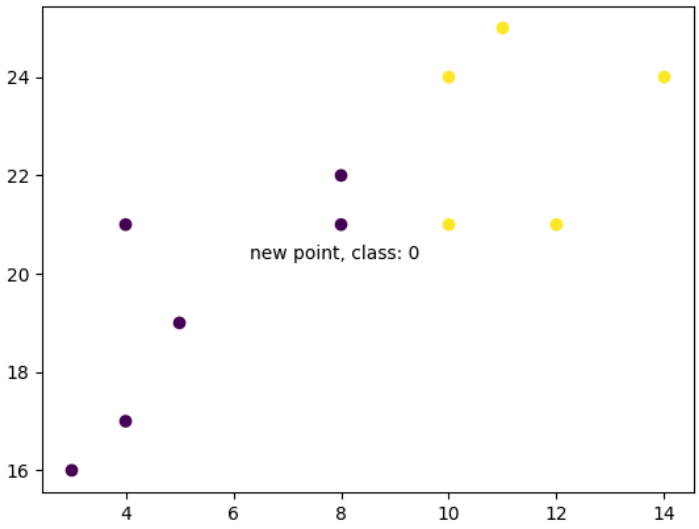

Ancak komşu sayısını 5 olarak değiştirdiğimizde, yeni noktamızı sınıflandırmak için kullanılan nokta sayısı değişir. Sonuç olarak, yeni noktanın sınıflandırılması da öyle:

```
knn = KNeighborsClassifier(n_neighbors=5)
knn.fit(data, classes)
prediction = knn.predict(new_point)
print(prediction)
```

Sonuç: [1]

Yeni noktanın sınıfını eski noktalarla birlikte çizdiğimizde, ilgili sınıf etiketine göre rengin değiştiğini not ederiz:

```
plt.scatter(x + [new_x], y + [new_y], c=classes + [prediction[0]])
plt.text(x=new_x-1.7, y=new_y-0.7, s=f"new point, class: {prediction[0]}")
plt.show()
```

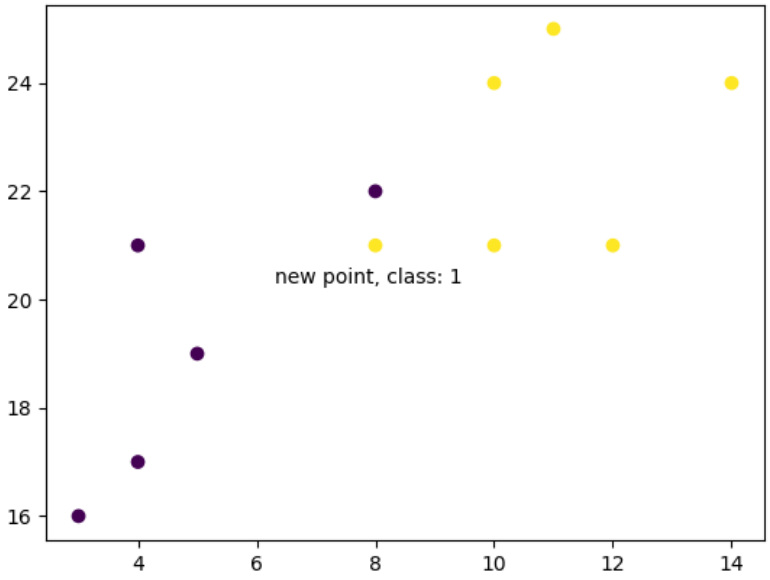

5.4. Destek Vektör Makineleri

Destek Vektör Makinesi, farklı sınıfları ayırmak ve sınır marjını en üst düzeye çıkarmak için karar sınırlarını bulmaktan sorumludur. Farklı sınıfların sınırları arasındaki boşluklar, çizgi ile çizgiye en yakın noktalar arasındaki (dik) mesafelerdir. DVM'de sınıflar arasındaki sınırlar çok önemlidir.

İki sınıflı bir örnekle başlayalım: Verilen X1 ve X2 sınıfları için, iki sınıfı en iyi, yani minimum hata ile ayıran karar sınırını bulmak istiyoruz. SVM bunu bir "Hiperplane" ile yapar. Şimdi bu hiperdüzlem 2 boyutlu veri olması durumunda tek bir doğru olabilir ve 3 boyutlu veri olması durumunda bir düzlem olabilir.

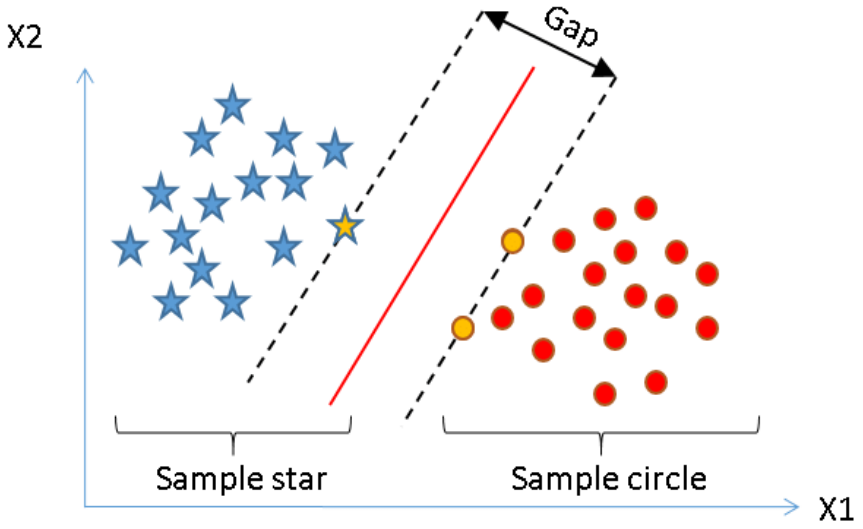

Destek Vektör Makineleri, hiper düzleme en yakın noktalar olan 'Destek Vektörleri' kavramını kullanır. Yukarıdaki örnekte, kırmızı çizgi, tampon bölgenin ortasından geçen doğrusal hattır. İki sınıfı (Mavi yıldızlar ve Kırmızı daireler) ayıran karar sınırımızı gösterir. Tireli çizgiler, her iki sınıfın Destek Vektörleri arasında istediğimiz veri yığınını ayıran bölge sınırıdır, 'Marj'ımızı temsil eder.

Sınırlar önemlidir. Veri bölgeleri sınırı üzerindeki verilerin kırmızı çizgiye uzaklığı hesaplanır. Marj, Destek Vektörlerinin (dolayısıyla algoritmanın adı) yardımıyla tanımlanır. Örneğimizde, Sarı yıldızlar ve Sarı daireler, Marjı tanımlayan Destek Vektörleridir. Boşluk ne kadar iyi olursa, sınıflandırıcı o kadar iyi çalışır. Bu nedenle destek vektörleri sınıflandırıcının geliştirilmesinde önemli bir rol oynamaktadır. Test verilerindeki her yeni veri noktası bu Marj'a göre sınıflandırılacaktır. Sağ tarafındaysa Kırmızı daire, aksi halde Mavi yıldız olarak sınıflandırılır.

En iyi yanı, SVM'nin doğrusal olmayan verileri de sınıflandırabilmesidir.

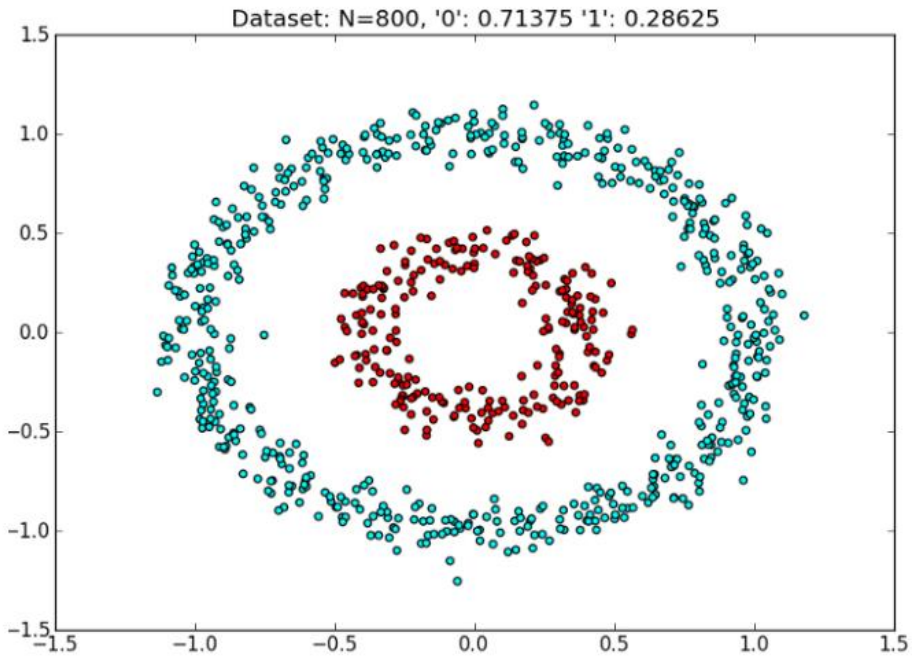

Doğrusal olmayan veriler söz konusu olduğunda işler biraz zorlaşır. Burada SVM 'Çekirdek hilesi' kullanır, doğrusal olmayan verileri daha yüksek boyutlara eşlemek için bir çekirdek işlevi kullanır, böylece doğrusal hale gelir ve orada karar sınırını bulur. Bir Çekirdek işlevi, ister doğrusal ister doğrusal olmayan veri olsun, SVM tarafından her zaman kullanılır, ancak ana işlevi, veriler mevcut haliyle ayrılmaz olduğunda devreye girer. Burada, Çekirdek işlevi, sınıflandırma sorununa boyutlar ekler.

Soruna bağlı olarak, farklı türde Çekirdek işlevleri kullanabilirsiniz:

- Doğrusal
- Polinom
- Radyal Temel Fonksiyonu
- Gauss
- Laplace

… ve daha fazlası. Doğru çekirdek işlevini seçmek, sınıflandırıcıyı oluşturmak için önemlidir.

Destek vektör ağları olarak da bilinen destek vektör makineleri, sınıflandırma ve regresyon için kullanılan ilgili denetimli öğrenme yöntemleri kümesidir. Her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneği verildiğinde, bir DVM eğitim algoritması yeni bir örneğin bir kategoriye mi yoksa diğerine mi düştüğünü tahmin eden bir model oluşturur.

SVM'nin (Destek Vektör Makinesi) kullanabileceği iki sınıflandırma yöntemi:

- İkili sınıflandırıcıları birleştirme
- Çok sınıflı öğrenmeyi dahil etmek için ikili programı değiştirme

Destek Vektör Makinesi algoritması oluşturulurken,

- Sınıflar arasındaki birbirine en yakın ikili seçilir. Bu noktalara destek vektörleri isimleri veriyoruz.
- Destek vektörlerinden geçecek şekilde doğrular çizilir. Bu doğrulara sınır çizgisi adı verilir.
- Her doğruya eşit uzakta çizilen doğruya karar doğrusu adı verilir. Karar doğrusuna hiper düzlem de denir.

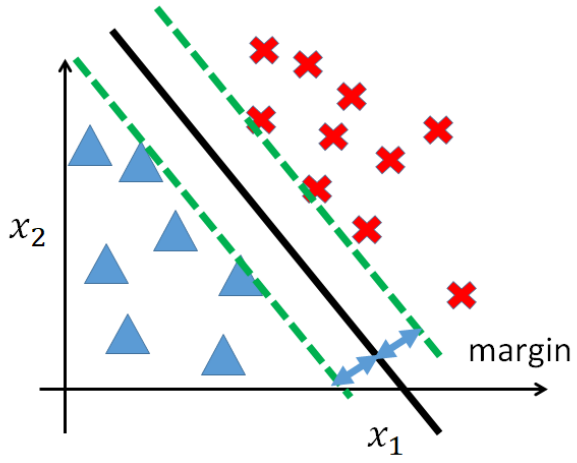

DVM'lerde sınıflar +1 ve -1 olarak etiketlenir. Karar doğrusunun üst kısmında kalan doğru denklemi, wx+b=1 , altında kalan doğru denklemi ise wx+b=-1 olarak belirlenir. Karar doğrusu denklemi ise, wx +b=0 olur.

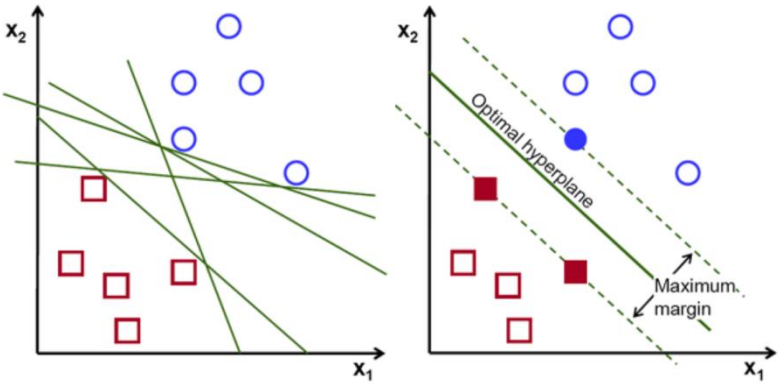

Doğru hiper düzlemi belirleyin: Burada üç hiper düzlemimiz var (A, B ve C). Şimdi, yıldızları ve daireleri sınıflandırmak için doğru hiper düzlemi belirleyin.

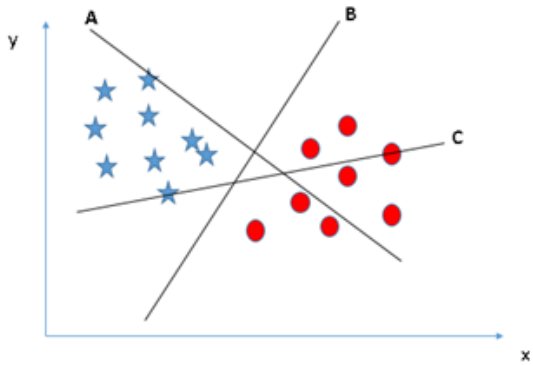

Doğru hiper düzlemi belirlemek için basit bir kuralı hatırlamanız gerekir: “İki sınıfı daha iyi ayıran hiper düzlemi seçin”. Bu senaryoda, hiper-düzlem “B” bu işi mükemmel bir şekilde gerçekleştirmiştir. B çizgisi hiçbirine değmez ve teğet geçmez.

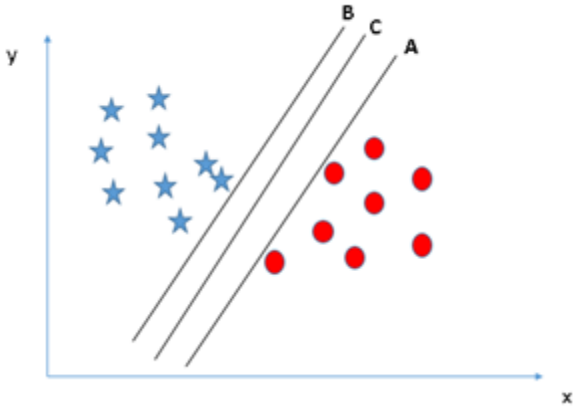

Burada en yakın veri noktası (her iki sınıf) ile hiper düzlem arasındaki mesafeleri maksimize etmek, doğru hiper düzleme karar vermemize yardımcı olacaktır. Bu mesafeye Marj denir.

Aşağıdaki anlık görüntüye bakalım:

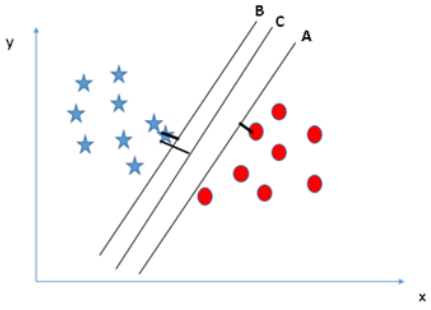

Yukarıda, C hiper düzleminin marjının hem A hem de B'ye kıyasla yüksek olduğunu görebilirsiniz. Bu nedenle, sağ hiper düzlemi C olarak adlandırıyoruz. Daha yüksek marjlı hiper düzlemi seçmenin bir başka yıldırım nedeni sağlamlıktır. Düşük marjlı bir hiper-düzlem seçersek, yüksek yanlış sınıflandırma şansı vardır.

Aşağıdaki senaryoda, iki sınıf arasında doğrusal hiper düzleme sahip olamayız, peki SVM bu iki sınıfı nasıl sınıflandırır? Şimdiye kadar sadece lineer hiper düzleme baktık.

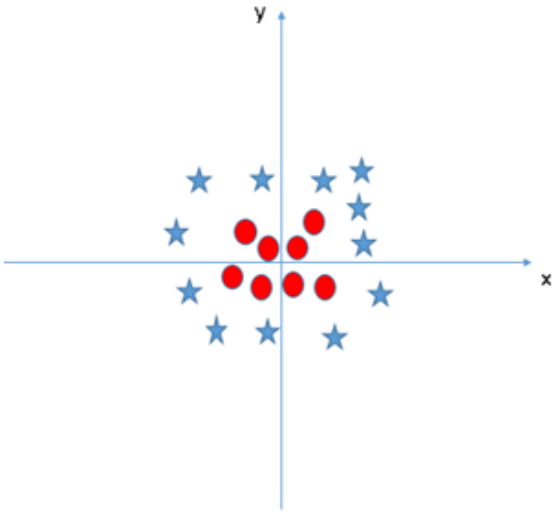

SVM bu sorunu çözebilir. Kolayca! Ek özellik sunarak bu sorunu çözer. Burada yeni bir özellik z=x^2+y^2 ekleyeceğiz. Şimdi veri noktalarını x ve z eksenlerine yerleştirelim:

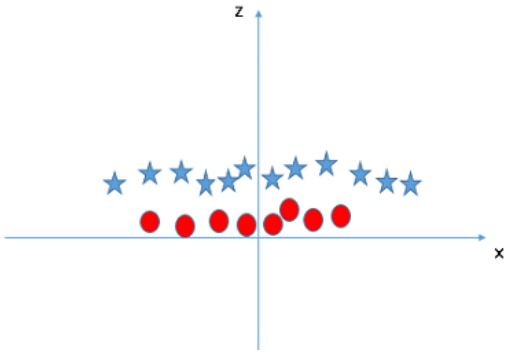

Yukarıdaki arsada, dikkate alınması gereken noktalar şunlardır:

- z için tüm değerler her zaman pozitif olacaktır çünkü z hem x hem de y'nin karelerinin toplamıdır
- Orijinal çizimde, x ve y eksenlerinin orijine yakın kırmızı daireler görünür, bu da daha düşük z değerine ve orijinden nispeten uzaktaki yıldızın daha yüksek z değerine yol açmasına neden olur.

DVM sınıflandırıcısında, bu iki sınıf arasında doğrusal bir hiper düzleme sahip olmak kolaydır. Ancak, ortaya çıkan bir diğer yakıcı soru, bir hiper düzleme sahip olmak için bu özelliği manuel olarak eklememiz gerekip gerekmediğidir. Hayır, SVM algoritmasının çekirdek hilesi adı verilen bir tekniği vardır. SVM çekirdeği, düşük boyutlu girdi uzayını alan ve onu daha

yüksek boyutlu bir uzaya dönüştüren, yani ayrılamayan problemi ayrılabilir probleme dönüştüren bir fonksiyondur. Çoğunlukla doğrusal olmayan ayırma probleminde kullanışlıdır. Basitçe söylemek gerekirse, bazı son derece karmaşık veri dönüşümleri yapar ve ardından tanımladığınız etiketlere veya çıktılara göre verileri ayırma sürecini bulur.

Orijinal girdi uzayındaki hiper düzleme baktığımızda bir daireye benziyor:

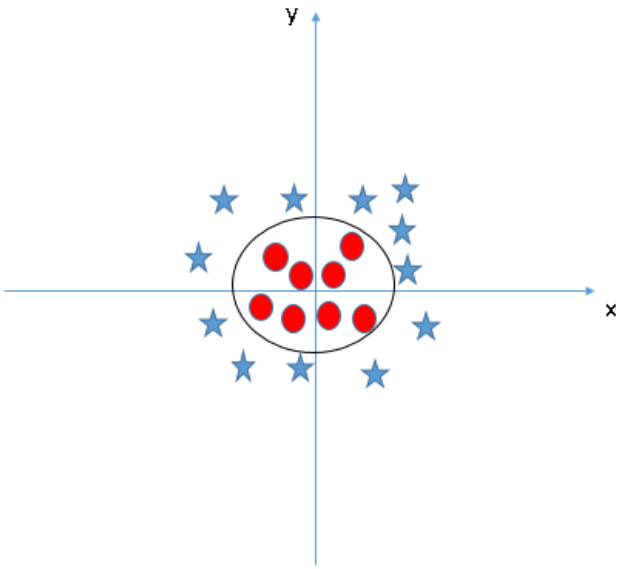

Kütüphaneleri İndirme, Çalışma Dizinini Ayarlama, Veri Setini İndirme

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import os
os.chdir('Calisma_Dizniniz')
dataset = pd.read_csv('SosyalMedyaReklamKampanyası.csv')
```

Spyder'ın variable explorer penceresinden veri setimizi görelim:

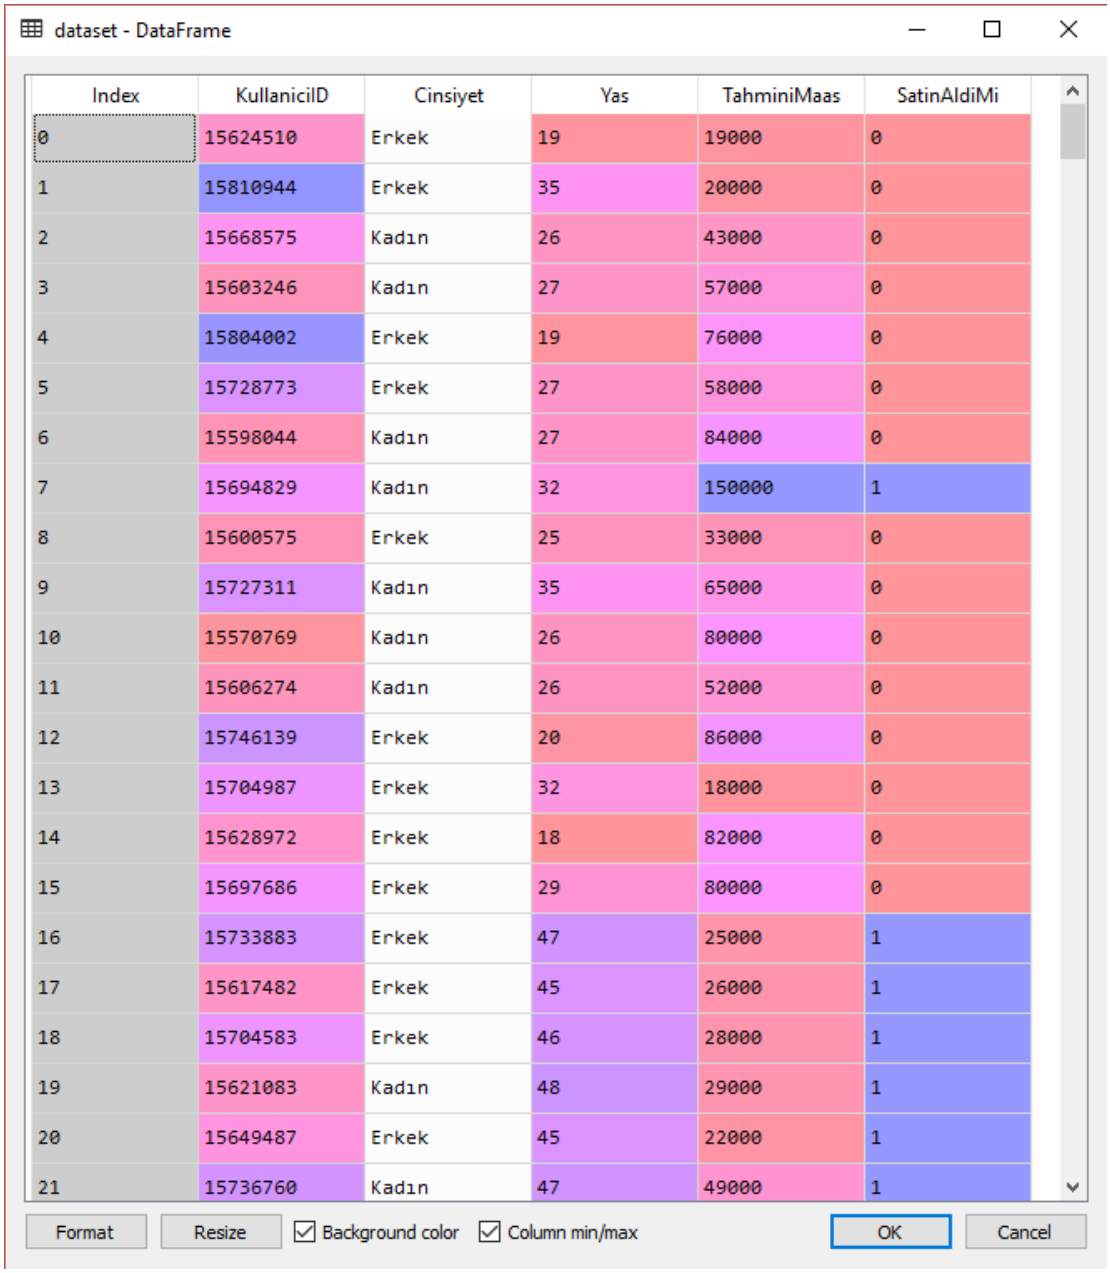

Index	KullaniciID	Cinsiyet	Yas	TahminiMaas	SatinAldiMi
0	15624510	Erkek	19	19000	0
1	15810944	Erkek	35	20000	0
2	15668575	Kadın	26	43000	0
3	15603246	Kadın	27	57000	0
4	15804002	Erkek	19	76000	0
5	15728773	Erkek	27	58000	0
6	15598044	Kadın	27	84000	0
7	15694829	Kadın	32	150000	1
8	15600575	Erkek	25	33000	0
9	15727311	Kadın	35	65000	0
10	15570769	Kadın	26	80000	0
11	15606274	Kadın	26	52000	0
12	15746139	Erkek	20	86000	0
13	15704987	Erkek	32	18000	0
14	15628972	Erkek	18	82000	0
15	15697686	Erkek	29	80000	0
16	15733883	Erkek	47	25000	1
17	15617482	Erkek	45	26000	1
18	15704583	Erkek	46	28000	1
19	15621083	Kadın	48	29000	1
20	15649487	Erkek	45	22000	1
21	15736760	Kadın	47	49000	1

Veriyi Anlamak

Yukarıda gördüğümüz veri seti beş nitelikten oluşuyor. Veri seti bir sosyal medya kayıtlarından derlenmiş durumda. KullaniciID müşteriyi belirleyen eşsiz rakam, Cinsiyet, Yaş, Tahmini Gelir yıllık tahmin edilen gelir, SatinAldiMi ise belirli bir ürünü satın almış olup olmadığı, hadi lüks araba diyelim. Bu veri setinde kolayca anlaşılabileceği gibi hedef değişkenimiz SatinAldiMi'dir. Diğer dört nitelik ise bağımsız niteliklerdir. Bu bağımsız niteliklerle bağımlı nitelik (satın alma davranışının gerçekleşip gerçekleşmeyeceği) tahmin edilecek.

Veri Setini Bağımlı ve Bağımsız Niteliklere Ayırmak

Yukarıda gördüğümüz niteliklerden bağımsız değişken olarak sadece yaş ve tahmini maaşı kullanacağız.

X = dataset.iloc[:, [2,3]].values

y = dataset.iloc[:, 4].values

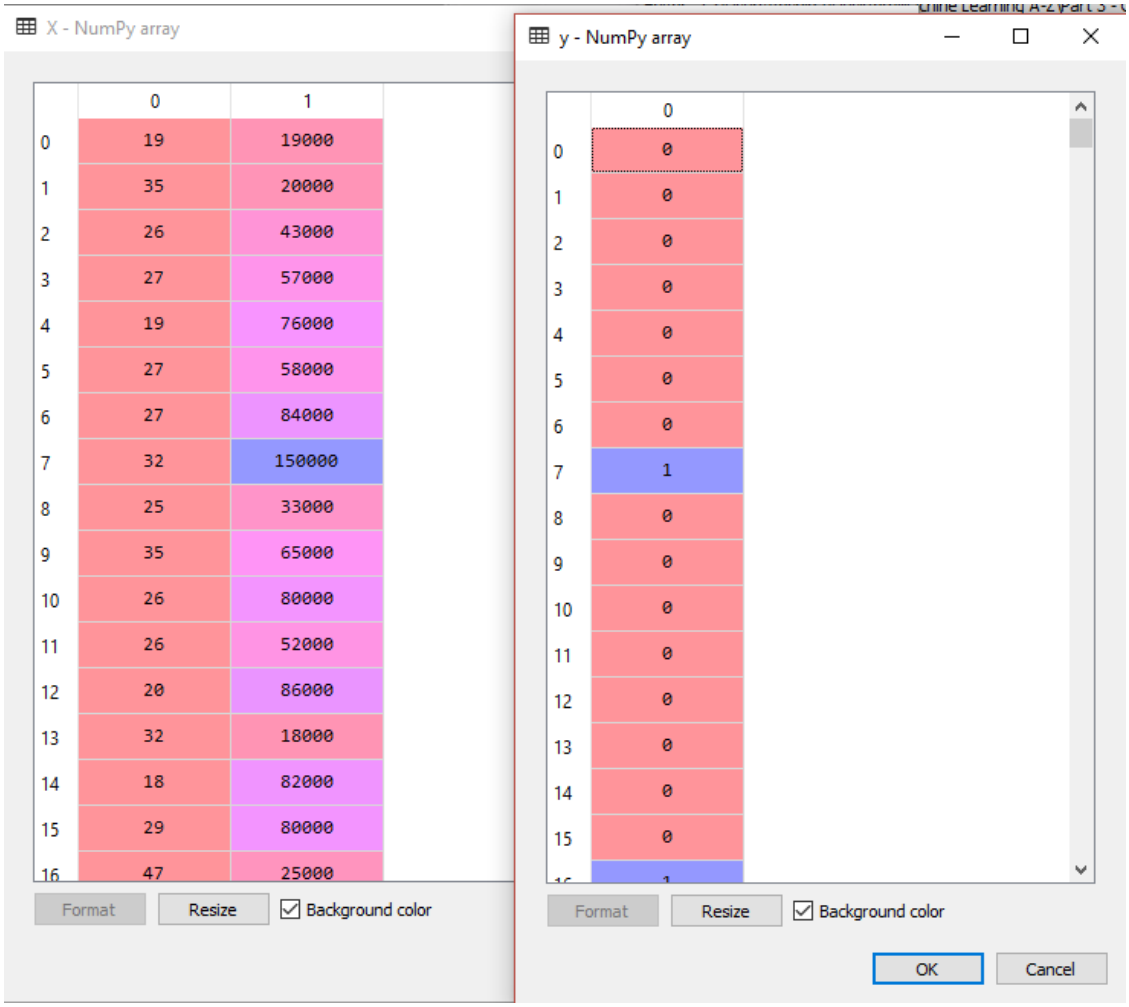

Veriyi Eğitim ve Test Olarak Ayırmak

Veri setinde 400 kayıt var bunun 300'ünü eğitim, 100'ünü test için ayıralım.

```
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.25, random_state = 0)
```

Normalizasyon – Feature Scaling

Bağımsız değişkenlerden yaş ile tahmini gelir aynı birimde olmadığı için feature scaling uygulayacağız.

```
from sklearn.preprocessing import StandardScaler
sc_X = StandardScaler()
X_train = sc_X.fit_transform(X_train)
X_test = sc_X.transform(X_test)
```

SVM Modeli Oluşturmak ve Eğitmek

Şimdi scikit-learn kütüphanesi svm modülü SVC sınıfından oluşturacağımız classifier nesnesi ile modelimiz oluşturalım.

```
from sklearn.svm import SVC
classifier = SVC(kernel='linear', random_state = 0)
classifier.fit(X_train, y_train)
```

Sınıf parametrelerinden biraz bahsedelim. kernel linear, her seferinde aynı sonuçları almak için de random_state=0 diyoruz.

Test Seti ile Tahmin Yapmak

Ayırdığımız test setimizi (X_test) kullanarak oluşturduğumuz model ile tahmin yapalım ve elde ettiğimiz set (y_pred) ile hedef değişken (y_test) test setimizi karşılaştıralım.

y_pred = classifier.predict(X_test)

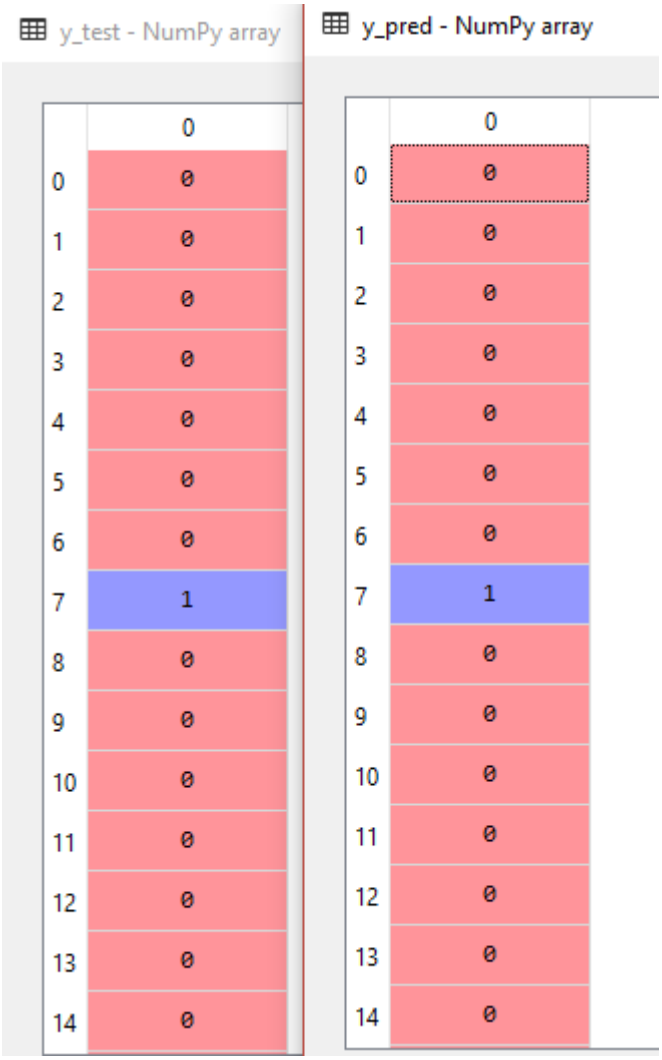

	0
0	0
1	0
2	0
3	0
4	0
5	0
6	0
7	1
8	0
9	0
10	0
11	0
12	0
13	0
14	0

	0
0	0
1	0
2	0
3	0
4	0
5	0
6	0
7	1
8	0
9	0
10	0
11	0
12	0
13	0
14	0

Yukarıda y_test (gerçek veri) ile modelin tahmin ettiği y_pred bir görüntü bulunuyor. gördüğümüz kadarıyla tüm tahminler doğru görünüyor ancak daha buradan göremediğimiz bir çok değer var. Neyse hata matrisinde görünür artık.

Hata Matrisini Oluşturma

Yaptığımız sınıflandırmanın doğruluğunu kontrol etme yöntemlerinden birisi de hata matrisi oluşturmaktır. Hata matrisi için scikit-learn kütüphanesi metrics modülü confusion_matrix fonksiyonunu kullanıyoruz.

```
from sklearn.metrics import confusion_matrix
cm = confusion_matrix(y_test, y_pred)
print(cm)
[[66 2]
 [ 8 24]]
```

Bildiğiniz gibi 100 kayıtlık test verisi ayırmıştık. Yukarıda gördüğümüz hata matrisine göre 10 kayıt yanlış sınıflandırılmış, 90 kayıt doğru sınıflandırılmış. Lojistik regresyonda yanlış sınıflandırma sayısı 11 idi. K en yakın komşuda ise 7 idi. Grafiğimizi görelim:

```
from matplotlib.colors import ListedColormap
X_set, y_set = X_train, y_train
X1, X2 = np.meshgrid(np.arange(start = X_set[:, 0].min() - 1, stop = X_set[:, 0].max() + 1, step
= 0.01),
       np.arange(start = X_set[:, 1].min() - 1, stop = X_set[:, 1].max() + 1, step = 0.01))
plt.contourf(X1, X2, classifier.predict(np.array([X1.ravel(), X2.ravel()]).T).reshape(X1.shape),
          alpha = 0.75, cmap = ListedColormap(('blue', 'green')))
plt.xlim(X1.min(), X1.max())
plt.ylim(X2.min(), X2.max())
for i, j in enumerate(np.unique(y_set)):
    plt.scatter(X_set[y_set == j, 0], X_set[y_set == j, 1],
               c = ListedColormap(('yellow', 'green'))(i), label = j)
plt.title('SVM (Eğitim Seti)')
plt.xlabel('Yaş')
plt.ylabel('Maaş')
plt.legend()
plt.show()
```

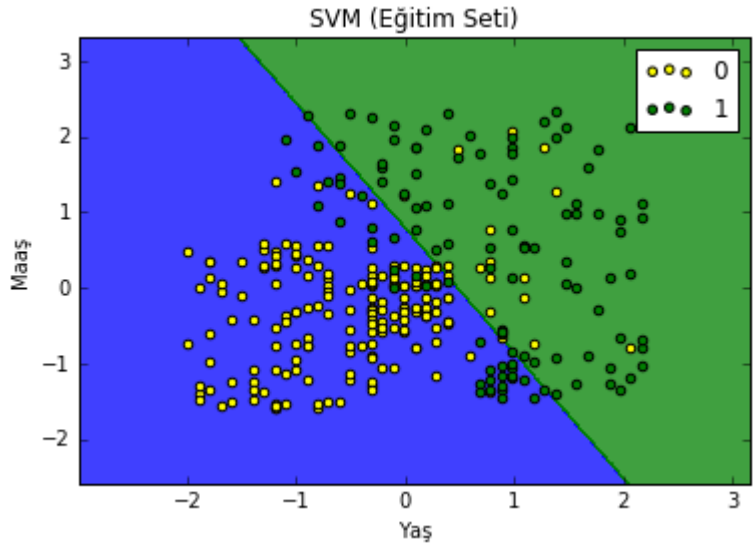

Şimdi grafiğimizi test setleri için çizelim. Bunun için yukarıdaki kodda veri setini ve etiket bilgilerini değiştirmek yeterli olur.

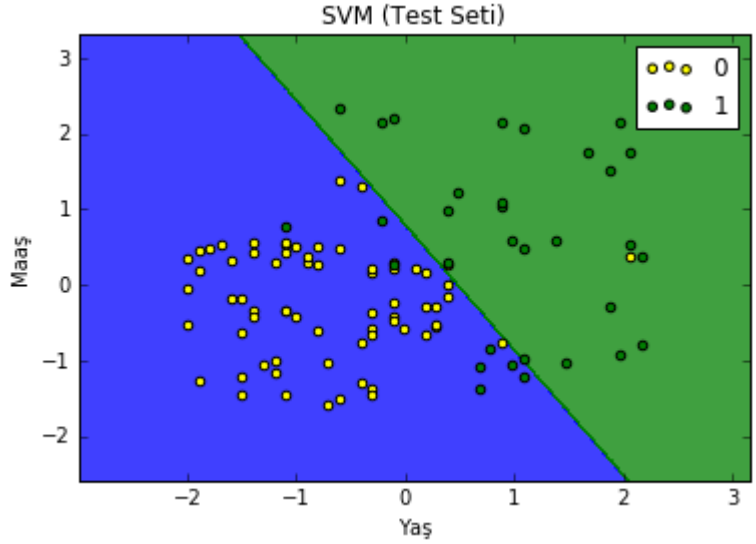

Yanlış sınıflandırılan 10 noktayı buradan sayabiliriz. Grafik lojistik regresyona çok benzedi. Zaten hata sayımız da birbirine çok yakındı.

5.5. Naive Bayes

Bayes Ağı, bir dizi değişken arasındaki ilişkilerin olasılıklarını öğrenerek çıkarım yapan bir makine öğrenmesi algoritmasıdır. Düşünce ya da oluşan kanı veya yönlendirilmiş olasılıklı bir modeldir. Örneğin, bir Bayes ağı, hastalıklar ve semptomlar arasındaki olasılık ilişkilerini temsil edebilir. Belirtiler verildiğinde, ağ çeşitli hastalıkların varlığının olasılıklarını hesaplamak için kullanılabilir.

Konuşma sinyalleri veya protein dizileri gibi değişken dizilerini modelleyen Bayes ağlarına dinamik Bayes şebekeleri denir. Belirsizlik altında karar problemlerini temsil edebilen ve çözebilen Bayes ağlarının genellemelerine etki diyagramları denir.

Naïve Bayes'te sınıflandırıcı, lojistik regresyon gibi ayırt edici modellere göre daha hızlı birleşir, bu nedenle daha az eğitim verisine ihtiyacınız vardır. Ana avantajı, özellikler arasındaki etkileşimleri öğrenememesidir.

Bayesci mantık programı iki bileşenden oluşur. İlk bileşen mantıklı bir bileşendir; alanın niteliksel yapısını yakalayan bir dizi Bayes Cümlelerinden oluşur. İkinci bileşen nicelikseldir, alanla ilgili nicel bilgileri kodlar.

Yağmur, yağmurlama sisteminin etkinleştirilip etkinleştirilmeyeceğini etkiler ve hem yağmur hem de yağmurlama sistemi çimlerin ıslak olup olmadığını etkiler. Çim ıslak ise yağmu mu yağdı yoksa yağmurlama sistemi mi çalıştı.

Örneğin, Cebrail pikniğie gitmiş olsun, bu durumda Cebrail'in olduğu yer de yağmur yağmuyor.

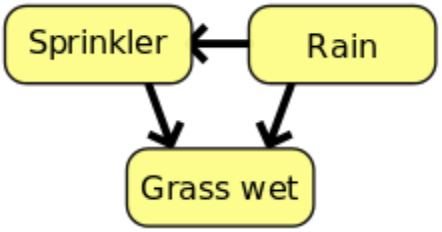

Örnek:
Test altındaki sistemin giriş sayısı 5 çıkış sayısı 1 dir. Girişler ikili sayı sisteminde bit olarak uygulanmaktadır. Toplam test sayısı 20 cihaz ise, testten geçen cihaz sayısı 18 ise testten kalma olasılığı nedir?

Örnek:

Gün	Görünüş	Sıcaklık	Nem	Rüzgar	Play
1	Güneşli	Sıcak	Yüksek	Zayıf	Hayır
2	Güneşli	Sıcak	Yüksek	Kuvvetli	Hayır
3	Bulutlu	Sıcak	Yüksek	Zayıf	Evet
4	Yağmurlu	Hafif	Yüksek	Zayıf	Evet
5	Yağmurlu	Soğuk	Normal	Zayıf	Evet
6	Yağmurlu	Soğuk	Normal	Kuvvetli	Hayır
7	Bulutlu	Soğuk	Normal	Kuvvetli	Evet
8	Güneşli	Hafif	Yüksek	Zayıf	hayır
9	Güneşli	Soğuk	Normal	Zayıf	Evet
10	Yağmurlu	Hafif	Normal	Zayıf	Evet
11	Güneşli	Hafif	Normal	Kuvvetli	Evet
12	Bulutlu	Hafif	Yüksek	Kuvvetli	Evet
13	Bulutlu	Sıcak	Normal	Zayıf	Evet
14	Yağmurlu	Hafif	Yüksek	Kuvvetli	hayır
	Güneşli	**Soğuk**	**Yüksek**	**Kuvvetli**	?

Toplam Gün Sayısı=14
Evet=9
Hayır=5

P(Evet)=9/14
P(Hayır)=5/14

Havanın görünüş durumuna göre,
Havanın görünüşü güneşli olduğunda 2 gün oyun var. Hava güneşli olduğunda oyun oynama olasılığı, P(H_Güneşli | Evet)=2/9
Havanın görünüşü güneşli olduğunda 3 gün oyun yok. P(H_Güneşli | Hayır)=3/5
Toplam güneşli gün sayısı=2+3=5

Havanın görünüşü bulutlu olduğunda 4 gün oyun var. P(H_Bulutlu | Evet)=4/9
Havanın görünüşü bulutlu olduğunda 0 gün oyun yok. P(H_Bulutlu | Hayır)=0/5
Toplam bulutlu gün sayısı=4+0=4

Havanın görünüşü yağmurlu olduğunda 3 gün oyun var. P(H_Yağmurlu | Evet)=3/9
Havanın görünüşü yağmurlu olduğunda 2 gün oyun yok. P(H_Yağmurlu | Hayır)=2/5

Toplam yağmurlu gün sayısı=2+3=5
Toplam gün sayısı=5+4+5=14

Sıcaklık durumuna göre,
Sıcaklığın sıcak olduğunda 2 gün oyun var. P(S_Sıcak | Evet)=2/9
Sıcaklığın sıcak olduğunda 2 gün oyun yok. P(S_Sıcak | Hayır)=2/5
Toplam sıcak gün sayısı=2+2=4

Sıcaklığın hafif olduğunda 4 gün oyun var. P(S_Hafif | Evet)=4/9
Sıcaklığın hafif olduğunda 2 gün oyun yok. P(S_Hafif | Hayır)=2/5
Toplam hafif gün sayısı=4+2=6

Sıcaklığın soğuk olduğunda 3 gün oyun var. P(S_Soğuk | Evet)=3/9
Sıcaklığın soğuk olduğunda 1 gün oyun yok. P(S_Soğuk | Hayır)=1/5
Toplam soğuk gün sayısı=3+1=4
Toplam gün sayısı=4+6+4=14

Rüzgar durumuna göre,
Rüzgar zayıf olduğunda 6 gün oyun var. P(R_Zayıf | Evet)=6/9=2/3
Rüzgar zayıf olduğunda 2 gün oyun yok. P(R_Zayıf | Hayır)=2/5
Toplam rüzgar zayıf gün sayısı=6+2=8

Rüzgar Kuvvetli olduğunda 3 gün oyun var. P(R_Kuvvetli | Evet)=3/9=1/9
Rüzgar Kuvvetli olduğunda 3 gün oyun yok. P(R_Kuvvetli | Hayır)=3/5
Toplam rüzgar kuvvetli gün sayısı=3+3=6
Toplam gün sayısı=8+6=14

Nem durumuna göre,
Nem yüksek olduğunda 3 gün oyun var. P(N_Yüksek | Evet)=3/9
Nem yüksek olduğunda 4 gün oyun yok. P(N_Yüksek | Hayır)=4/5
Toplam nem yüksek gün sayısı=3+4=7

Nem normal olduğunda 6 gün oyun var. P(N_Normal | Evet)=6/9
Nem normal olduğunda 1 gün oyun yok. P(N_Normal | Hayır)=1/5
Toplam nem zayıf gün sayısı=6+1=7
Toplam gün sayısı=7+7=14

X={Güneşli, Soğuk, Yüksek, Kuvvetli} ise

P(X | Evet) = P(Evet) * P(H_Güneşli | Evet) * P(S_Soğuk | Evet) * P(R_Kuvvetli | Evet) * P(N_Yüksek | Evet)

P(X | Evet) = (9/14)*(2/9)*(1/9)*(3/9)=(1/7)*(1/27)=1/189=0.053

P(X | Hayır) = P(Hayır) * P(H_Güneşli | Hayır) * P(S_Soğuk | Hayır) * P(R_Kuvvetli | Hayır) * P(N_Yüksek | Hayır)

P(X | Hayır) = (5/14)* (3/5)*(1/5)*(3/5)*(4/5)=(3/14)(12/125)=18/875=0.0206

5.6. Rassal Orman Modeli

Rastgele ormanlar, denetimli bir öğrenme algoritmasıdır. Hem sınıflandırma hem de regresyon için kullanılabilir.

Karar ağaçları:

Rastgele orman modelinin yapı taşları oldukları için karar ağaçlarının bilinmesi gerekmektedir. Oldukça sezgisel yaklaşımlar içerir. Çoğu insanın hayatlarının bir noktasında bilerek ya da bilmeyerek bir karar ağacı kullandığına bahse girerim. Bir karar ağacının nasıl çalıştığını bir örnek üzerinden anlamak muhtemelen çok daha kolaydır.

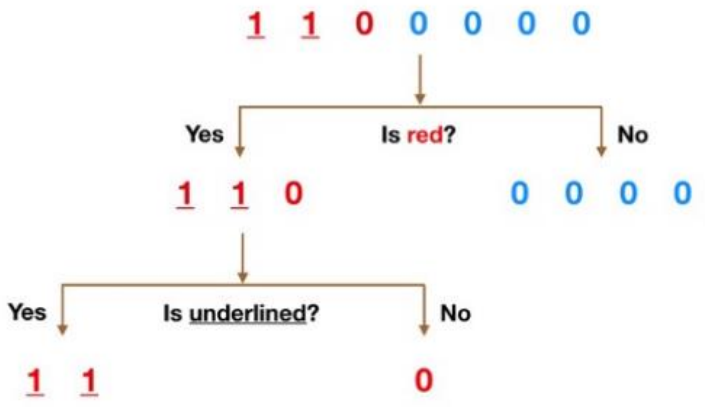

Veri setimizin soldaki şeklin üstündeki sayılardan oluştuğunu hayal edin. İki 1 ve beş 0'ımız var (1'ler ve 0'lar sınıflarımızdır) ve özelliklerini kullanarak sınıfları ayırmak istiyoruz. Özellikler renklidir (kırmızıya karşı mavi) ve gözlemin altı çizili olup olmadığıdır. Peki bunu nasıl yapabiliriz?

Renk, 0'lardan biri hariç tümü mavi olduğu için, ayrılması oldukça bariz bir özellik gibi görünüyor. Böylece "Kırmızı mı?" Sorusunu kullanabiliriz. ilk düğümümüzü ayırmak için. Bir ağaçtaki bir düğümü, yolun ikiye ayrıldığı nokta olarak düşünebilirsiniz - kriterleri karşılayan gözlemler Evet dalına ve Hayır dalına inmeyenler.

Hayır dalı (blues) artık 0'lardır, bu yüzden orada işimiz bitti, ancak Evet şubemiz yine de bölünebilir. Şimdi ikinci özelliği kullanıp "Altı çizili mi?" Diye sorabiliriz. ikinci bir bölme yapmak için.

Altı çizili iki 1, Evet alt dalına gider ve altı çizilmemiş 0, sağ alt daldan aşağı gider ve hepimiz işimiz biter. Karar ağacımız, verileri mükemmel bir şekilde bölmek için iki özelliği kullanabildi. Açıkçası gerçek hayatta verilerimiz bu kadar net olmayacak, ancak bir karar ağacının kullandığı mantık aynı kalacak. Her düğümde sorulacak - Hangi özellik, eldeki gözlemleri, ortaya çıkan grupların olabildiğince farklı olacağı şekilde (ve ortaya çıkan her alt grubun üyeleri mümkün olduğunca birbirine benzeyecek şekilde) bölmeme izin verir?

Ağaç tabanlı algoritmalar, denetimli öğrenme problemlerini çözmek için kullanılan popüler makine öğrenme yöntemleridir. Ağaç tabanlı algoritmalar, yüksek doğruluk , kararlılık ve yorumlama kolaylığına sahip tahminler üretirler .

Bir karar ağacı temel olarak 4 ana düğüm (node)'den oluşur: Kök (root) düğüm, iç düğümler ve yaprak (leaf) düğümlerden oluşur. Bu düğümler dallar aracılığıyla birbirine bağlanır.

Karar ağaçlarında problem sınıfına göre veri türleri:

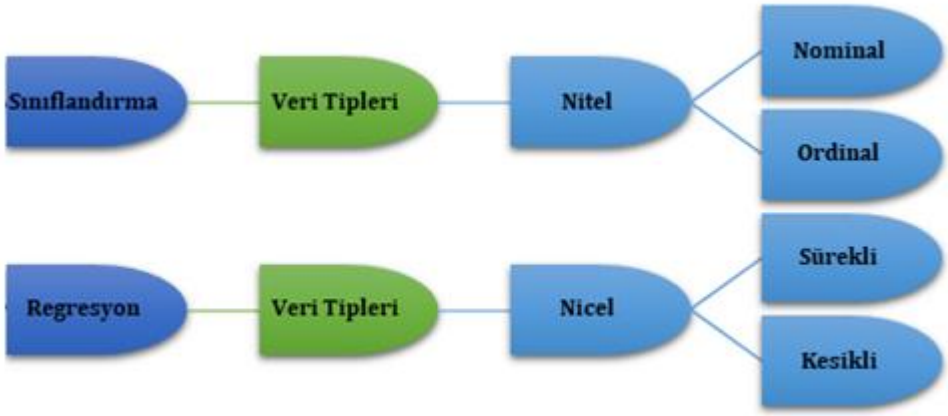

Karar ağaçlarında kurulan modelin veya modellerin performansını değerlendirmede kullanılan hata metrikleri ise genel itibariyle aşağıdaki şekilde verilmiştir. Şekilde yer verilen hata metrikleri gerek makine öğrenme gerekse derin öğrenme modellerinin performansının testinde sıklıkla kullanılmaktadır.

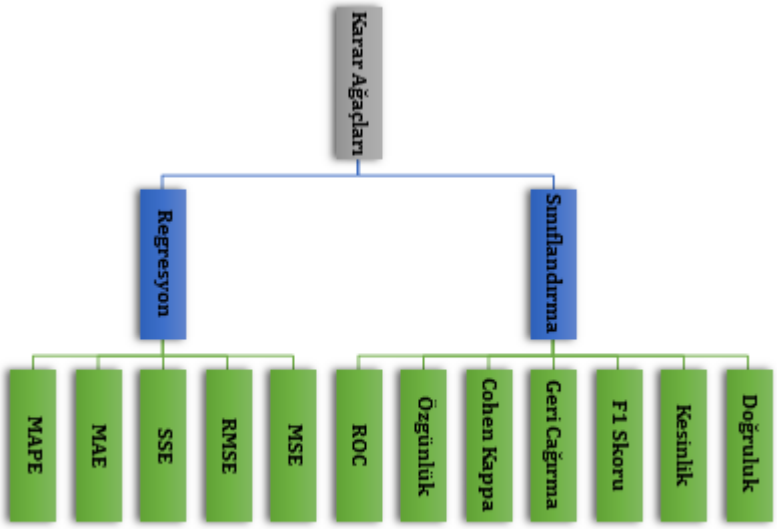

Farklı ağaç tabanlı algoritmalar vardır:

- Karar ağaçları
- Rastgele Orman
- Gradyan Artırma
- Torbalama (Bootstrap Toplama)

Rastgele Orman Sınıflandırıcısı:

Rastgele orman, adından da anlaşılacağı gibi, bir topluluk olarak çalışan çok sayıda bireysel karar ağacından oluşur. Rastgele ormandaki her bir ağaç bir sınıf tahmini verir ve en çok oyu alan sınıf, modelimizin öngörüsü haline gelir (aşağıdaki şekle bakın).

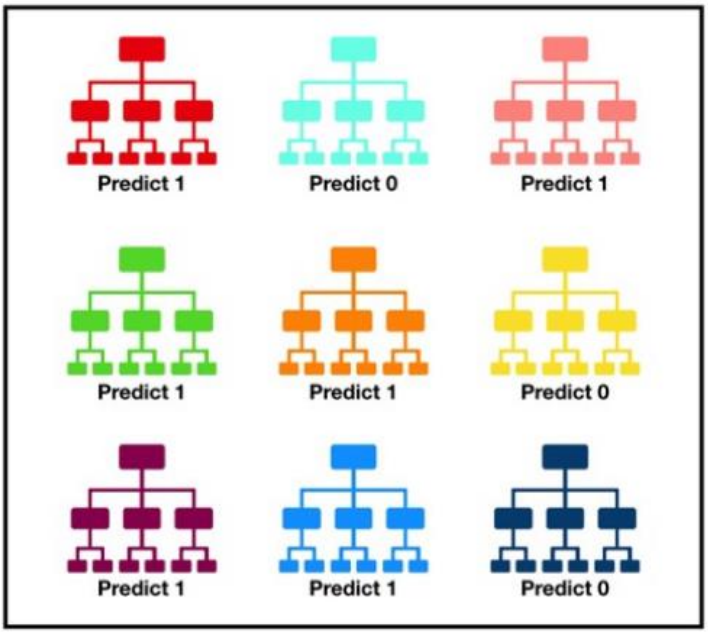

Tally: Six 1s and Three 0s

Rastgele ormanın ardındaki temel kavram basit ama güçlü bir kavramdır - kalabalıkların bilgeliği.

Rastgele orman, en popüler ağaç tabanlı denetimli öğrenme algoritmalarından biridir. Aynı zamanda en esnek ve kullanımı kolaydır. Karar ağaçlarının en büyük problemlerinden biri aşırı öğrenme-veriyi ezberlemedir (overfitting). Rassal orman modeli bu problemi çözmek için hem veri setinden hem de öznitelik setinden rassal olarak 10'larca 100'lerce farklı alt-setler seçilir ve bunlar eğitilir. Bu yöntemle 100'lerce karar ağacı oluşturulur ve her bir karar ağacı bireysel olarak tahminde bulunur. Günün sonunda problem regresyonsa karar ağaçlarının tahminlerinin ortalaması problem sınıflandırma ise tahminler arasında en çok oy alan seçilir.

Rastgele Orman denetimli bir öğrenme algoritmasıdır. Rastgele orman, yüzlerce karar ağaçları ve sonra her bir karar ağacını farklı bir gözlem örneği üzerinde eğitir. Zaten adından da anlaşılacağı gibi, bir orman oluşturur ve bunu bir şekilde rastgele yapar. Kurduğu "orman", çoğu zaman "torbalama (bagging) " yöntemiyle eğitilen karar ağaçları topluluğudur. Rastgele orman, birden fazla karar ağacını oluşturur ve daha doğru ve istikrarlı bir tahmin elde etmek için onları birleştirir. Rastgele ormanın büyük bir avantajı, mevcut makine öğrenmesi sistemlerinin çoğunu oluşturan hem sınıflandırma hem de regresyon problemleri için kullanılabilmesidir.

Rastgele orman, farklı ağaçlardan tahmin sonuçlarının ortalamasını alarak tek bir karar ağacından daha yüksek bir tahmin doğruluğu verir.

Rastgele orman algoritması, veri kümesinde önemli olan özelliklerin bulunmasına yardımcı olabilir. Bir veri kümesindeki önemli özellikleri seçen Boruta algoritmasının temelinde yer alır. Rastgele orman, çeşitli uygulamalarda, örneğin e-ticarette müşterilere farklı ürünlerin tavsiyelerini sağlamak için kullanılılır. Tıpta, hastanın tıbbi kaydını analiz ederek hastanın hastalığını tanımlamak için rastgele bir orman algoritması kullanılabilir. Ayrıca bankacılık sektöründe müşterinin dolandırıcı veya meşru olup olmadığını kolayca tespit etmek için kullanılabilir.

Rastgele orman algoritması aşağıdaki adımları tamamlayarak çalışır:
Adım 1 : Algoritma, sağlanan veri kümesinden rastgele örnekler seçer.
Adım 2: Algoritma, seçilen her örnek için bir karar ağacı oluşturur. Ardından oluşturulan her karar ağacından bir tahmin sonucu alır.
Adım 3: Daha sonra tahmin edilen her sonuç için seçim yapılacaktır. Bir sınıflandırma problemind regresyon problemi için ortalama kullanacaktır .
Adım 4 : Son olarak, algoritma, son tahmin olarak en çok oylanan tahmin sonucunu seçecektir.

Rastgele Orman, ağaçları büyütürken, modele ek rasgelelik katıyor. Bir düğümü parçalara ayırırken en önemli özelliği aramak yerine, rastgele bir özellik alt kümesi arasında en iyi özelliği arar. Bu, genellikle daha iyi bir modelle sonuçlanan geniş bir çeşitlilikle sonuçlanır.

Bu nedenle, Rastgele Ormanda, bir düğümün bölünmesi için algoritma tarafından özelliklerin sadece rastgele bir alt kümesi dikkate alınır. Hatta mümkün olan en iyi eşikleri (normal bir karar ağacı gibi) aramak yerine, her özellik için rastgele eşikler kullanılarak ağaçlar daha rastgele yapılabilir.

Bir tatil gezisine karar vermek isteyen bir adam düşünün. Arkadaşlarına geçmişte gittiğini yerle ilgili kendisine sorular sormalarını ve tavsiyede bulunmasını ister. Arkadaşları, sorduklara soruların cevaplarını kullanarak ne tavsiye edilmesi gerektiğine dair kararını yönlendirmek için kurallar yaratırlar. Ardından arkadaşlarından daha fazla tavsiyede bulunmasını tavsiye eder ve ona farklı sorular sormalarını ister. Daha sonra, kendisine en çok tavsiye edilen yeri seçer. Bu, Rastgele Orman algoritması yaklaşımının tipik bir örneğidir.

Örneğin bir film izlemek istiyorsunuz ve karar veremiyorsunuz. Bir arkadaşınızı ararsanız ve o size tercih ettiğiniz film türü, süre, yıl, oyuncu-yönetmen, hollywood-alternatif vs. soru setinden çeşitli sorularla daha önce izlediğiniz filmlere (training set) göre bir tahminde bulunursa bu karar ağacı olur. Eğer 20 arkadaşınız bu soru setinden farklı sorular seçip verdiğiniz cevaplara göre tavsiyede bulunursa ve siz en çok tavsiye edilen filmi seçerseniz bu rassal orman olur.

Rastgele Orman algoritmasının bir başka büyük kalitesi, her bir özelliğin tahmin üzerindeki nispi önemini ölçmenin çok kolay olmasıdır. Sklearn, bu özelliği kullanan ağaç düğümlerinin, ormandaki tüm ağaçlar arasındaki kirliliği ne kadar azalttığına bakarak, bir özelliği ön planda tutan harika bir araç sağlar. Her bir özellik için bu skoru otomatik olarak eğitir ve sonuçları ölçeklendirir, böylece tüm önemlerin toplamı 1'e eşittir.

Bir karar ağacında her iç düğüm bir öznitelik üzerinde bir "testi" temsil eder (örn. bir para yatırma işleminin başa ya da kuyruklara mı dönüştüğü), her bir dal testin sonucunu temsil eder ve her bir yaprak düğümü bir sınıf etiketini temsil eder (tüm nitelikleri hesapladıktan sonra alınan karar). Çocukları olmayan bir düğüm bir yapraktır.

Özelliğin önemine bakarak, hangi özellikleri düşürmek istediğinize karar verebilirsiniz, çünkü bunlar tahmin sürecine yeterince katkıda bulunmaz. Bu önemlidir, çünkü makine öğreniminde genel bir kural, sahip olduğunuz daha fazla özellik olması, modelinizin aşırı uydurma ve tersi olma olasılığı daha yüksektir.

Karar Ağaçları ve Rastgele Ormanlar Arasındaki Fark:
Bir karar ağacında özelliklere ve etiketlere sahip bir eğitim veri seti girdiyseniz, tahminleri yapmak için kullanılacak bazı kurallar formüle edilir.

Örneğin, bir kişinin bir çevrimiçi reklama tıklayacağını tahmin etmek istiyorsanız, reklamı geçmişte tıklanan ve kararını açıklayan bazı özellikleri toplayabilirsiniz. Özellikleri ve etiketleri bir karar ağacına koyarsanız, bazı kurallar oluşturur. Sonra reklamın tıklanıp tıklanmayacağını tahmin edebilirsiniz. Buna karşılık, Rastgele Orman algoritması çeşitli karar ağaçları inşa etmek için gözlemleri ve özellikleri rastgele seçer ve sonuçların ortalamasını alır.

Bir başka farklılık da, "derin" karar ağaçlarının aşırı ısınmaktan muzdarip olmasıdır. Rastgele Orman, özelliklerin rastgele alt kümeleri oluşturarak ve bu alt kümeleri kullanarak daha küçük ağaçlar oluşturarak, çoğu zaman aşırı uydurmayı(overfitting) engeller. Daha sonra alt ağaçları birleştirir. Bunun her zaman çalışmadığını ve aynı zamanda rastgele ormanınızın kaç ağaç oluşturduğuna bağlı olarak hesaplamayı yavaşlattığını unutmayın.

1. Öngörücü Gücün Artırılması(Estimator)
En yüksek oyu almadan ya da tahminlerin ortalamalarını almadan önce algoritmanın oluşturduğu ağaç sayısı önemli bir parametredir. Genel olarak, daha yüksek sayıda ağaç performansı artırır ve tahminleri daha kararlı hale getirir, fakat aynı zamanda hesaplamayı da yavaşlatır.

Bir başka önemli parametre “max_features”, yani Random Forest’ın tek bir ağaçta denemesine izin verilen maksimum özellik sayısıdır. Sklearn belgelerinde açıklanan çeşitli seçenekler sunar.

Hız açısından konuşacağımız son önemli parametre, “min_sample_leaf” dir. Bu, adından da anlaşılacağı gibi, bir iç düğümü ayırmak için gereken minimum yaprak sayısını belirler.

2. Model Hızını Artırma

“N_jobs” hiperparametre, motora kaç tane işlemcinin kullanılmasına izin verildiğini söyler. 1 değeri varsa, yalnızca bir işlemci kullanabilir. “-1” değeri, sınır olmadığını gösterir.
“Random_state”, modelin çıkışını çoğaltılamaz hale getirir. Model, her zaman rastgele bir random_state değeri olduğunda ve aynı parametreler ve aynı eğitim verisi verilmişse, aynı sonuçları üretecektir.

Son olarak, rastgele bir ormanda çapraz doğrulama yöntemi olan “oob_score” (aynı zamanda oob örneklemesi olarak da adlandırılır) vardır. Bu örneklemede, verinin yaklaşık üçte biri modeli eğitmek için kullanılmamıştır ve performansını değerlendirmek için kullanılabilir. Bu numunelere bağ dışı örnekler denir. leave-one-cross-validasyon yöntemine çok benzer, ancak neredeyse hiçbir ek hesaplama yükü de beraberinde gelmiyor.

Avantajlar ve dezavantajlar:

Rassal orman modelinde farklı veri setleri üzerinde eğitim gerçekleştiği için varyans, diğer bir deyişle karar ağaçlarının en büyük problemlerinden olan overfitting azalır. Ayrıca bootstrap yöntemiyle oluşturulan alt-veri kümelerinde outlier bulunma şansını da düşürülmüş olunur.
Random forest modelinin diğer bir özelliği de özniteliklerin ne kadar önemli olduğunun belirtilmesidir. Bir özniteliğin önemli olması demek o özniteliğin bağımlı değişkendeki varyansın açıklanmasına ne kadar katkı yaptığıyla alakalıdır. Random forest algoritmasında x sayıda öznitelik verilip en faydalı y tanesinin seçilmesi istenebilir ve istenirse bu bilgi istenen başka bir modelde kullanabilir.

Rastgele Ormanların bir avantajı hem regresyon hem de sınıflandırma görevleri için kullanılabileceği ve girdi özelliklerine verdiği göreceli önemi görmenin kolay olmasıdır.
Rastgele Orman ayrıca çok kullanışlı ve kullanımı kolay bir algoritma olarak kabul edilir, çünkü varsayılan hiperparametreler genellikle iyi bir tahmin sonucu oluşturur.

Hiperparametre sayısı da o kadar yüksek değildir ve anlaşılması kolaydır.

Rastgele Ormanın ana sınırlaması, çok sayıda ağacın algoritmayı gerçek zamanlı tahminler için yavaş ve etkisiz hale getirebilmesidir. Genel olarak, bu algoritmalar hızlı bir şekilde eğitilebilir, ancak bir kez eğitildiklerinde tahminler oluşturmak için oldukça yavaştır. Daha

doğru bir tahmin, daha yavaş bir modelle sonuçlanan daha fazla ağaç gerektirir. Gerçek dünyadaki uygulamaların çoğunda Rastgele Orman algoritması yeterince hızlıdır, ancak çalışma zamanı performansının önemli olduğu ve diğer yaklaşımların tercih edilebileceği durumlar olabilir.

Ve tabii ki Rastgele Orman, prediktif bir modelleme aracıdır ve açıklayıcı bir araç değildir. Bu, verilerinizdeki ilişkilerin bir tanımını arıyorsanız, başka yaklaşımların tercih edileceği anlamına gelir.

Rastgele Orman algoritması, Bankacılık, Borsa, Tıp ve E-Ticaret gibi birçok farklı alanda kullanılmaktadır. Bankacılıkta, örneğin bankanın hizmetlerini diğerlerinden daha sık kullanacak müşterileri tespit etmek ve borçlarını zaman içerisinde geri ödemek için kullanılır. Bu alanda bankayı dolandırmak isteyen dolandırıcılık müşterilerini tespit etmek için de kullanılır. Finansmanda, bir hissenin gelecekteki davranışını belirlemek için kullanılır. Sağlık alanında, tıptaki bileşenlerin doğru kombinasyonunu tanımlamak ve hastalıkları tanımlamak için bir hastanın tıbbi geçmişini analiz etmek için kullanılır. Ve son olarak, E-ticaret'te Rastgele Orman, bir müşterinin ürünü gerçekten beğenip beğenmeyeceğini belirlemek için kullanılır.

Rastgele Orman, model geliştirme sürecinde erken eğitim için ve nasıl performans gösterdiğini görmek için basit bir algoritmadır ve sadeliği nedeniyle "kötü" bir Rastgele Orman oluşturmak zordur. Kısa bir süre içinde bir model geliştirmeniz gerekiyorsa, bu algoritma da mükemmel bir seçimdir. Bunun üzerine, özelliklerine verdiğiniz önemin oldukça iyi bir göstergesidir.

Rastgele Ormanlar da performans açısından yenmek için çok zor. Elbette, sinir ağları gibi her zaman daha iyi performans gösterebilecek bir model bulabilirsin, ama bunlar genellikle gelişimde daha fazla zaman alırlar. Üstelik, ikili, kategorik ve sayısal gibi bir çok farklı özellik tipini de kullanabilirler.

Genel olarak, Rastgele Orman, sınırlamaları olmasına rağmen (çoğunlukla) hızlı, basit ve esnek bir araçtır.

Modeli uygulama süreci:

1) Sütunlar isimlendirilir veri tipleri ve eksik veri olup olmadığı kontrol edilir. Modeldeki hedef değişkenin dağılımına bakılır ve veri setinin geri kalanından ayırılır.
2) Veri tipi 'object' olan sütunlar seçilir. Bu sütunlar yine o sütunun mode() değeriyle doldurulur.
3) Makine öğrenmesi modelleri kategorik değişkenleri algılayamadığı için 'object' tipindeki değişkenleri one-hot-encoding yöntemiyle 0 ve 1'lere ayırılır.
4) Modeli kurulmaya hazır şimdi standart modelleme süreçleri uygulanır.

5) Veriyi eğitim ve test alt-veri gruplarına ayırılır.
6) Karar ağacı modeli oluşturulur.
7) Modeli eğitim verisi 'fit' edilir.
8) Görülmeyen test verisi modele verilip tahminde bulunulur.
9) Modelin başarı metrikleri: Confusion matrix, Modelin başarı metrikleri: Precision, recall, f1-score.
10) Karar ağaçlarından birini görselleştiriir.
11) Modelin özniteliklerinin önem sıralama analiz edilir.

Veri tiplerini kontrol etme/düzeltme:

- Açıklayıcı veri analizi ve görselleştirme.
- Eksik verileri tahmin etme/veri atama.
- Kategori tipindeki verileri one-hot encoding ile nümerik formata çevirme.
- Veri setini eğitim ve test veri-setlerine ayırma.
- Modeli eğitme ve test verisi üzerinde tahmin yapma.
- Sınıflandırma başarı metriklerine bakma.
- Karar ağacını görselleştirme.
- Modelin yaptığı öznitelik sıralamasını görselleştirme.

İlişkisiz sonuçların neden bu kadar büyük olduğuna dair bir örnek:

Bir sayı üretmek için tekdüze dağıtılmış rasgele sayı üreteci kullanılsın. Oluşturulan sayı 40'tan büyük veya ona eşitse, kazanılsın (yani% 60 zafer şansınız olur) ve size biraz para ödensin. 40'ın altındaysa kaybedilsin, kaybeden aynı miktarı ödersin. Şimdi size aşağıdaki seçenekler sunulmaktadır. Şunlardan birini yapılabilinir: Oyun 1 - 100 kez oynayın, her seferinde 1 $ bahis yapın.
Oyun 2 - 10 kez oynayın, her seferinde 10 $ bahis yapın.
Oyun 3 - bir kez oynayarak 100 $ bahis yapın.

Hangisini seçerdin? Her oyunun beklenen değeri aynıdır:
Beklenen Değer Oyunu 1 = (0.60 * 1 + 0.40 * -1) * 100 = 20
Beklenen Değer Oyunu 2 = (0.60 * 10 + 0.40 * -10) * 10 = 20
Beklenen Değer Oyunu 3 = 0.60 * 100 + 0.40 * -100 = 20

Dağılımlar ne olacak? Sonuçları bir Monte Carlo simülasyonu ile görselleştirildiğinde (her oyun türü için 10.000 simülasyon çalıştırılacak; örneğin, 1. Oyundaki 100 oyunun 10.000 katı simüle edilacak). Aşağıdakii tabloya bir göz atın - şimdi hangi oyunu seçerdiniz? Beklenen değerler aynı olsa bile, sonuç dağılımları, pozitif ve dardan (mavi) ikiliye (pembe) doğru büyük ölçüde farklıdır.

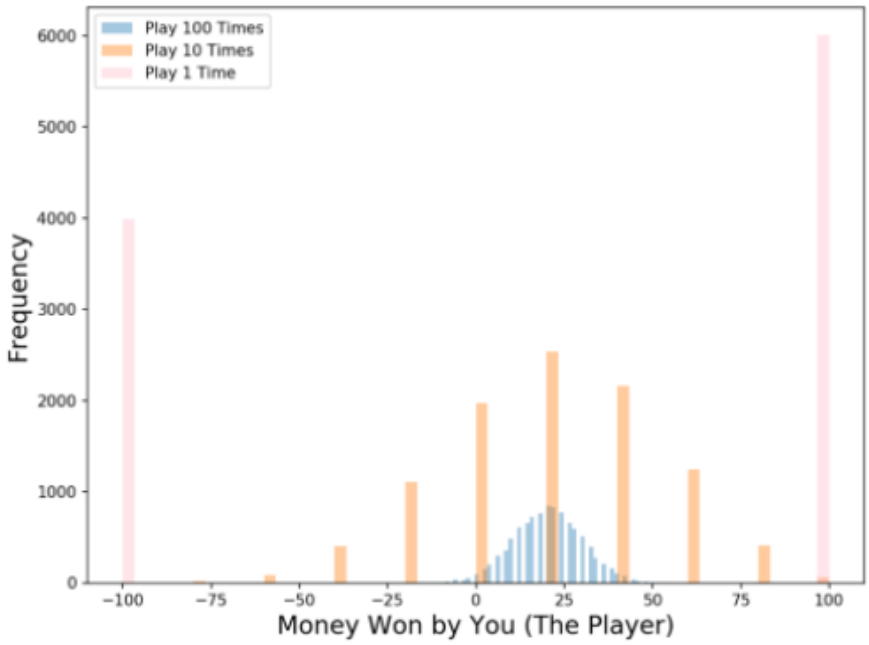

Outcome Distribution of 10,000 Simulations for each Game

Oyun 1 (100 kez oynadığımız yer), biraz para kazanmak için en iyi şansı sunuyor - yürüttüğüm 10.000 simülasyondan% 97'sinde para kazanıyorsunuz! Oyun 2'de (10 kez oynadığımız yerde) simülasyonların% 63'ünde para kazanırsınız, ciddi bir düşüş (ve para kaybetme olasılığınızda ciddi bir artış). Ve sadece bir kez oynadığımız 3. Oyun, beklendiği gibi simülasyonların% 60'ında para kazanıyorsunuz.

Dolayısıyla, oyunlar aynı beklenen değeri paylaşsa da, sonuç dağılımları tamamen farklıdır. 100 $ 'lık bahsimizi farklı oyunlara ne kadar çok bölersek, para kazanacağımıza o kadar güvenebiliriz. Daha önce de belirtildiği gibi, bu işe yarar çünkü her oyun diğerlerinden bağımsızdır.

Rastgele orman aynıdır - her ağaç, önceki oyunumuzdaki bir oyun gibidir. Daha fazla oynadığımızda para kazanma şansımızın nasıl arttığını gördük. Benzer şekilde, rastgele bir orman modeliyle, modelimizdeki ilişkisiz ağaçların sayısı ile doğru tahminler yapma şansımız artar.

Modellerin birbirini çeşitlendirmesini sağlamak:
Öyleyse rastgele orman, her bir ağacın davranışının modeldeki diğer ağaçlardan herhangi birinin davranışıyla çok fazla ilişkili olmamasını nasıl sağlar?

Aşağıdaki iki yöntemi kullanır:
Torbalama (Bootstrap Aggregation) - Karar ağaçları, eğitildikleri verilere karşı çok hassastır - eğitim setinde yapılan küçük değişiklikler, önemli ölçüde farklı ağaç yapılarına neden olabilir.

Rastgele orman, her bir ağacın veri kümesinden değiştirilerek rasgele örneklemesine izin vererek bundan yararlanır ve farklı ağaçlarla sonuçlanır. Bu işlem torbalama olarak bilinir.

Torbalama ile eğitim verilerini daha küçük parçalara ayırmadığımıza ve her ağacı farklı bir yığın üzerinde eğitmediğimize dikkat edin. Bunun yerine, N büyüklüğünde bir örneğimiz varsa, yine de her ağaca N boyutunda bir eğitim seti besliyoruz (aksi belirtilmedikçe). Ancak orijinal eğitim verileri yerine, değiştirilmiş N boyutunda rastgele bir örnek alıyoruz. Örneğin, eğitim verilerimiz [1, 2, 3, 4, 5, 6] ise, ağaçlarımızdan birine aşağıdaki listeyi verebiliriz [1, 2, 2, 3, 6, 6]. Her iki listenin de altı uzunluğunda olduğuna ve "2" ile "6" nın ikisinin de ağacımıza verdiğimiz rastgele seçilmiş eğitim verilerinde tekrarlandığına dikkat edin (çünkü değiştirme ile örnekleme yapıyoruz).

Özellik Rastgeleliği:
Normal bir karar ağacında, bir düğümü bölme zamanı geldiğinde, mümkün olan her özelliği göz önünde bulundururuz ve sağ düğümdekilerle sol düğümdeki gözlemler arasında en fazla ayrımı yaratanı seçeriz. Bunun aksine, rastgele bir ormandaki her ağaç yalnızca rastgele bir özellik alt kümesinden seçim yapabilir. Bu, modeldeki ağaçlar arasında daha fazla çeşitliliği zorlar ve sonuçta ağaçlarda daha düşük korelasyon ve daha fazla çeşitlilik ile sonuçlanır.

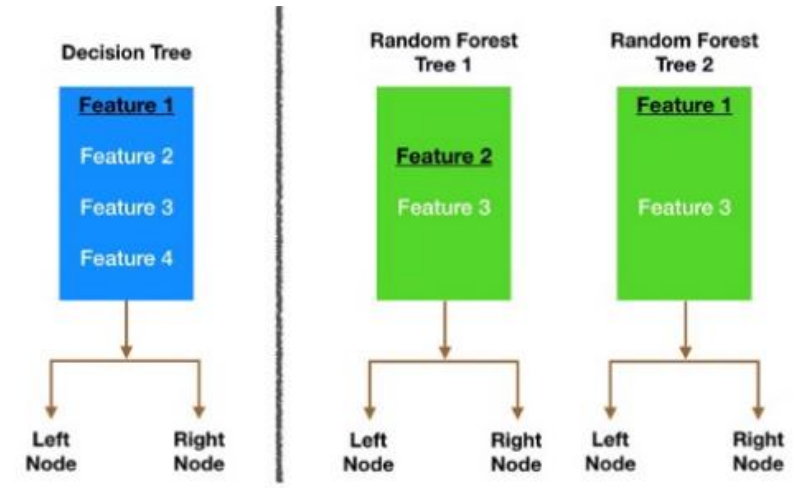

Node splitting in a random forest model is based on a random subset of features for each tree.

Görsel bir örnek üzerinden geçelim - yukarıdaki resimde, geleneksel karar ağacı (mavi), düğümü nasıl böleceğine karar verirken dört özelliğin tümünden seçim yapabilir. Verileri olabildiğince ayrılmış gruplara böldüğü için Özellik 1 (siyah ve altı çizili) ile devam etmeye karar verir. Şimdi rastgele ormanımıza bir göz atalım. Bu örnekte ormanın iki ağacını inceleyeceğiz. Rastgele Orman Ağacı 1'i kontrol ettiğimizde, düğüm bölme kararı için yalnızca Özellik 2 ve 3'ü (rastgele seçilir) dikkate alabileceğini görürüz. Geleneksel karar

ağacımızdan (mavi olarak) Özelliğin bölme için en iyi özellik olduğunu biliyoruz, ancak Ağaç 1, Özellik 1'i göremediğinden, Özellik 2'ye (siyah ve altı çizili) gitmek zorunda kalır. Öte yandan Ağaç 2, yalnızca Özellik 1 ve 3'ü görebilir, bu nedenle Özellik 1'i seçebilir. Dolayısıyla rastgele ormanımızda, yalnızca farklı veri kümeleri üzerinde eğitilen (torbalama sayesinde) değil, aynı zamanda karar vermek için farklı özellikler kullanan ağaçlarla karşılaşıyoruz. Ve bu, sevgili okuyucum, birbirlerini tamponlayan ve hatalarından koruyan ilişkisiz ağaçlar yaratır.

Rastgele orman, birçok karar ağacından oluşan bir sınıflandırma algoritmasıdır. Komite tarafından tahmin edilmesi herhangi bir ağaçtan daha doğru olan ilişkisiz bir ağaç ormanı yaratmaya çalışmak için her bir ağacı inşa ederken torbalama kullanır ve rastgelelik özelliğini kullanır. Rasgele ormanımızın doğru sınıf tahminleri yapabilmesi için neye ihtiyacımız var? En azından bir miktar tahmin gücüne sahip özelliklere ihtiyacımız var. Sonuçta, eğer içine çöp koyarsak, o zaman çöpü dışarı atarız. Ormanın ağaçları ve daha da önemlisi tahminlerinin ilintisiz olması (veya en azından birbirleriyle düşük korelasyonlara sahip olması) gerekir. Algoritmanın kendisi özellik rastgeleliği aracılığıyla bu düşük korelasyonları bizim için tasarlamaya çalışırken, seçtiğimiz özellikler ve seçtiğimiz hiper parametreler nihai korelasyonları da etkileyecektir.

6. Regresyon Algoritmaları

Değişkenler arasındaki ilişkiyi bulmaya çalıştığınızda regresyon yöntemi kullanılır. Makine Öğreniminde ve istatistiksel modellemede bu ilişki gelecekteki olayların sonucunu tahmin etmek için kullanılır. Sürekli değerleri tahmin etmek için regresyon algoritmaları kullanılır.

Regresyon algoritmaları:

- Linear Regression
- Polynomial Regression
- Exponential Regression
- Logistic Regression
- Logarithmic Regression

Regresyon analizi, girdi değişkenleri ile çıktı arasındaki ilişkiyi tahmin etmek için çok çeşitli istatistiksel yöntemleri kapsar. En yaygın şekli, sıradan en küçük kareler gibi bir matematiksel kritere göre verilen verilere en iyi uyacak şekilde tek bir çizginin çizildiği doğrusal regresyondur.

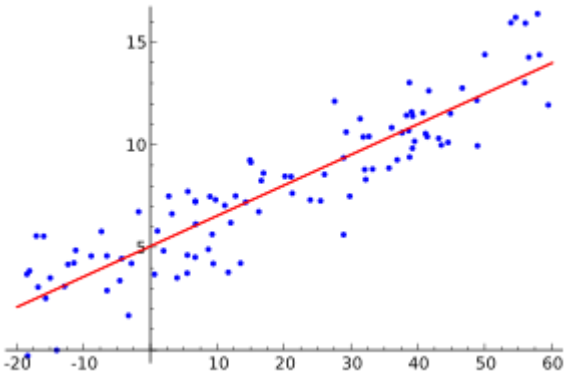

Makine öğrenmesinde bir modeli eğitmenin amacı, tüm örneklerde ortalama olarak düşük kayıplı bir eşik değer bulmaktır. Bu ortalama kareler hatası ile bulunur; farkların kareleri toplamının örnek sayısına bölümüdür. Regresyon algoritmaları, girdi özellikleri ile çıktı arasındaki ilişkiyi modelleyen istatistiksel bir yaklaşımdır. Regresyon algoritmasında veri kümesine ait kabul edilebilir birden fazla sayıda fonksiyon elde edilebilir. Bu durumda doğru fonksiyonu seçimde ortalama karelerin hatası göz önüne alınır.

Regresyon katsayıları bulunurken optimal kapsayıcı bir eğri fonksiyonu elde edilmelidir.
İpucu: Sınıflandırma yapılırken yüksek dereceli polinomlardan kaçınılmalıdır.

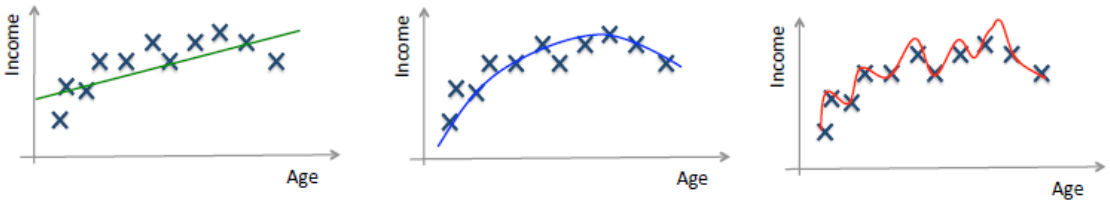

$$f(x) = \lambda_0 + \lambda_1 x \ \ldots \ (1)$$

$$f(x) = \lambda_0 + \lambda_1 x + \lambda_2 x^2 \ \ldots \ (2)$$

$$f(x) = \lambda_0 + \lambda_1 x + \lambda_2 x^2 + \lambda_3 x^3 + \lambda_4 x^4 \ \ldots \ (3)$$

Yeterli veri olduğunda, aşırı uyum sorununu önlemek için "İzotonik Regresyon" kullanılır.

6.1. Doğrusal Regrasyon

Doğrusal Regresyon Nedir? Makine Öğreniminde Nasıl Kullanılır?

Çoğu makine öğrenimi (ML) algoritması, başta istatistik olmak üzere çeşitli alanlardan ödünç alınmıştır. Modellerin daha iyi tahmin etmesine yardımcı olabilen her şey, sonunda makine öğreniminin bir parçası haline gelmektedir. Bu nedenle, doğrusal regresyonun hem istatistiksel hem de makine öğrenimi algoritması olduğunu söylemek güvenlidir.

Doğrusal regresyon, veri bilimi ve makine öğreniminde kullanılan popüler ve karmaşık olmayan bir algoritmadır. Denetimli bir öğrenme algoritmasıdır ve değişkenler arasındaki matematiksel ilişkiyi incelemek için kullanılan en basit regresyon biçimidir.

Doğrusal regresyon nedir?

Doğrusal regresyon, değişkenler arasındaki ilişkiyi göstermeye çalışan istatistiksel bir yöntemdir. Farklı veri noktalarına bakar ve bir trend çizgisi çizer. Doğrusal regresyonun basit bir örneği, bir makine parçasını tamir etme maliyetinin zamanla arttığını bulmaktır.

Daha kesin olarak, bir bağımlı değişken ile bir dizi diğer bağımsız değişken arasındaki ilişkinin karakterini ve gücünü belirlemek için doğrusal regresyon kullanılır. Bir şirketin hisse senedi fiyatını tahmin etmek gibi tahminler yapmak için modeller oluşturmaya yardımcı olur.

Gözlemlenen veri kümesine doğrusal bir model uydurmaya çalışmadan önce, değişkenler arasında bir ilişki olup olmadığı değerlendirilmelidir. Elbette bu, bir değişkenin diğerine neden olduğu anlamına gelmez, ancak aralarında gözle görülür bir korelasyon olmalıdır.

Örneğin, daha yüksek üniversite notları mutlaka daha yüksek bir maaş paketi anlamına gelmez. Ancak iki değişken arasında bir ilişki olabilir.

Doğrusal terimi, bir çizgiye benzeyen veya çizgilerle ilgili anlamına gelir. Bir dağılım grafiği oluşturmak, açıklayıcı (bağımsız) ve bağımlı değişkenler arasındaki ilişkinin gücünü belirlemek için idealdir. Dağılım grafiği herhangi bir artan veya azalan eğilim göstermiyorsa, gözlemlenen değerlere doğrusal bir regresyon modeli uygulamak faydalı olmayabilir.

Korelasyon katsayıları, iki değişken arasındaki ilişkinin ne kadar güçlü olduğunu hesaplamak için kullanılır. Genellikle r ile gösterilir ve -1 ile 1 arasında bir değere sahiptir. Pozitif bir korelasyon katsayısı değeri, değişkenler arasında pozitif bir ilişkiyi gösterir. Aynı şekilde, negatif bir değer, değişkenler arasında negatif bir ilişkiyi gösterir.

İpucu: Regresyon analizini yalnızca korelasyon katsayısı pozitif veya negatif 0,50 veya üzerindeyse gerçekleştirilmelidir.
Çalışma süresi ile notlar arasındaki ilişkiye bakıyor olsaydınız, muhtemelen pozitif bir ilişki görürdünüz. Öte yandan, sosyal medyada geçirilen süre ile notlar arasındaki ilişkiye bakarsanız, büyük olasılıkla negatif bir ilişki görürsünüz.

Burada “notlar” bağımlı değişken, ders çalışmak veya sosyal medyada geçirilen süre ise bağımsız değişkendir. Bunun nedeni, notların çalışmak için ne kadar zaman harcadığınıza bağlı olmasıdır.

Hem dağılım grafiği hem de korelasyon katsayısı yoluyla değişkenler arasında (en azından) orta düzeyde bir korelasyon kurabilirseniz, söz konusu değişkenler bir tür doğrusal ilişkiye sahiptir.

Kısacası, doğrusal regresyon, gözlemlenen verilere doğrusal bir denklem uygulayarak iki değişken arasındaki ilişkiyi modellemeye çalışır. Doğrusal bir regresyon çizgisi, düz bir çizginin denklemi kullanılarak temsil edilebilir:

$y = mx + b$
Bu basit doğrusal regresyon denkleminde:

- y tahmini bağımlı değişkendir (veya çıktıdır)
- m, regresyon katsayısıdır (veya eğimdir)
- x, bağımsız değişkendir (veya girdidir)
- b sabittir (veya y-keseni üzerinde bir nokta)

Değişkenler arasındaki ilişkiyi bulmak, değerleri veya sonuçları tahmin etmeyi mümkün kılar. Başka bir deyişle, doğrusal regresyon, mevcut verilere dayalı olarak yeni değerlerin tahmin edilmesini mümkün kılar.

Bir örnek, alınan yağışa dayalı olarak mahsul verimini tahmin etmek olabilir. Bu durumda, yağış bağımsız değişkendir ve mahsul verimi (öngörülen değerler) bağımlı değişkendir.
Bağımsız değişkenler aynı zamanda yordayıcı değişkenler olarak da adlandırılır. Aynı şekilde, bağımlı değişkenler de yanıt değişkenleri olarak bilinir.

Lineer regresyonda anahtar terminolojiler

Doğrusal regresyon analizini anlamak, bir dizi yeni terime aşina olmak anlamına da gelebilir. İstatistik veya makine öğrenimi dünyasına yeni adım attıysanız, bu terminolojileri adil bir şekilde anlamanız önemli olacaktır.

- **Değişken (Variable):** Sayılabilen veya ölçülebilen herhangi bir sayı, nicelik veya özelliktir. Veri öğesi olarak da adlandırılır. Gelir, yaş, hız ve cinsiyet örnek olarak verilebilir.
- **Katsayı (Coefficient):** Yanındaki değişkenle çarpılan bir sayıdır (genellikle bir tam sayıdır). Örneğin, 7x'te 7 sayısı katsayıdır. y=a x + b, a ve b katsayıdır, x: bağımsız değişken, y ise bağımlı değşkendir.
- **Aykırı Değerler (Outliers):** Bunlar, diğerlerinden önemli ölçüde farklı olan veri noktalarıdır.
- **Kovaryans (Covariance):** İki değişken arasındaki doğrusal ilişkinin yönü. Başka bir deyişle, iki değişkenin doğrusal olarak ilişkili olma derecesini hesaplar.
- **Çok değişkenli (Multivariate):** Tek bir sonuçla sonuçlanan iki veya daha fazla bağımsız değişkenlerin dahil edilmesi anlamına gelir.
- **Artıklar (Residuals):** Bağımlı değişkenin gözlemlenen ve tahmin edilen değerleri arasındaki fark.

- **Değişkenlik (Variability):** Tutarlılığın olmaması veya bir dağılımın ne ölçüde sıkıştırıldığı veya esnetildiği.
- **Doğrusallık (Linearity):** Orantılılıkla yakından ilgili olan ve grafiksel olarak düz bir çizgi olarak gösterilebilen bir matematiksel ilişkinin özelliği.
- **Doğrusal fonksiyon (Linear function):** Grafiği düz bir çizgi olan fonksiyondur.
- **Doğrusallık (Collinearity):** Bir regresyon modelinde doğrusal bir ilişki sergileyecek şekilde bağımsız değişkenler arasındaki korelasyon.
- **Standart sapma (Standard deviation - SD):** Bir veri kümesinin ortalamasına göre dağılımının bir ölçüsüdür. Başka bir deyişle, sayıların ne kadar dağıldığının bir ölçüsüdür.
- **Standart hata (Standard error - SE):** İstatistiksel bir örneklem popülasyonunun yaklaşık SD'si. Değişkenliği ölçmek için kullanılır.

Doğrusal regresyon türleri

İki tür doğrusal regresyon vardır: basit doğrusal regresyon ve çoklu doğrusal regresyon.

Basit doğrusal regresyon yöntemi, tek bir bağımsız değişken ile buna karşılık gelen bir bağımlı değişken arasındaki ilişkiyi bulmaya çalışır. Bağımsız değişken girdidir ve karşılık gelen bağımlı değişken çıktıdır. İpucu: Lineer regresyonu Python, R, MATLAB ve Excel gibi çeşitli programlama dillerinde ve ortamlarında uygulayabilirsiniz.

Çoklu doğrusal regresyon yöntemi, iki veya daha fazla bağımsız değişken ile bunlara karşılık gelen bağımlı değişken arasındaki ilişkiyi bulmaya çalışır. Polinom regresyon adı verilen özel bir çoklu doğrusal regresyon durumu da vardır.

Basit bir şekilde ifade etmek gerekirse, basit bir doğrusal regresyon modelinde yalnızca tek bir bağımsız değişken bulunurken, çoklu bir doğrusal regresyon modelinde iki veya daha fazla bağımsız değişken olacaktır. Ve evet, oldukça karmaşık veri analizi için kullanılan başka doğrusal olmayan regresyon yöntemleri de var.

Doğrusal regresyon, belirli bir bağımsız değişken seti için sürekli bağımlı değişkeni tahmin ederken, lojistik regresyon kategorik bağımlı değişkeni tahmin eder. Her ikisi de denetimli öğrenme yöntemleridir. Ancak regresyon problemlerini çözmek için lineer regresyon kullanılırken, sınıflandırma problemlerini çözmek için lojistik regresyon kullanılır.

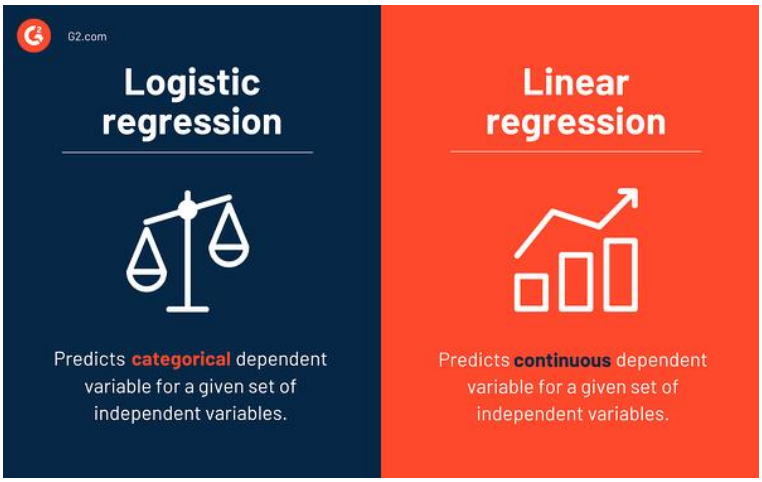

Elbette lojistik regresyon, regresyon problemlerini çözebilir, ancak esas olarak sınıflandırma problemlerinde kullanılır. Çıktısı yalnızca 0 veya 1 olabilir. İki sınıf arasındaki olasılıkları belirlemeniz veya başka bir deyişle bir olayın olasılığını hesaplamanız gereken durumlarda değerlidir. Örneğin, bugün yağmur yağıp yağmayacağını tahmin etmek için lojistik regresyon kullanılabilir.

Doğrusal regresyon varsayımları:

Değişkenler arasındaki ilişkiyi modellemek için doğrusal regresyon kullanırken birkaç varsayımda bulunuyoruz. Varsayımlar, tahminlerde bulunmak için bir model kullanmadan önce karşılanması gereken gerekli koşullardır.

Doğrusal regresyon modelleriyle ilgili genellikle dört varsayım vardır:

- Doğrusal ilişki: Bağımsız değişken x ile bağımlı değişken y arasında doğrusal bir ilişki vardır.
- Bağımsızlık: Artıklar bağımsızdır. Zaman serisi verilerinde ardışık artıklar arasında bir ilişki yoktur.
- Eş varyans: Artıklar tüm seviyelerde eşit varyansa sahiptir.
- Normallik: Artıklar normal dağılır.

Doğrusal regresyon modellerini çözme yöntemleri:

Makine öğreniminde veya istatistik dilinde, doğrusal bir regresyon modeli öğrenmek, mevcut verileri kullanarak katsayıların değerlerini tahmin etmek anlamına gelir. Doğrusal bir regresyon modelini daha verimli hale getirmek için çeşitli yöntemler uygulanabilir.

İpucu: Tekdüze görevleri ortadan kaldırmak ve doğru tahminler yapmak için makine öğrenimi yazılımını kullanılır. Farklılıklarını ve takaslarını anlamak için doğrusal regresyon modellerini çözmek için kullanılan farklı tekniklere bakılmalıdır.

Basit doğrusal regresyon:
Daha önce de belirtildiği gibi, basit doğrusal regresyonda tek bir girdi veya bir bağımsız değişken ve bir bağımlı değişken vardır. Sürekli doğada oldukları göz önüne alındığında, iki değişken arasındaki en iyi ilişkiyi bulmak için kullanılır. Örneğin, tüketilen kalorilere göre kazanılan kilo miktarını tahmin etmek için kullanılabilir.

Sıradan en küçük kareler regresyonu, birden fazla bağımsız değişken veya girdi olduğunda katsayıların değerini tahmin etmenin başka bir yöntemidir. Doğrusal regresyonu çözmek için en yaygın yaklaşımlardan biridir ve normal denklem olarak da bilinir.

Bu prosedür kare artıkların toplamını en aza indirmeye çalışır. Verileri bir matris olarak ele alır ve her katsayı için en uygun değerleri belirlemek için doğrusal cebir işlemlerini kullanır. Tabii ki, bu yöntem ancak tüm verilere erişimimiz varsa uygulanabilir ve ayrıca verileri sığdırmak için yeterli bellek olmalıdır.

Gradyan iniş, doğrusal regresyon problemlerini çözmek için en kolay ve yaygın olarak kullanılan yöntemlerden biridir. Bir veya daha fazla girdi olduğunda kullanışlıdır ve modelin hatasını yinelemeli olarak en aza indirerek katsayıların değerini optimize etmeyi içerir.
Gradyan iniş, her katsayı için rastgele değerlerle başlar. Her giriş ve çıkış değeri çifti için, kareleri alınmış hataların toplamı hesaplanır. Öğrenme oranı olarak bir ölçek faktörü kullanır ve her katsayı hatayı en aza indirecek yönde güncellenir.

İşlem, daha fazla iyileştirme mümkün olmayana veya minimum kareler toplamına ulaşılana kadar tekrarlanır. Gradyan iniş, belleğe sığmayan çok sayıda satır ve sütun içeren büyük bir veri kümesi olduğunda yardımcı olur.

Düzenlileştirme (Regularization), bir modelin hata karelerinin toplamını en aza indirmeye çalışan ve aynı zamanda modelin karmaşıklığını azaltan bir yöntemdir. Sıradan en küçük kareler yöntemini kullanarak kareleri alınmış hataların toplamını azaltır.

Kement regresyonu ve sırt regresyonu (Lasso regression and ridge regression), lineer regresyonda düzenlileştirmenin iki ünlü örneğidir. Bu yöntemler, bağımsız değişkenlerde eşdoğrusallık olduğunda değerlidir.

Adam'ın yöntemi (Adam’s method):

Uyarlanabilir moment tahmini veya ADAM, derin öğrenmede kullanılan bir optimizasyon algoritmasıdır. Gürültülü veriler üzerinde iyi performans gösteren yinelemeli bir algoritmadır. Uygulaması kolaydır, hesaplama açısından verimlidir ve minimum bellek gereksinimlerine sahiptir.

ADAM, iki gradyan iniş algoritmasını birleştirir - kök ortalama kare yayılma (**root mean square propagation - RMSprop)** ve uyarlanabilir gradyan iniş (adaptive gradient descent). ADAM, gradyanı hesaplamak için tüm veri kümesini kullanmak yerine, stokastik bir yaklaşım yapmak için rasgele seçilmiş alt kümeleri kullanır.

ADAM, çok sayıda parametre veya veri içeren problemler için uygundur. Ayrıca, bu optimizasyon yönteminde, hiperparametreler genellikle minimum ayar gerektirir ve sezgisel yorumlamaya sahiptir.

Tekil değer ayrışımı

Tekil değer ayrışımı veya SVD (Singular value decomposition), doğrusal regresyonda yaygın olarak kullanılan bir boyut indirgeme tekniğidir. Öğrenme algoritması için boyut sayısını azaltan bir ön işleme adımıdır.

SVD, bir matrisi diğer üç matrisin bir ürünü olarak parçalamayı içerir. Yüksek boyutlu veriler için uygundur ve küçük veri kümeleri için verimli ve kararlıdır. Kararlılığı nedeniyle, lineer regresyon için lineer denklemleri çözmek için en çok tercih edilen yaklaşımlardan biridir. Ancak, aykırı değerlere karşı hassastır ve büyük bir veri kümesiyle kararsız hale gelebilir.

Verileri doğrusal regresyon için hazırlama

Çoğu durumda gerçek dünya verileri eksiktir. Diğer herhangi bir makine öğrenimi modelinde olduğu gibi, veri hazırlama ve ön işleme, doğrusal regresyonda çok önemli bir süreçtir. Eksik değerler, hatalar, aykırı değerler, tutarsızlıklar ve öznitelik değerleri eksikliği olacaktır.

Eksik verileri hesaba katmanın ve daha güvenilir bir tahmin modeli oluşturmanın bazı yolları aşağıda verilmiştir.

- Doğrusal regresyon, yordayıcı (Tahmin edici) ve yanıt değişkenlerinin gürültülü olmadığını düşünür. Bu nedenle, çeşitli veri temizleme işlemleriyle gürültünün giderilmesi çok önemlidir. Mümkünse çıktı değişkenindeki aykırı değerler kaldırılmalıdır.
- Girdi ve çıktı değişkenleri Gauss dağılımına sahipse, lineer regresyon daha iyi tahminler yapacaktır.
- Girdi değişkenlerini normalleştirme veya standardizasyon kullanarak yeniden ölçeklendirilirse, doğrusal regresyon genellikle daha iyi tahminler yapar.
- Çok sayıda öznitelik varsa, verileri doğrusal bir ilişkiye sahip olacak şekilde dönüştürülmesi gerekir.

- Girdi değişkenleri yüksek oranda ilişkiliyse, doğrusal regresyon verileri aşacaktır. Bu gibi durumlarda, eşdoğrusallık kaldırılmalıdır.

Doğrusal regresyonun avantajları ve dezavantajları:
Doğrusal regresyon, anlaşılması en basit ve uygulaması en basit algoritmalardan biridir. Değişkenler arasındaki ilişkileri analiz etmek için harika bir araçtır.

Lineer regresyonun bazı dikkate değer avantajları şunlardır:

- Basitliği nedeniyle bir devam et algoritması.
- Fazla uydurmaya yatkın olmasına rağmen, boyut küçültme tekniklerinin yardımıyla önlenebilir.
- İyi yorumlanabilirliğe sahiptir.
- Doğrusal olarak ayrılabilir veri kümelerinde iyi performans gösterir.
- Alan karmaşıklığı düşüktür; bu nedenle, yüksek gecikmeli bir algoritmadır.

Bununla birlikte, pratik uygulamaların çoğu için genellikle doğrusal regresyon önerilmez. Bunun nedeni, değişkenler arasında doğrusal bir ilişki olduğunu varsayarak gerçek dünya sorunlarını aşırı basitleştirmesidir.

Lineer regresyonun bazı dezavantajları şunlardır:

- Aykırı değerlerin regresyon üzerinde olumsuz etkileri olabilir.
- Doğrusal bir modele uyması için değişkenler arasında doğrusal bir ilişki olması gerektiğinden, değişkenler arasında doğrusal bir ilişki olduğu varsayılır.
- Verilerin normal dağıldığını algılar
- Bağımsız ve bağımlı değişkenlerin ortalamaları arasındaki ilişkiye de bakar.
- Doğrusal regresyon, değişkenler arasındaki ilişkilerin tam bir açıklaması değildir.
- Değişkenler arasında yüksek bir korelasyonun varlığı, lineer bir modelin performansını önemli ölçüde etkileyebilir.

Önce gözlemle, sonra tahmin et
Doğrusal regresyonda, değişkenlerin doğrusal bir ilişkisi olup olmadığını değerlendirmek çok önemlidir. Bazı insanlar eğilime bakmadan tahminde bulunmaya çalışsa da, değişkenler arasında orta derecede güçlü bir korelasyon olduğundan emin olmak en iyisidir.

Daha önce bahsedildiği gibi, dağılım grafiğine ve korelasyon katsayısına bakmak mükemmel yöntemlerdir. Ve evet, korelasyon yüksek olsa bile dağılım grafiğine bakmak yine de daha iyidir. Kısacası, veriler görsel olarak doğrusalsa, doğrusal regresyon analizi yapılabilir.

Doğrusal regresyon, bağımlı bir değişkenin değerini tahmin etmenizi sağlarken, yeni veri noktalarını sınıflandıran veya komşularına bakarak değerlerini tahmin eden bir algoritma vardır. Buna k-en yakın komşu algoritması denir ve tembel bir öğrenme algoritmasıdır.

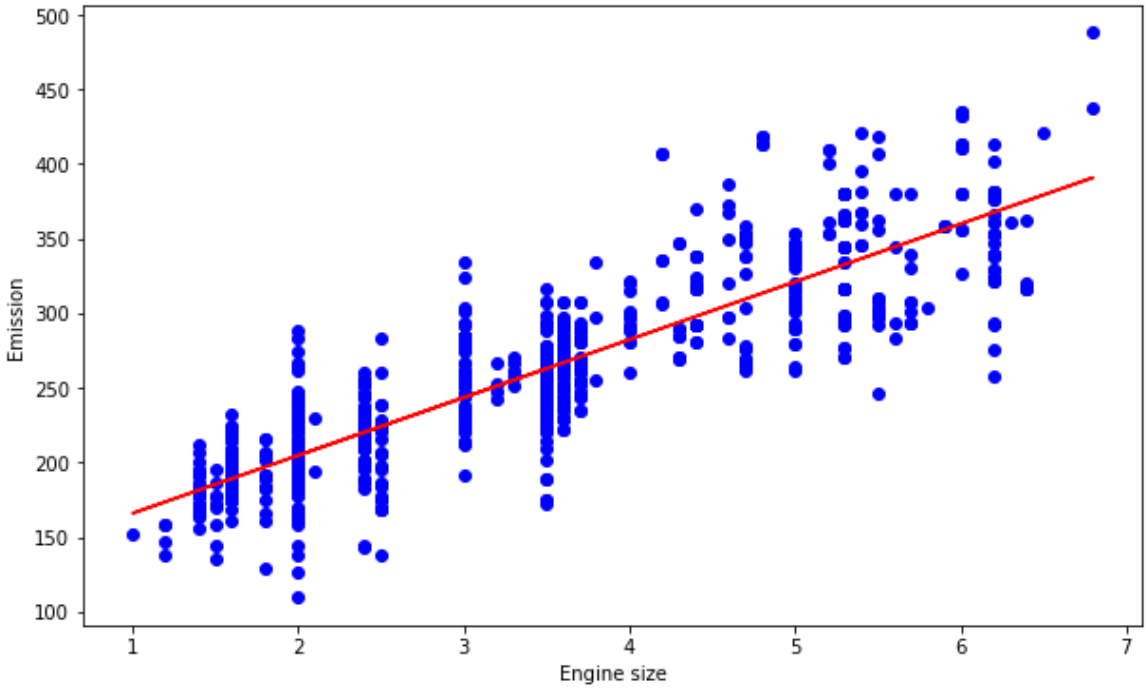

Grafik: Doğrusal Regresyon algoritması

Doğrusal regresyon, girdi özellikleri ile çıktı arasındaki ilişkiyi modelleyen istatistiksel bir yaklaşımdır. Girdi özelliklerine bağımsız değişkenler denir ve çıktıya bağımlı değişken adı verilir. Buradaki amacımız, girdi özelliklerine göre çıktının değerini, optimal katsayıları ile çarparak tahmin etmektir.

Doğrusal regresyonun gerçek hayattan bazı örnekleri:
(1) Ürün satışlarını tahmin etmek.
(2) Ekonomik büyümeyi tahmin etmek.
(3) Petrol fiyatlarını tahmin etmek.
(4) Yeni bir arabanın emisyonunu tahmin etmek.
(5) Not ortalamasının üniversiteye girişler üzerindeki etkisi.

İki tür doğrusal regresyon vardır:
1. Basit Doğrusal Regresyon
2. Çok Değişkenli Doğrusal Regresyon

Basit Doğrusal Regresyon:

Basit doğrusal regresyonda, y=ax+b ifadesinde çıkış ya da bağımlı değişken yalnızca bir giriş özelliğine göre tahmin edilir.
Burada

a: eğimi, girdi özelliğinin katsayısı
y: bağımlı çıkış değişkeni,
x: bağımsız giriş değişkeni, çıktının esas alındığı giriş özelliği
b: doğrunun x-eksenindeki kaymasını gösterir.

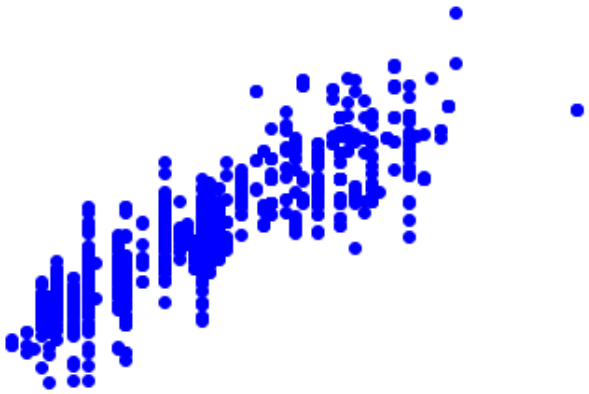

Doğrusal regresyon algoritması için veri grafiği

Adım adım uygulama:

a. Gerekli kütüphaneler aktarılır: Hesaplamalar için çeşitli kütüphaneler kullanacağımızdan, bunları aktarmamız gerekiyor.
b. Veritabanı dosyası okunur.
c. Değerler tahmin edilirken dikkate almak istenilen özellikleri seçilir.
d. Etiketli verilerin istatistiksel özellikleri belirlenir ve yorumlanır.
e. Verilerin grafiği çizilir.
f. Bir modelin doğruluğunu kontrol etmek için, veriler eğitim ve test veri setlerine ayrılır.
g. Model eğitilir: Modelin eğitimi uygun regresyon çizgimi için katsayıların nasıl bulabileceğidir.
h. En uygun çizgi çizilir.
i. Test veri seti için bir tahmin fonksiyonu bulunur.
j. Test verilerinin doğruluğu kontrol edilir: Gerçek değerleri veri setindeki tahmin edilen değerlerle karşılaştırılarak bir modelin doğruluğu kontrol edilebilir.
k. Performas artırma süreci gerçekleştirlir.

Doğrusal regresyon, veri noktaları arasındaki ilişkiyi, tüm bunların arasından düz bir çizgi çizmek için kullanır. Bu çizgi gelecekteki değerleri tahmin etmek için kullanılabilir.

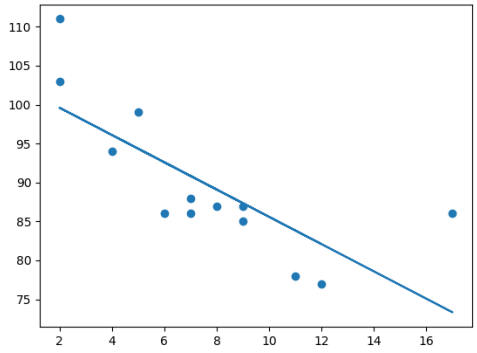

Makine Öğreniminde geleceği tahmin etmek çok önemlidir.
Python, veri noktaları arasında bir ilişki bulmak ve bir doğrusal regresyon çizgisi çizmek için yöntemlere sahiptir. Matematik formülü üzerinden gitmek yerine bu yöntemleri nasıl kullanacağınızı göstereceğiz.

Aşağıdaki örnekte, x ekseni arabanın yaşı, y ekseni ise hızı temsil etmektedir. Bir gişeden geçen 13 arabanın yaşını ve hızını kaydettik. Topladığımız verilerin doğrusal bir regresyonda kullanılıp kullanılamayacağını görelim:

Örnek: Bir dağılımın grafiği çizilerek başlanılır.

```
import matplotlib.pyplot as plt
x = [5,7,8,7,2,17,2,9,4,11,12,9,6]
y = [99,86,87,88,111,86,103,87,94,78,77,85,86]
plt.scatter(x, y)
plt.show()
```

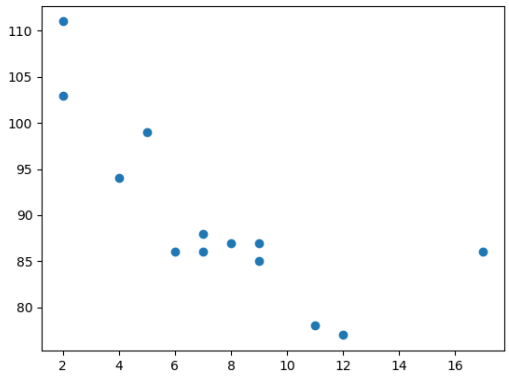

Example: Import scipy and draw the line of Linear Regression.

```
import matplotlib.pyplot as plt
from scipy import stats
x = [5,7,8,7,2,17,2,9,4,11,12,9,6]
y = [99,86,87,88,111,86,103,87,94,78,77,85,86]
slope, intercept, r, p, std_err = stats.linregress(x, y)
def myfunc(x):
  return slope * x + intercept
mymodel = list(map(myfunc, x))
plt.scatter(x, y)
plt.plot(x, mymodel)
plt.show()
```

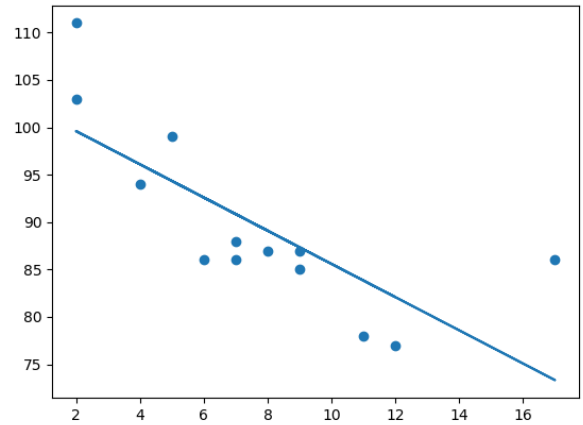

Örneğin açıklanması:

İhtiyaç olan modüller içe aktarılır.

matplotlib.pyplot, plt olarak içe aktarılır.
scipy istatistiklerinden transfer edilir.

x ve y ekseninin değerlerini temsil eden diziler oluşturulur:
x = [5,7,8,7,2,17,2,9,4,11,12,9,6]
y = [99,86,87,88,111,86,103,87,94,78,77,85,86]

Doğrusal Regresyonun bazı önemli anahtar değerlerini elde eden bir komut yürütülür:
slop(eğim), intercept(kesişme), r, p, std_err = stats.linregress(x, y)

Yeni bir değer elde etmek için eğim ve kesişme değerlerini kullanan bir işlev oluşturulur. Bu yeni değer, x değerine karşılık gelen y değerinin y-ekseninde nereye yerleştirileceğini temsil edilir:
def myfunc(x):
  return slope * x + intercept

x dizisinin her değeri işlev aracılığıyla çalıştırılır. Bu, y ekseni için yeni değerlere sahip yeni bir diziyle sonuçlanacaktır:
mymodel = list(map(myfunc, x))
Orijinal dağılım grafiğini çizin: plt.scatter(x, y)
Doğrusal regresyon çizgisini çizin: plt.plot(x, mymodel)
Diyagramı görüntüleyin: plt.show()

X ekseninin değerleri ile y ekseninin değerleri arasındaki ilişkinin nasıl olduğunu bilmek önemlidir, eğer ilişki yoksa doğrusal regresyon hiçbir şeyi tahmin etmek için kullanılamaz. Bu ilişki - korelasyon katsayısı - r olarak adlandırılır. r değeri -1 ile 1 arasındadır, burada 0 hiçbir ilişki olmadığını ve 1 (ve -1) %100 ilişkili anlamına gelir. Python ve Scipy modülü sizin için bu değeri hesaplayacaktır, tek yapmanız gereken onu x ve y değerleri ile beslemek.

Örnek: Verilerim doğrusal bir regresyona ne kadar uyuyor?
from scipy import stats
x = [5,7,8,7,2,17,2,9,4,11,12,9,6]
y = [99,86,87,88,111,86,103,87,94,78,77,85,86]
slope, intercept, r, p, std_err = stats.linregress(x, y)
print(r)
Not: r korelasyon değeridir. Bağımlı ve bağımsız iki değişken arasında bir ilişki olup olmadığını belirler. r=-0.76 sonucu, mükemmel olmayan bir ilişki olduğunu gösterir, ancak gelecekteki tahminlerde doğrusal regresyon kullanabileceğimizi gösterir. Mükemmel ilişki, -1 ya da +1 değeridir. Mükemmel olmayan ilişki 0 değeridir.

Gelecekteki Değerleri Tahmin Edilmesi

Artık gelecekteki değerleri tahmin etmek için topladığımız bilgileri kullanabiliriz. Örnek: 10 yaşında bir arabanın hızını tahmin etmeye çalışalım. Bunu yapmak için, yukarıdaki örnekteki aynı myfunc() işlevine ihtiyacımız var:

```
def myfunc(x):
  return slope * x + intercept
```

Örnek:

```
from scipy import stats
x = [5,7,8,7,2,17,2,9,4,11,12,9,6]
y = [99,86,87,88,111,86,103,87,94,78,77,85,86]
slope, intercept, r, p, std_err = stats.linregress(x, y)
def myfunc(x):
  return slope * x + intercept
speed = myfunc(10)
print("speed=", speed)
print("r=",r)
print("slope=",slope)
print("intercept=",intercept)
```

```
speed= 85.59308314937454
r= -0.7585915243761551
slope= -1.751287711552612
intercept= 103.10596026490066
```

Soru: aşağıdaki ifadede komutlar neden farklı hizalarda? Python'da koşul, döngüsel ve alt fonksiyonlar ifadlerinde farklı hizalrda olmazlar.

```
def myfunc(x):
  return slope * x + intercept
```

Örnek, şemadan da okuyabileceğimiz 85.6'da bir hız öngördü:

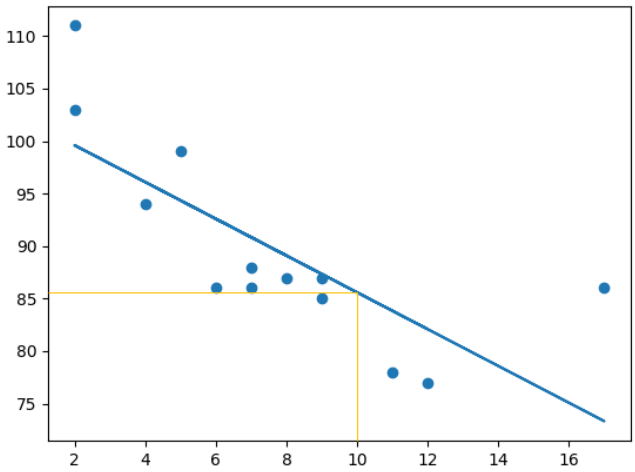

Kötü Uyum

Doğrusal regresyonun gelecekteki değerleri tahmin etmek için en iyi yöntem olmayacağı bir örnek oluşturalım.

Example: x ve y ekseni için bu değerler, doğrusal regresyon için çok kötü bir uyumla sonuçlanmalıdır.

```
import matplotlib.pyplot as plt
from scipy import stats
x = [89,43,36,36,95,10,66,34,38,20,26,29,48,64,6,5,36,66,72,40]
y = [21,46,3,35,67,95,53,72,58,10,26,34,90,33,38,20,56,2,47,15]
slope, intercept, r, p, std_err = stats.linregress(x, y)
def myfunc(x):
  return slope * x + intercept
mymodel = list(map(myfunc, x))
plt.scatter(x, y)
plt.plot(x, mymodel)
plt.show()
```

```
speed= 40.59144864292098
r= 0.013318141542974908
slope= 0.013916581398452628
intercept= 40.452282828936454
```

Not: y= ax+b ifadesinde slope=a, intercept=b

Not: r değeri 0'a yakın bir değer olduğu için x ile y değerleri arasında bir ilişki yoktur.

```
import matplotlib.pyplot as plt
from scipy import stats
x = [89,43,36,36,95,10,66,34,38,20,26,29,48,64,6,5,36,66,72,40]
y = [21,46,3,35,67,95,53,72,58,10,26,34,90,33,38,20,56,2,47,15]
slope, intercept, r, p, std_err = stats.linregress(x, y)
def myfunc(x):
  return slope * x + intercept
mymodel = list(map(myfunc, x))
plt.scatter(x, y)
plt.plot(x, mymodel)
plt.show()
```

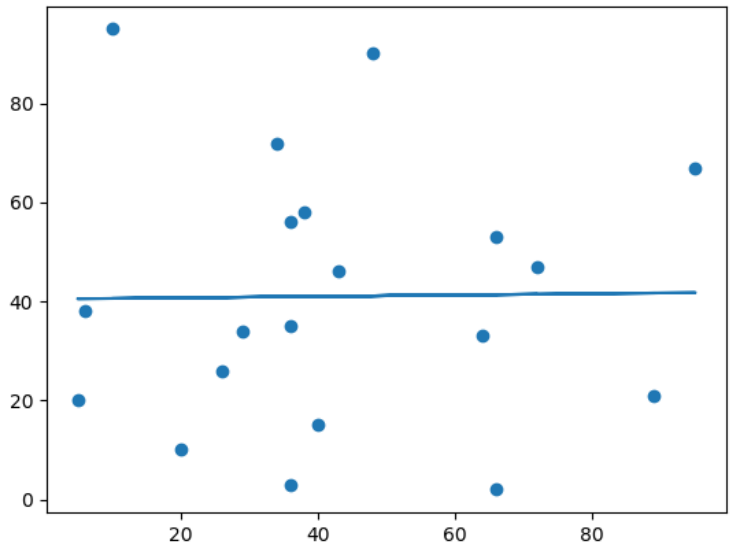

6.2. Çok Değişkenli Doğrusal Regresyon

Basit doğrusal regresyonda, çıktı özelliğinin değerinin tahmin edilmesi için yalnızca bir giriş özelliği dikkate alınır. Bununla birlikte, Çok Değişkenli Doğrusal Regresyonda, çıktı birden fazla giriş özelliğine göre tahmin edilebilir.

Burada b0, b1, ...bn: Sabit katsayılardır.
x1, x2, ..., xn: Giriş değerleridir; bağımsız değişkenlerdir.
Y: Çıkış eğeri; bağımlı değişkenler; x'değerleri ve katsayılara bağımlıdır.
ML, hangi değerler elde edilir? Paremetreler yani, b0, b1, .., bn
Katsayılar çok büyükse ne yaparsız? Katsayılar elenir. Önemsiz olanlar yani değerleri sıfıra yakın olanlar. Bunlar neden elersiniz? Gürültü...

$$Y = b_0 + b_1 * X_1 + b_2 * X_2 + \cdots + b_n * X_n$$

$$\begin{aligned} &Where, \\ &b_0 \quad = constant\ or\ y\ intercept\ of\ line \\ &b_1, b_2, b_n \ = coefficient\ of\ input\ feature \\ &X_1, X_2, X_n \ = input\ features \\ &Y \quad = output \end{aligned}$$

g. Predict the values:
h. Accuracy of the model:
Now notice that here we used the same dataset for simple and multivariable linear regression. We can notice that the accuracy of multivariable linear regression is far better than the accuracy of simple linear regression.

Multiple linear regression formula
Multiple regression is like linear regression, but with more than one independent value, meaning that we try to predict a value based on two or more variables.

The formula for a multiple linear regression is:

$$y = \beta_0 + \beta_1 X_1 + \ldots + \beta_n X_n + \epsilon$$

- y = the predicted value of the dependent variable
- B_0 = the y-intercept (value of y when all other parameters are set to 0)
- $B_1 X_1$ = the regression coefficient (B_1) of the first independent variable (X_1) (a.k.a. the effect that increasing the value of the independent variable has on the predicted y value)
- … = do the same for however many independent variables you are testing
- $B_n X_n$ = the regression coefficient of the last independent variable
- ϵ = model error (a.k.a. how much variation there is in our estimate of y)

Multiple Regression

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ 1 & x_{31} & x_{32} & \dots & x_{3q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nq} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_q \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \vdots \\ \epsilon_n \end{pmatrix}$$

Örnek: An analyst studying a chemical process expects the yield to be affected by the levels of two factors, x1 and x2. Observations recorded for various levels of the two factors are shown in the following table. The analyst wants to fit a first order regression model to the data. Interaction between x1 and x2 is not expected based on knowledge of similar processes. Units of the factor levels and the yield are ignored for the analysis.

Observation Number	Factor 1 (x_{i1})	Factor 2 (x_{i2})	Yield (y_i)
1	41.9	29.1	251.3
2	43.4	29.3	251.3
3	43.9	29.5	248.3
4	44.5	29.7	267.5
5	47.3	29.9	273.0
6	47.5	30.3	276.5
7	47.9	30.5	270.3
8	50.2	30.7	274.9
9	52.8	30.8	285.0
10	53.2	30.9	290.0
11	56.7	31.5	297.0
12	57.0	31.7	302.5
13	63.5	31.9	304.5
14	65.3	32.0	309.3
15	71.1	32.1	321.7
16	77.0	32.5	330.7
17	77.8	32.9	349.0

A scatter plot for the data is shown next.

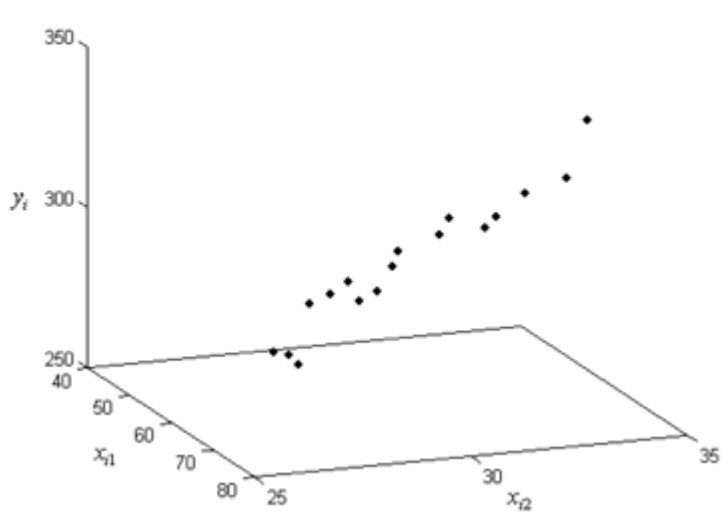

The first order regression model applicable to this data set having two predictor variables is:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

where the dependent variable, Y, represents the yield and the predictor variables, x_1 and x_2, represent the two factors respectively. The X and y matrices for the data can be obtained as:

$$X = \begin{bmatrix} 1 & 41.9 & 29.1 \\ 1 & 43.4 & 29.3 \\ . & . & . \\ . & . & . \\ . & . & . \\ 1 & 77.8 & 32.9 \end{bmatrix} \quad y = \begin{bmatrix} 251.3 \\ 251.3 \\ . \\ . \\ . \\ 349.0 \end{bmatrix}$$

The least square estimates, $\hat{\beta}$, can now be obtained:

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'y \\ &= \begin{bmatrix} 17 & 941 & 525.3 \\ 941 & 54270 & 29286 \\ 525.3 & 29286 & 16254 \end{bmatrix}^{-1} \begin{bmatrix} 4902.8 \\ 276610 \\ 152020 \end{bmatrix} \\ &= \begin{bmatrix} -153.51 \\ 1.24 \\ 12.08 \end{bmatrix}\end{aligned}$$

Thus:

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} -153.51 \\ 1.24 \\ 12.08 \end{bmatrix}$$

and the estimated regression coefficients are $\hat{\beta}_0 = -153.51$, $\hat{\beta}_1 = 1.24$ and $\hat{\beta}_2 = 12.08$. The fitted regression model is:

$$\begin{aligned}\hat{y} &= \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 \\ &= -153.5 + 1.24 x_1 + 12.08 x_2\end{aligned}$$

Adım adım uygulama:

a. Gerekli kütüphaneler aktarılır.
b. Veri tabanı dosyası okunur.
c. X ve Y tanımlanır: X, istediğimiz bir girdi, Y ise çıktının değeri.
d. Veriler bir test ve eğitim veri kümesine bölünür.
e. Model eğitilir.
f. Giriş özelliklerinin katsayılarını bulunur: Şimdi hangi özelliğin çıktı değişkeni üzerinde daha önemli bir etkiye sahip olduğunu bilmemiz gerekiyor. Bunun için katsayı değerleri bulunur. Negatif katsayının çıktı üzerinde ters etkisi olduğu anlamına geldiği unutulmamalıdır. Özelliklerin değeri artarsa, çıktı değeri düşer.
g. Değerler tahmin edilir.
h. Modelin doğruluğu test edilir: Şimdi, burada basit ve çok değişkenli doğrusal regresyon için aynı veri seti kullanıldığına dikkat edilir. Çok değişkenli doğrusal regresyonun doğruluğunun, basit doğrusal regresyonun doğruluğundan çok daha iyi olduğu fark edilebilir.

Örnek:

Çoklu regresyon, doğrusal regresyon gibidir, ancak birden fazla bağımsız değere sahiptir, yani iki veya daha fazla değişkene dayalı bir değeri tahmin etmeye çalışıyoruz.

Aşağıdaki veri setine bir göz atın, arabalar hakkında bazı bilgiler içeriyor.

Car	Model	Volume	Weight	CO2
Toyota	Aygo	1000	790	99
Mitsubishi	Space Star	1200	1160	95
Skoda	Citigo	1000	929	95
Fiat	500	900	865	90
Mini	Cooper	1500	1140	105
VW	Up!	1000	929	105
Skoda	Fabia	1400	1109	90
Mercedes	A-Class	1500	1365	92
Ford	Fiesta	1500	1112	98
Audi	A1	1600	1150	99
Hyundai	I20	1100	980	99
Suzuki	Swift	1300	990	101
Ford	Fiesta	1000	1112	99
Honda	Civic	1600	1252	94
Hundai	I30	1600	1326	97
Opel	Astra	1600	1330	97
BMW	1	1600	1365	99
Mazda	3	2200	1280	104
Skoda	Rapid	1600	1119	104
Ford	Focus	2000	1328	105
Ford	Mondeo	1600	1584	94
Opel	Insignia	2000	1428	99
Mercedes	C-Class	2100	1365	99
Skoda	Octavia	1600	1415	99
Volvo	S60	2000	1415	99
Mercedes	CLA	1500	1465	102
Audi	A4	2000	1490	104
Audi	A6	2000	1725	114
Volvo	V70	1600	1523	109
BMW	5	2000	1705	114
Mercedes	E-Class	2100	1605	115
Volvo	XC70	2000	1746	117
Ford	B-Max	1600	1235	104
BMW	2	1600	1390	108
Opel	Zafira	1600	1405	109
Mercedes	SLK	2500	1395	120

Motorun boyutuna bağlı olarak bir arabanın CO2 emisyonunu tahmin edebiliriz, ancak çoklu regresyonla, tahmini daha doğru hale getirmek için arabanın ağırlığı gibi daha fazla değişken ekleyebiliriz. Python'da işi bizim için yapacak modüllerimiz var.

Pandalar modülü içe aktarılarak başlanır.
import pandas

Pandas modülü, csv dosyalarını okumamıza ve bir DataFrame nesnesi döndürmemize izin verir.
df = pandas.read_csv("cars.csv")

Ardından bağımsız değerlerin bir listesi yapılır ve bu değişkene X adını verilir. Aynı şekilde bağımlı değerler de y adlı bir değişkene konur.
X = df[['Weight', 'Volume']]
y = df['CO2']

İpucu: Bağımsız değerler listesini büyük harf X ile ve bağımlı değerler listesini küçük harf y ile adlandırmak yaygındır. Sklearn modülünden bazı yöntemler kullanacağız, bu yüzden o modülü de içe aktarmamız gerekecek.
from sklearn import linear_model

Sklearn modülünden, doğrusal bir regresyon nesnesi oluşturmak için LinearRegression() yöntemini kullanacağız. Bu nesnenin, bağımsız ve bağımlı değerleri parametre olarak alan ve regresyon nesnesini ilişkiyi tanımlayan verilerle dolduran fit() adlı bir yöntemi vardır.
regr = linear_model.LinearRegression()
regr.fit(X, y)

Artık bir otomobilin ağırlığına ve hacmine dayalı olarak CO2 değerlerini tahmin etmeye hazır bir regresyon nesnemiz var.

#predict the CO2 emission of a car where the weight is 2300kg, and the volume is 1300cm^3:
predictedCO2 = regr.predict([[2300, 1300]])

Örnek: Tüm örneği çalışırken görün.

```
import pandas
from sklearn import linear_model
df = pandas.read_csv("cars.csv")
X = df[['Weight', 'Volume']]
y = df['CO2']
```

```
regr = linear_model.LinearRegression()
regr.fit(X, y)
#predict the CO2 emission of a car where the weight is 2300kg, and the volume is 1300cm3:
predictedCO2 = regr.predict([[2300, 1300]])
print(predictedCO2)
```

Result: [107.2087328]

1,3 litrelik motora ve 2300 kg ağırlığa sahip bir otomobilin kat ettiği her kilometrede yaklaşık 107 gram CO2 salacağı tahmin edilmiştir.

Katsayı:
Katsayı, bilinmeyen bir değişkenle olan ilişkiyi tanımlayan bir faktördür.
Örnek: x bir değişken ise, o zaman 2x, x'in iki katıdır. x bilinmeyen değişkendir ve 2 sayısı katsayıdır.
Bu durumda, CO2'ye karşı ağırlığın ve CO2'ye karşı hacmin katsayı değerini isteyebiliriz.
Aldığımız cevap(lar), bağımsız değerlerden birini arttırırsak veya azaltırsak ne olacağını söyler.

Örnek: Regresyon nesnesinin katsayı değerlerinin bulunması.

```
import pandas
from sklearn import linear_model
df = pandas.read_csv("cars.csv")
X = df[['Weight', 'Volume']]
y = df['CO2']
regr = linear_model.LinearRegression()
regr.fit(X, y)
print(regr.coef_)
```

Result: [0.00755095 0.00780526]

Sonuç Açıklaması:
Sonuç dizisi, ağırlık ve hacmin katsayı değerlerini temsil eder.
Ağırlık: 0.00755095
Hacim: 0.00780526
Bu değerler bize ağırlık 1 kg artarsa CO2 emisyonunun 0.00755095g arttığını söyler.
Motor hacmi (Hacim) 1 cm3 artarsa CO2 emisyonu 0,00780526 g artar.

Bence bu adil bir tahmin, ama test edelim!

1300cm3 motorlu bir araba 2300kg ağırlığındaysa CO2 emisyonunun yaklaşık 107g olacağını zaten tahmin etmiştik.
Ağırlığı 1000kg ile arttırırsak ne olur?

Örnek: Önceki örneği kopyalayın, ancak ağırlığı 2300'den 3300'e değiştirin.

```
import pandas
from sklearn import linear_model
df = pandas.read_csv("cars.csv")
X = df[['Weight', 'Volume']]
y = df['CO2']
regr = linear_model.LinearRegression()
regr.fit(X, y)
predictedCO2 = regr.predict([[3300, 1300]])
print(predictedCO2)
```

Result:
[114.75968007]
1,3 litrelik motora ve 3300 kg ağırlığa sahip bir otomobilin kat ettiği her kilometrede yaklaşık 115 gram CO2 salacağını tahmin etmiştik.
Bu, 0.00755095 katsayısının doğru olduğunu gösterir:
107.2087328 + (1000 * 0.00755095) = 114.75968

Ölçeklendirme Özellikleri:

Verileriniz farklı değerlere ve hatta farklı ölçüm birimlerine sahip olduğunda bunları karşılaştırmak zor olabilir. Metre ile karşılaştırıldığında kilogram nedir? Ya da zamana göre yükseklik? Bu sorunun cevabı ölçeklendirmedir. Verileri, karşılaştırması daha kolay yeni değerlere ölçekleyebiliriz. Aşağıdaki tabloya bakın, aynı veri seti ama bu sefer hacim sütunu cm^3 (1000 yerine 1.0) yerine litre cinsinden değerler içeriyor.

Car	Model	Volume	Weight	CO2
Toyota	Aygo	1	790	99
Mitsubishi	Space Star	1.2	1160	95
Skoda	Citigo	1	929	95
Fiat	500	0.9	865	90
Mini	Cooper	1.5	1140	105
VW	Up!	1	929	105
Skoda	Fabia	1.4	1109	90
Mercedes	A-Class	1.5	1365	92
Ford	Fiesta	1.5	1112	98
Audi	A1	1.6	1150	99
Hyundai	I20	1.1	980	99
Suzuki	Swift	1.3	990	101
Ford	Fiesta	1	1112	99
Honda	Civic	1.6	1252	94
Hundai	I30	1.6	1326	97
Opel	Astra	1.6	1330	97
BMW	1	1.6	1365	99
Mazda	3	2.2	1280	104
Skoda	Rapid	1.6	1119	104
Ford	Focus	2	1328	105
Ford	Mondeo	1.6	1584	94
Opel	Insignia	2	1428	99
Mercedes	C-Class	2.1	1365	99
Skoda	Octavia	1.6	1415	99
Volvo	S60	2	1415	99
Mercedes	CLA	1.5	1465	102
Audi	A4	2	1490	104
Audi	A6	2	1725	114
Volvo	V70	1.6	1523	109
BMW	5	2	1705	114
Mercedes	E-Class	2.1	1605	115
Volvo	XC70	2	1746	117

Ford	B-Max	1.6	1235	104
BMW	2	1.6	1390	108
Opel	Zafira	1.6	1405	109
Mercedes	SLK	2.5	1395	120

1.0 hacmini 790 ağırlığı ile karşılaştırmak zor olabilir, ancak her ikisini de karşılaştırılabilir değerlere ölçeklendirirsek, bir değerin diğerine kıyasla ne kadar olduğunu kolayca görebiliriz. Verileri ölçeklendirmek için farklı yöntemler vardır, bu derste standardizasyon adı verilen bir yöntem kullanacağız. Standardizasyon yöntemi şu formülü kullanır:
z = (x - u) / s

z'nin yeni değer olduğu yerde, x orijinal değerdir, u ortalamadır ve s standart sapmadır. Ağırlık sütununu yukarıdaki veri kümesinden alırsanız, ilk değer 790'dır ve ölçeklenen değer şöyle olacaktır: (790 - 1292.23) / 238.74 = -2.1

Hacim sütununu yukarıdaki veri kümesinden alırsanız, ilk değer 1.0'dır ve ölçeklenen değer şöyle olacaktır: (1.0 - 1.61) / 0.38 = -1.59

Artık 790'ı 1.0 ile karşılaştırmak yerine -2.1 ile -1.59'u karşılaştırabilirsiniz. Bunu manuel olarak yapmanız gerekmez, Python sklearn modülü, veri kümelerini dönüştürmek için yöntemlerle bir Scaler nesnesi döndüren StandardScaler() adlı bir yönteme sahiptir.

Örnek: Ağırlık ve Hacim sütunlarındaki tüm değerleri ölçeklendirin.

```
import pandas
from sklearn import linear_model
from sklearn.preprocessing import StandardScaler
scale = StandardScaler()
df = pandas.read_csv("cars1.csv")
X = df[['Weight', 'Volume']]
scaledX = scale.fit_transform(X)
print(scaledX)
```

Result: İlk iki değerin, hesaplamalarımıza karşılık gelen -2.1 ve -1.59 olduğuna dikkat edin..

```
[[-2.10389253 -1.59336644]
 [-0.55407235 -1.07190106]
 [-1.52166278 -1.59336644]
 [-1.78973979 -1.85409913]
 [-0.63784641 -0.28970299]
 [-1.52166278 -1.59336644]
 [-0.76769621 -0.55043568]
 [ 0.3046118  -0.28970299]
```

```
[-0.7551301  -0.28970299]
[-0.59595938 -0.0289703 ]
[-1.30803892 -1.33263375]
[-1.26615189 -0.81116837]
[-0.7551301  -1.59336644]
[-0.16871166 -0.0289703 ]
[ 0.14125238 -0.0289703 ]
[ 0.15800719 -0.0289703 ]
[ 0.3046118  -0.0289703 ]
[-0.05142797  1.53542584]
[-0.72580918 -0.0289703 ]
[ 0.14962979  1.01396046]
[ 1.2219378  -0.0289703 ]
[ 0.5685001   1.01396046]
[ 0.3046118   1.27469315]
[ 0.51404696 -0.0289703 ]
[ 0.51404696  1.01396046]
[ 0.72348212 -0.28970299]
[ 0.8281997   1.01396046]
[ 1.81254495  1.01396046]
[ 0.96642691 -0.0289703 ]
[ 1.72877089  1.01396046]
[ 1.30990057  1.27469315]
[ 1.90050772  1.01396046]
[-0.23991961 -0.0289703 ]
[ 0.40932938 -0.0289703 ]
[ 0.47215993 -0.0289703 ]
[ 0.4302729   2.31762392]]
```

CO2 Değerlerinin Tahmin Edilmesi:
Görev, yalnızca ağırlığını ve hacmini bildiğiniz bir arabadan kaynaklanan CO2 emisyonunu tahmin etmekti. Veri seti ölçeklendiğinde, değerleri tahmin ederken ölçeği kullanmanız gerekecektir.

Örnek: 2300 kilogram ağırlığındaki 1,3 litrelik bir arabanın CO2 emisyonunu tahmin edin.

```
import pandas
from sklearn import linear_model
from sklearn.preprocessing import StandardScaler
scale = StandardScaler()
df = pandas.read_csv("cars1.csv")
X = df[['Weight', 'Volume']]
```

```
y = df['CO2']
scaledX = scale.fit_transform(X)
regr = linear_model.LinearRegression()
regr.fit(scaledX, y)
scaled = scale.transform([[2300, 1.3]])
predictedCO2 = regr.predict([scaled[0]])
print(predictedCO2)
```

Result: [107.2087328]

Modelin Değerlendirilmesi:
Makine Öğreniminde, ağırlığı ve motor boyutunu bildiğimizde bir arabanın CO2 emisyonunu tahmin ettiğimiz önceki bölümde olduğu gibi, belirli olayların sonucunu tahmin etmek için modeller oluşturulur. Modelin yeterince iyi olup olmadığını ölçmek için Eğitim/Test adlı bir yöntem kullanılır.

Eğitim / Test
Eğitim / Test, modelin doğruluğunu ölçmek için kullanılan bir yöntemdir. Eğitim/Test olarak adlandırılır çünkü veri kümesi iki kümeye bölünür: bir eğitim kümesi ve bir test kümesi. Söz gelimi, eğitim için %80 ve test için %20.

Model eğitim seti kullanılarak eğitilir. Test seti kullanılarak model test edilir. Modeli eğitmek, modeli oluşturmak anlamına gelir. Modeli test etmek, modelin doğruluğunu test etmek anlamına gelir.

Örnek: Bir veri kümesiyle ve Test etmek istenilen bir veri seti ile başlanır. Veri seti bir mağazadaki 100 müşteriyi ve onların alışveriş alışkanlıklarını göstersin.

```
import numpy
import matplotlib.pyplot as plt
numpy.random.seed(2)
x = numpy.random.normal(3, 1, 100)
y = numpy.random.normal(150, 40, 100) / x
plt.scatter(x, y)
plt.show()
```

Sonuç:
X ekseni, satın alma yapmadan önce gezinme süresini dakika olarakı temsil etsin.
Y ekseni, satın alma işlemine harcanan para miktarını temsil etsin.

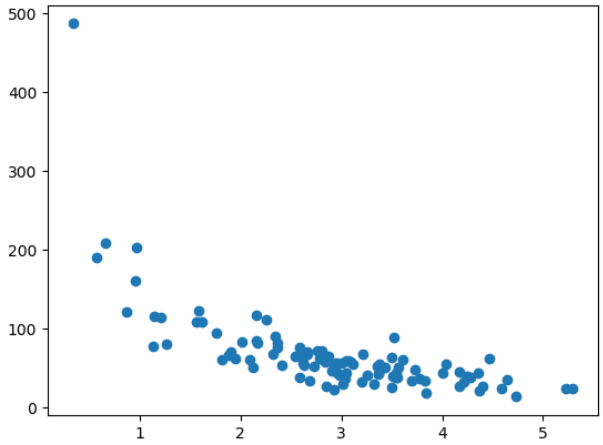

Eğitim/Test olarak bölme:
Eğitim seti, orijinal verilerin %80'inden rastgele bir seçim olmalıdır. Test seti kalan %20 olmalıdır.

train_x = x[:80]
train_y = y[:80]

test_x = x[80:]
test_y = y[80:]

Eğitim Setini Görüntülenmesi:
Eğitim seti ile aynı dağılım grafiğinde görüntülenirç

Example:
plt.scatter(train_x, train_y)
plt.show()

Result: It looks like the original data set, so it seems to be a fair selection.

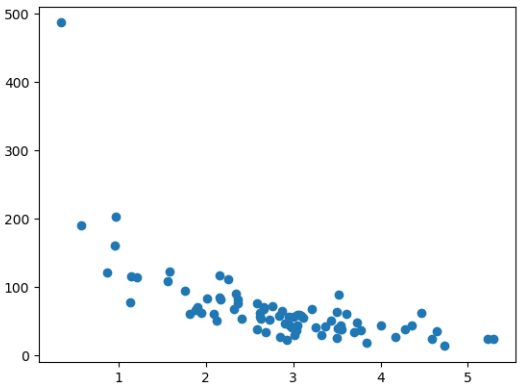

Test Setini Göster: Test setinin tamamen farklı olmadığından emin olmak için test setine de bir göz atacağız.

Example:
plt.scatter(test_x, test_y)
plt.show()

Sonuç: Test seti aynı zamanda orijinal veri setine benziyor.

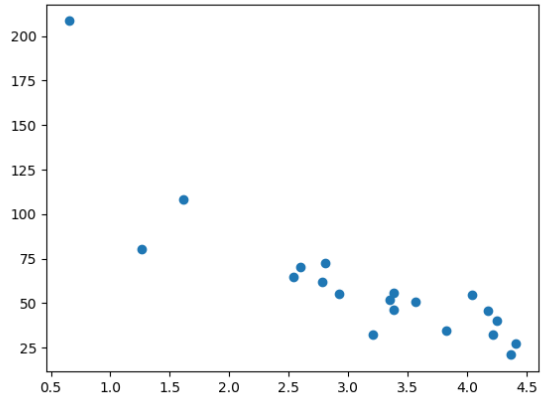

Eğtim ve test verilerinin birlikte çizilmesi:

```
import numpy
import matplotlib.pyplot as plt
numpy.random.seed(2)
x = numpy.random.normal(3, 1, 100)
y = numpy.random.normal(150, 40, 100) / x

train_x = x[:80]
train_y = y[:80]
plt.scatter(train_x, train_y)

test_x = x[:20]
test_y = y[:20]
plt.scatter(test_x, test_y)

plt.show()
```

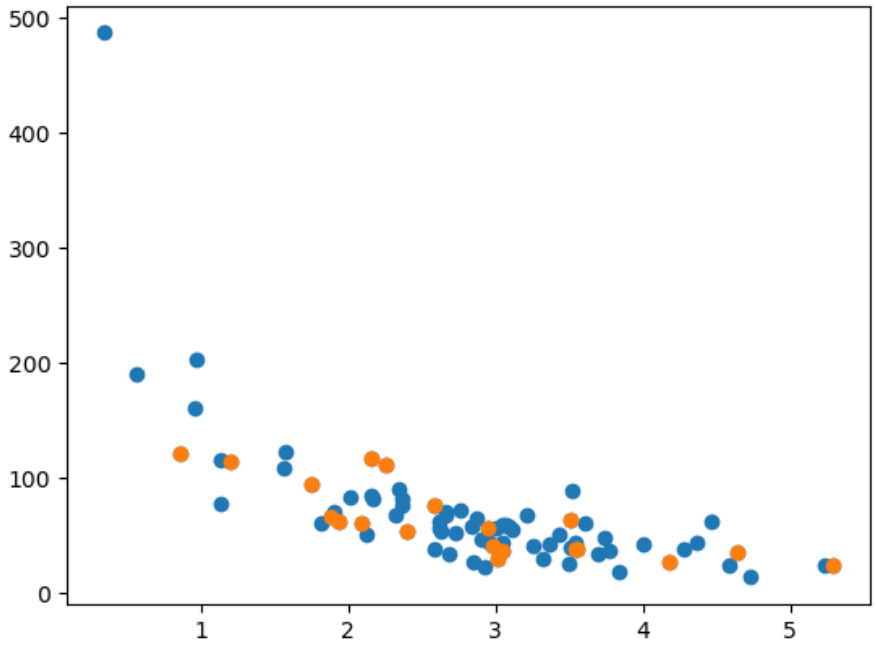

Veri Kümesini Matematiksel Modele Uydurulması:
Veri seti neye benziyor? Bence en uygun olanı bir polinom regresyonu olur, bu yüzden bir polinom regresyon eğrisi çizelim. Veri noktaları arasında bir çizgi çizmek için matplotlib modülünün plot() yöntemini kullanırız.

Örnek: Veri noktalarından bir polinom regresyon çizgisi çizilmesi.

```
import numpy
import matplotlib.pyplot as plt
numpy.random.seed(2)

x = numpy.random.normal(3, 1, 100)
y = numpy.random.normal(150, 40, 100) / x

train_x = x[:80]
train_y = y[:80]

test_x = x[80:]
test_y = y[80:]

mymodel = numpy.poly1d(numpy.polyfit(train_x, train_y, 4))
myline = numpy.linspace(0, 6, 100)
plt.scatter(train_x, train_y)
plt.plot(myline, mymodel(myline))
plt.show()
```

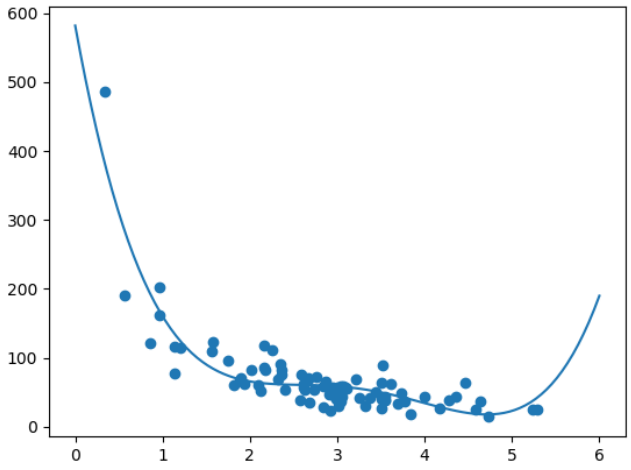

Sonuç, veri kümesinin dışındaki değerleri tahmin etmeye çalışırsak bize bazı garip sonuçlar verecek olsa da, bir polinom regresyonuna uyan veri kümesi önerimi destekleyebilir. Örnek: satır, mağazada 6 dakika geçiren bir müşterinin 200 değerinde bir satın alma yapacağını gösterir. Bu muhtemelen fazla uydurmanın bir işaretidir. Peki ya R-kare puanı? R-kare puanı, veri setimin modele ne kadar iyi uyduğunun iyi bir göstergesidir.

R^2

R-kare olarak da bilinen R^2'yi hatırlıyor musunuz? X ekseni ile y ekseni arasındaki ilişkiyi ölçer ve 0 ile 1 arasında değişir; burada 0, ilişki yok ve 1 tamamen ilişkili anlamına gelir.

sklearn modülünde bu ilişkiyi bulmamıza yardımcı olacak r2_score() adında bir metod vardır. Bu durumda müşterinin mağazada kaldığı dakikalar ile ne kadar para harcadıkları arasındaki ilişkiyi ölçmek istiyoruz.

Örnek: Eğitim verileri bir polinom regresyonuna ne kadar uyuyor?

```
import numpy
from sklearn.metrics import r2_score
numpy.random.seed(2)

x = numpy.random.normal(3, 1, 100)
y = numpy.random.normal(150, 40, 100) / x

train_x = x[:80]
train_y = y[:80]

test_x = x[80:]
test_y = y[80:]
```

```
mymodel = numpy.poly1d(numpy.polyfit(train_x, train_y, 4))
r2 = r2_score(train_y, mymodel(train_x))
print(r2)
```

Not: 0.799 sonucu, bir olumlu ilişki olduğunu gösterir.

Test Setini getirilmesi:
Şimdi, en azından eğitim verileri söz konusu olduğunda, tamam olan bir model yaptık. Şimdi aynı sonucu verip vermediğini görmek için modeli test verileriyle de test etmek istiyoruz.

Örnek: Test verilerini kullanırken R2 puanını bulalım.

```
import numpy
from sklearn.metrics import r2_score
numpy.random.seed(2)

x = numpy.random.normal(3, 1, 100)
y = numpy.random.normal(150, 40, 100) / x

train_x = x[:80]
train_y = y[:80]

test_x = x[80:]
test_y = y[80:]

mymodel = numpy.poly1d(numpy.polyfit(train_x, train_y, 4))
r2 = r2_score(test_y, mymodel(test_x))
print(r2)
```

Not: 0.809 sonucu, modelin test kümesine de uyduğunu gösterir ve modeli gelecekteki değerleri tahmin etmek için kullanabileceğimizden eminiz.

Tahmin Değerleri:
Artık modelimizin tamam olduğunu belirlediğimize göre, yeni değerleri tahmin etmeye başlayabiliriz.
Örnek: Satın alan bir müşteri, dükkanda 5 dakika kalırsa ne kadar para harcar?

```
print(mymodel(5))
```

Örnek, şemaya karşılık geldiği gibi, müşterinin 22.88 dolar harcamasını öngördü.

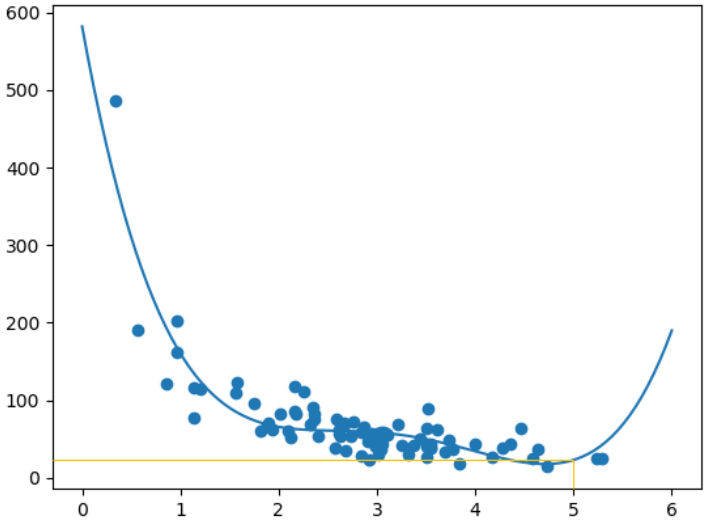

6.3. Polynomial Regression

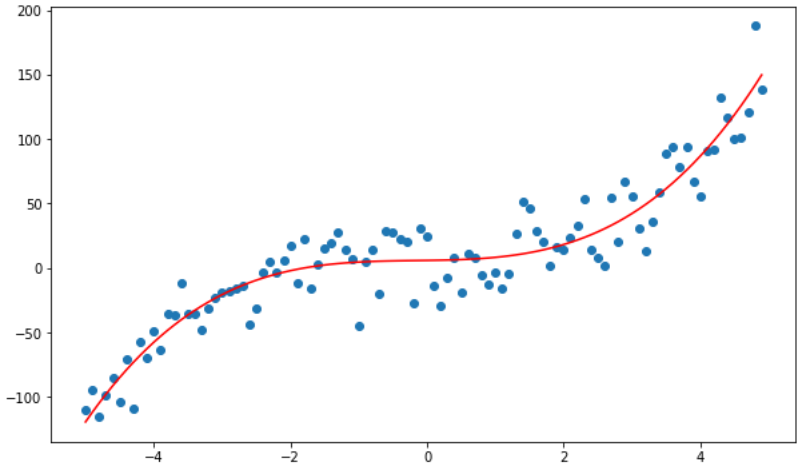

Graph for **Y=X**

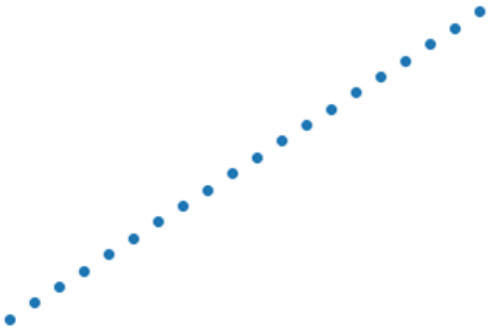

Graph for **Y = X²**

Graph for **Y = X³**

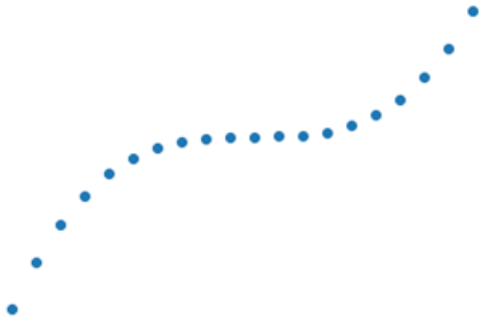

Graph with more than one polynomials: **$Y = X^3+X^2+X$**

Below is the formula for polynomial regression:

$$Y = b_0 + b_1X + b_2X^2 + \ldots + b_nX^n$$

$Where,$

$Y \quad = output$

$X \quad = input\ feature$

$b_0, b_1, b_n \quad = coefficients$

$$\theta = \left(X^T X\right)^{-1}.\left(X^T y\right)$$

Yukarıdaki denklemde:
θ: onu en iyi tanımlayan hipotez parametreleri.
X: her örneğin giriş özelliği değeri.
Y: Her örneğin çıktı değeri.

Veri noktalarınız açıkça doğrusal bir regresyona uymuyorsa (tüm veri noktalarından geçen düz bir çizgi), polinom regresyon için ideal olabilir. Polinom regresyon, lineer regresyon gibi, veri noktalarından bir çizgi çizmenin en iyi yolunu bulmak için x ve y değişkenleri arasındaki ilişkiyi kullanır.

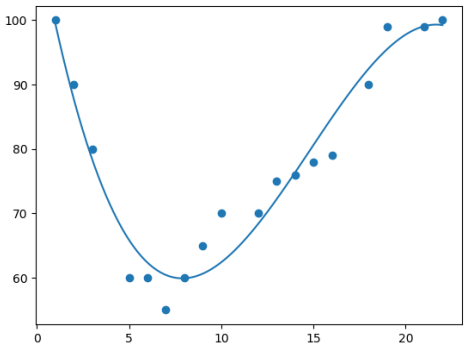

Python, veri noktaları arasında bir ilişki bulmak ve bir polinom regresyon çizgisi çizmek için yöntemlere sahiptir. Matematik formülü üzerinden gitmek yerine bu yöntemleri nasıl kullanacağınızı göstereceğiz. Aşağıdaki örnekte, belirli bir gişeden geçerken 18 araba kaydettik. Aracın hızını ve geçişin gerçekleştiği günün saatini (saati) kaydettik. X ekseni günün saatlerini ve y ekseni hızı temsil eder.

Örnek: Bir dağılım grafiği çizerek başlayın.

```
import matplotlib.pyplot as plt
x = [1,2,3,5,6,7,8,9,10,12,13,14,15,16,18,19,21,22]
y = [100,90,80,60,60,55,60,65,70,70,75,76,78,79,90,99,99,100]
plt.scatter(x, y)
plt.show()
```

Result:

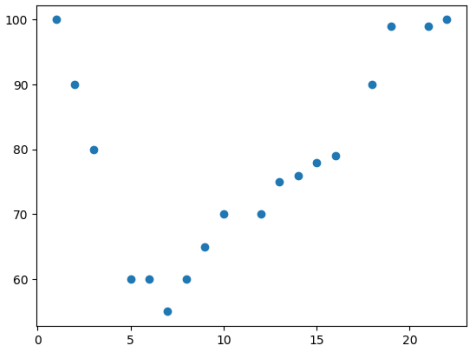

Example: Numpy ve matplotlib'i içe aktarın, ardından Polinom Regresyon çizgisini çizin

```
import numpy
import matplotlib.pyplot as plt
x = [1,2,3,5,6,7,8,9,10,12,13,14,15,16,18,19,21,22]
y = [100,90,80,60,60,55,60,65,70,70,75,76,78,79,90,99,99,100]
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))
myline = numpy.linspace(1, 22, 100)
plt.scatter(x, y)
plt.plot(myline, mymodel(myline))
plt.show()
```

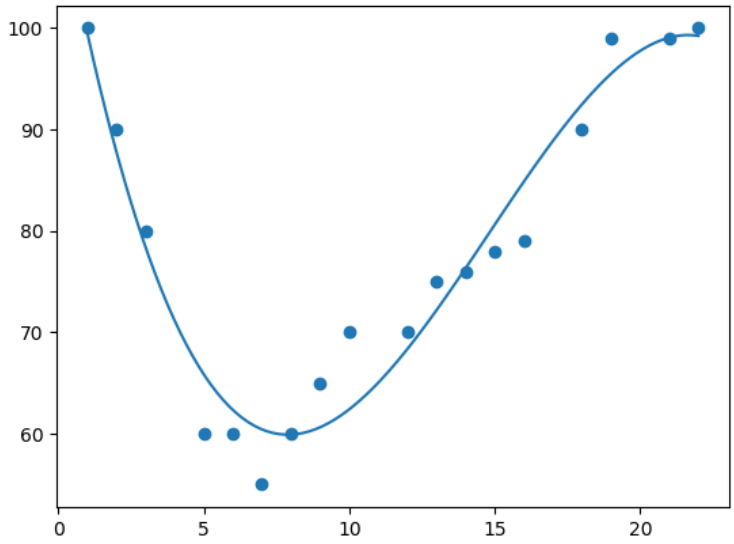

Örneğin açıklanması
İhtiyacınız olan modülleri içe aktarılır.

```
import numpy
import matplotlib.pyplot as plt
```

x ve y ekseninin değerlerini temsil eden dizileri oluşturulur:

```
x = [1,2,3,5,6,7,8,9,10,12,13,14,15,16,18,19,21,22]
y = [100,90,80,60,60,55,60,65,70,70,75,76,78,79,90,99,99,100]
```

NumPy, bir polinom modeli yapmamızı sağlayan bir metoda sahiptir:
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))

Ardından satırın nasıl görüneceğini belirtilir, 1. pozisyondan başlayıp 22. pozisyonda bitirilirsin:

```
myline = numpy.linspace(1, 22, 100)
```

Orijinal dağılım grafiğini çizilir:
plt.scatter(x, y)

Polinom regresyon çizgisini çizdirilir:
plt.plot(myline, mymodel(myline))

Diyagramı görüntülenir:
plt.show()

X ve y ekseni değerleri arasındaki ilişkinin ne kadar iyi olduğunu bilmek önemlidir, eğer ilişki yoksa polinom regresyonu hiçbir şeyi tahmin etmek için kullanılamaz.
İlişki, r-kare adı verilen bir değerle ölçülür.
r-kare değeri 0 ile 1 arasındadır, burada 0 hiçbir ilişki olmadığı ve 1 %100 ilişkili anlamına gelir.

Python ve Sklearn modülü bu değeri sizin için hesaplayacaktır, tek yapmanız gereken onu x ve y dizileriyle beslemek:
Örnek: Verilerim bir polinom regresyonuna ne kadar uyuyor?

```
import numpy
from sklearn.metrics import r2_score
x = [1,2,3,5,6,7,8,9,10,12,13,14,15,16,18,19,21,22]
y = [100,90,80,60,60,55,60,65,70,70,75,76,78,79,90,99,99,100]
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))
print(r2_score(y, mymodel(x)))
```

Not: 0.94 sonucu, çok iyi bir ilişkinin olduğunu ve gelecek tahminlerinde polinom regresyonunu kullanabileceğimizi göstermektedir.

Gelecekteki Değerlerin Tahmin Edilmesi
Artık gelecekteki değerleri tahmin etmek için topladığımız bilgileri kullanabiliriz. Örnek: Saat 17.00 civarında gişeden geçen bir arabanın hızını tahmin etmeye çalışalım: Bunu yapmak için, yukarıdaki örnekteki aynı mymodel dizisine ihtiyacımız var:
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))

Örnek: Saat 17:00'de geçen bir arabanın hızını tahmin edin.

```
import numpy
from sklearn.metrics import r2_score
x = [1,2,3,5,6,7,8,9,10,12,13,14,15,16,18,19,21,22]
y = [100,90,80,60,60,55,60,65,70,70,75,76,78,79,90,99,99,100]
```

mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))
speed = mymodel(17)
print(speed)

Örnek, şemadan da okuyabileceğimiz bir hızın 88.87 olacağını öngörüldü.

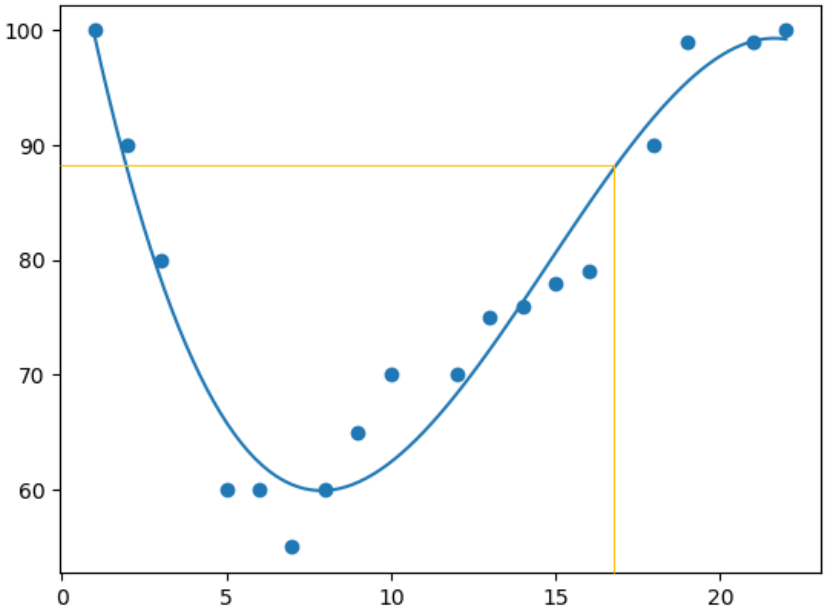

Kötü Uyum

Polinom regresyonunun gelecekteki değerleri tahmin etmek için en iyi yöntem olmayacağı bir örnek oluşturalım. Örnek: x ve y ekseni için bu değerler, polinom regresyonu için çok kötü bir uyumla sonuçlanmalıdır.

```
import numpy
import matplotlib.pyplot as plt
x = [89,43,36,36,95,10,66,34,38,20,26,29,48,64,6,5,36,66,72,40]
y = [21,46,3,35,67,95,53,72,58,10,26,34,90,33,38,20,56,2,47,15]
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))
myline = numpy.linspace(2, 95, 100)
plt.scatter(x, y)
plt.plot(myline, mymodel(myline))
plt.show()
```

Result:

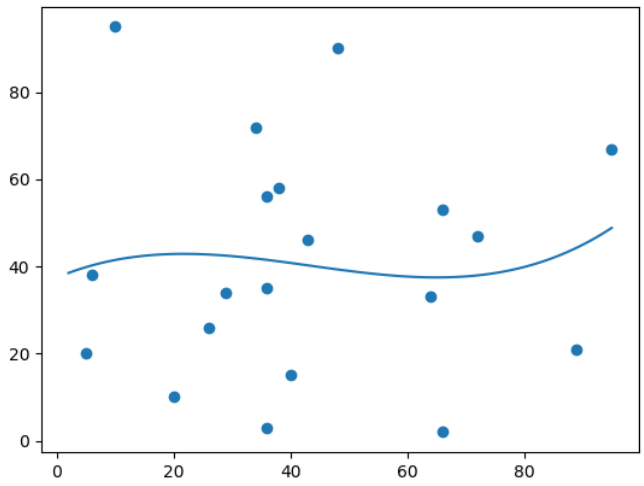

Çok düşük bir r-kare değeri almalısınız.

```
import numpy
from sklearn.metrics import r2_score
x = [89,43,36,36,95,10,66,34,38,20,26,29,48,64,6,5,36,66,72,40]
y = [21,46,3,35,67,95,53,72,58,10,26,34,90,33,38,20,56,2,47,15]
mymodel = numpy.poly1d(numpy.polyfit(x, y, 3))
print(r2_score(y, mymodel(x)))
```

Sonuç: 0,00995 çok kötü bir ilişkiyi gösterir ve bize bu veri setinin polinom regresyonu için uygun olmadığını söyler.

6.4. Hypothesis Function for Polynomial Regression

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 x^3 + \ldots + \beta_n x^{n-1}$$

$$X = \begin{bmatrix} 1 & x_0 & x_0^2 & \cdots & x_0^{n-1} \\ 1 & x_1 & x_1^2 & \cdots & x_1^{n-1} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_n & x_n^2 & \cdots & x_n^{n-1} \end{bmatrix}$$

Hiperbolik fonksiyonlar ML uygulamaları nelerdir? İz sürmede ve yöründe tahmin etmede.

Step by step implementation:

a. Import the required libraries:

b. Generate the data points: We are going to generate a dataset for implementing our polynomial regression.

c. Initialize x, x^2, x^3 vectors: We are taking the maximum power of x as 3. So our X matrix will have X, X^2, X^3.

d. Column-1 of X matrix: The 1st column of the main matrix X will always be 1 because it holds the coefficient of beta_0.

e. Form the complete x matrix: Look at the matrix X at the start of this implementation. We are going to create it by appending vectors.

f. Transpose of the matrix:

We are going to calculate the value of theta step-by-step. First, we need to find the transpose of the matrix.

g. Matrix multiplication: After finding the transpose, we need to multiply it with the original matrix. Keep in mind that we are going to implement it with a normal equation, so we have to follow its rules.

h. The inverse of a matrix:

i. Matrix multiplication: Finding the multiplication of transposed X and the Y vector and storing it in the temp2 variable.

j. Coefficient values: To find the coefficient values, we need to multiply temp1 and temp2.

k. Store the coefficients in variables: Storing those coefficient values in different variables.

l. Plot the data with curve:

m. Prediction function: Now we are going to predict the output using the regression curve.

n. Error function: Calculate the error using mean squared error function.

o. Calculate the error:

6.5. Üssel Regrasyon

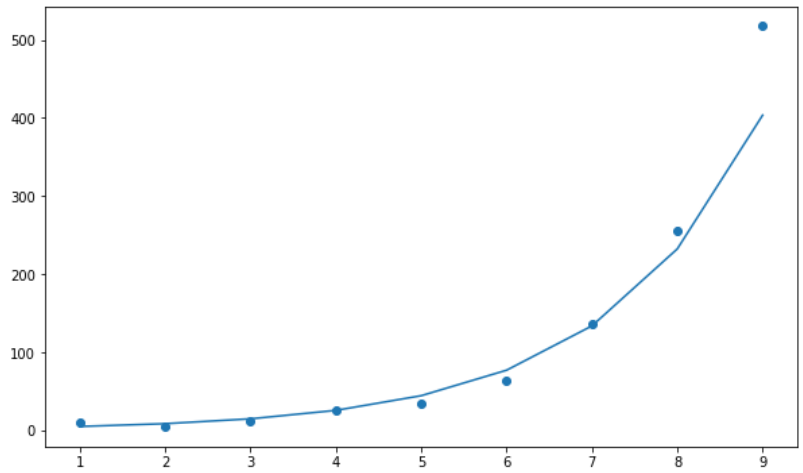

Üstel büyümenin bazı gerçek hayat örnekleri:

1. Kültürlerdeki mikroorganizmalar
2. Yiyeceklerin bozulması
3. İnsan Nüfusu
4. Bileşik Faiz
5. Pandemiler (Covid-19 gibi)
6. Ebola Salgını
7. İstilacı Türler
8. Ateş
9. Kanser Hücreleri
10. Akıllı Telefon Alımı ve Satışı

The formula for exponential regression is as follow:

$$Y = a + b * c^X$$

$Where,$

$Y = output$

$X = input\ feature$

$a = shift\ value$

$b = y - intercpet$

$c = base$

Korelasyon katsayısı: -1< r <+1
r=-1: kuvvetli negatif
r=0: zayıf
r=+1: kuvvetli positif

linear, y=mx + a
Üssel, $y=e^x$

$dy/dx = e^x = y$, eğim, fonksiyonun kendisine eşittir. x=0, da y=1 olur. Eğim de 1'e eşittir. Yükseliyor. Pozitif yükseliyor. x büyüdükce y'de çok hızlı büyümektedir.

$y= a+ bc^x$

Step by step implementation:
a. Import the required libraries:
b. Insert the data points:
c. Implement the exponential function algorithm:
d. Apply optimal parameters and covariance:
e. Plot the data: Plotting the data with the coefficients found.
f. Check the accuracy of the model:

6.6. Sinusoidal Regression

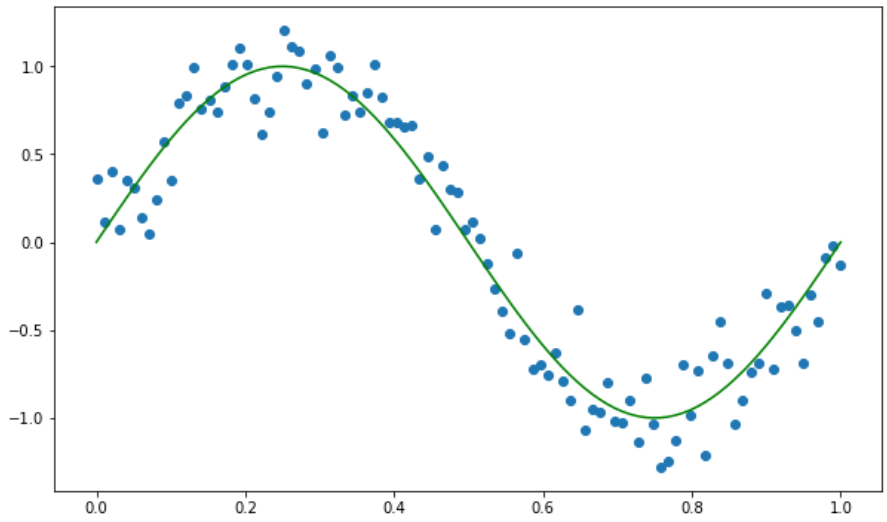

Some real-life examples of sinusoidal regression:

1. Müzik dalgalarının oluşturulması.
2. Ses, dalgalar halinde hareket eder.
3. Yapılarda trigonometrik fonksiyonlar.
4. Uzay uçuşlarında kullanılır.
5. GPS konum hesaplamaları.
6. Mimari.
7. Elektrik akımı.
8. Radyo yayını.
9. Okyanusun alçak ve yüksek gelgitler.
10. Binalar.

$$Y = A * \sin\big(B(X + C)\big) + D$$

$Where,$

$A \quad = amplitude$

$Period = 2 * pi/B$

$Period = length\ of\ one\ cycle$

$C \quad = phase\ shift\ (In\ radian)$

$D \quad = vertical\ shift$

Step by step implementation:

a. Generating the dataset

b. Applying a sine function

c. Why does a sinusoidal regression perform better than linear regression?

If we check the accuracy of the model after fitting our data with a straight line, we can see that the accuracy in prediction is less than that of sine wave regression. That is why we use sinusoidal regression.

6.7. Logarithmic Regression

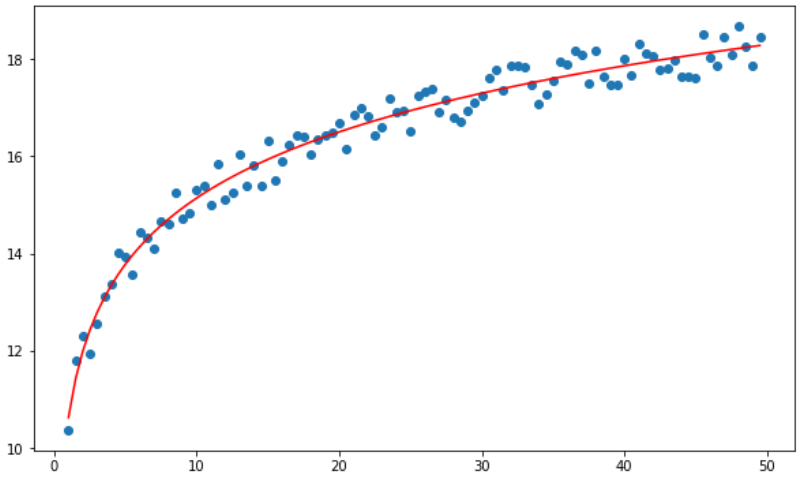

Graph for a logarithmic regression

Some real-life examples of logarithmic growth:

1. The magnitude of earthquakes.
2. The intensity of sound.
3. The acidity of a solution.
4. The pH level of solutions.
5. Yields of chemical reactions.
6. Production of goods.
7. Growth of infants.

Sometimes we have data that grows exponentially in the statement, but after a certain point, it goes flat. In such a case, we can use a logarithmic regression.

$$Y = a + b * \ln(X)$$

$Where,$

$Y = output$

$X = input\ feature$

$a = the\ line/curve\ always\ passes\ through\ (1, a)$

$b = controls\ the\ rate\ of\ growth\ or\ decay$

Step by step implementation:

a. Import required libraries:

b. Generating the dataset:

c. The first column of our matrix X :

d. Reshaping X:

e. Going with the Normal Equation formula:

f. Forming the main matrix X:

g. Finding the transpose matrix:

h. Performing matrix multiplication:

i. Finding the inverse:

j. Matrix multiplication:

k. Finding the coefficient values:

l. Plot the data with the regression curve:

6.8. Lojistik Regresyon

Bir veya birden fazla bağımsız değişkeni bulunan ve bir sonucu belirlemek için kullanılan istatistik yönetimidir. Var olan bir veri kümesinin analizi sonucu iki olası sonuçtan seçim yapılması imkanı verir. Sınıflandırma problemlerinde kullanılır. Lojistik regresyon, ikili(binary) 1 veya 0 olarak kodlanmış verileri içerir.

Lojistik regresyon, iki veri faktörü arasındaki ilişkileri bulmak için matematikten yararlanan bir veri analizi tekniğidir. Lojistik regresyon, daha sonra bağımsız değişken bağımlı değişkene dayalı faktörlerden birinin değerini tahmin etmek için bu ilişkiyi kullanır. Bağımsız değişken değişkenleri bağımlı değişkenler var. Bunları ikil ya da çoklu gruplandırılır. Yeni bir bağımsız değişken geldiğinde bunun hangi gruba ait olduğu belirlenir. Tahminin genellikle evet ya da hayır gibi sınırlı sayıda sonucu vardır.

Örneğin, web sitesi ziyaretçinizin alışveriş sepetindeki ödeme düğmesine tıklayıp tıklamayacağını tahmin etmek istediğinizi varsayalım. Lojistik regresyon analizi, web sitesinde harcanan zaman ve sepetteki ürün sayısı gibi geçmiş ziyaretçi davranışlarına bakar. Geçmişte, ziyaretçiler sitede beş dakikadan fazla zaman geçirdiyse ve sepete üçten fazla ürün eklediyse ödeme düğmesine tıkladıklarını belirler. Lojistik regresyon işlevi bu bilgiyi kullanarak daha sonra yeni bir web sitesi ziyaretçisinin davranışını tahmin edebilir.

Lojistik regresyon neden önemlidir?

Lojistik regresyon, yapay zeka ve makine öğrenimi (AI/ML) alanında önemli bir tekniktir. ML modelleri (Algoritmaları), insan müdahalesi olmadan karmaşık veri işleme görevlerini gerçekleştirmek için eğitebileceğiniz yazılım programlarıdır. Lojistik regresyon kullanılarak oluşturulan ML modelleri, kuruluşların iş verilerinden eyleme dönüştürülebilir öngörüler elde etmelerine yardımcı olur. Bu bilgileri operasyonel maliyetleri azaltmak, verimliliği artırmak ve daha hızlı ölçeklendirmek amacıyla tahmine dayalı analiz için kullanabilirler. Örneğin, işletmeler, çalışanların elde tutulmasını artıran veya daha kârlı ürün tasarımına yol açan kalıpları ortaya çıkarabilir.

Diğer ML tekniklerine göre lojistik regresyon kullanmanın bazı avantajları aşağıda verilmiştir:

- Basitlik: Lojistik regresyon modelleri matematiksel olarak diğer ML yöntemlerine göre daha az karmaşıktır. Bu nedenle, ekibinizdeki hiç kimsenin derinlemesine ML uzmanlığı olmasa bile bunları uygulayabilirsiniz.
- Hız: Lojistik regresyon modelleri, bellek ve işlem gücü gibi daha az hesaplama kapasitesine ihtiyaç duydukları için büyük hacimli verileri yüksek hızda işleyebilir. Bu da onları, ML projelerine başlayan kuruluşların hızlı kazançlar elde etmesi için ideal kılar.

- Esneklik: Lojistik regresyon, iki veya daha fazla sınırlı sonucu olan soruların yanıtlarını bulmak için kullanılabilir. Ayrıca verileri önceden işlemek için de kullanılabilir. Örneğin, banka işlemleri gibi çok çeşitli değerlere sahip verileri lojistik regresyon kullanarak daha küçük, sınırlı bir değer aralığında sıralayabilirsiniz. Daha sonra daha doğru analiz için diğer ML tekniklerini kullanarak bu küçük veri kümesini işleyebilirsiniz.
- Görünürlük: Lojistik regresyon analizi, geliştiricilere dahili yazılım süreçlerinde diğer veri analizi tekniklerinden daha fazla görünürlük sağlar. Hesaplamalar daha az karmaşık olduğundan sorun giderme ve hata düzeltme de daha kolaydır.

Lojistik regresyon uygulamaları nelerdir?

Lojistik regresyon birçok farklı sektörde birkaç gerçek dünya uygulamasına sahiptir.
Üretim: İmalat şirketleri, makinelerde parça arızası olasılığını tahmin etmek için lojistik regresyon analizini kullanır. Daha sonra gelecekteki arızaları en aza indirmek için bu tahmine dayalı olarak bakım programları planlarlar.

Sağlık hizmetleri: Tıbbi araştırmacılar, hastalarda hastalık olasılığını tahmin ederek önleyici bakım ve tedaviyi planlar. Aile öyküsünün veya genlerin hastalıklar üzerindeki etkisini karşılaştırmak için lojistik regresyon modelleri kullanırlar.

Finans: Finansal şirketlerin dolandırıcılık için finansal işlemleri analiz etmesi ve kredi başvurularını ve sigorta uygulamalarını risk açısından değerlendirmesi gerekir. Lojistik regresyon modellerinin yüksek riskli veya düşük riskli ve dolandırıcılık olan ya da olmayan gibi ayrı sonuçları olduğundan bu sorunlar lojistik regresyon modeli için uygundur.

Pazarlama: Çevrimiçi reklamcılık araçları, kullanıcıların bir reklama tıklayıp tıklamayacağını tahmin etmek için lojistik regresyon modelini kullanır. Sonuç olarak pazarlamacılar, farklı kelimelere ve resimlere verilen kullanıcı yanıtlarını analiz edebilir ve müşterilerin etkileşimde bulunacağı yüksek performanslı reklamlar oluşturabilir.

Regresyon analizi nasıl çalışır?

Lojistik regresyon, veri bilimcilerin makine öğreniminde (ML) yaygın olarak kullandığı birkaç farklı regresyon analizi tekniğinden biridir. Lojistik regresyonu anlamak için öncelikle temel regresyon analizini anlamalıyız. Aşağıda regresyon analizinin nasıl çalıştığını göstermek için bir doğrusal regresyon analizi örneği verilmiştir.
Soruyu tanımlanır: Herhangi bir veri analizi, bir iş sorusuyla başlar. Lojistik regresyon için belirli sonuçları elde etmek üzere soruyu çerçevelemelisiniz:

- Yağmurlu günler aylık satışlarımızı etkiler mi? (evet ya da hayır)
- Müşteri ne tür bir kredi kartı etkinliği gerçekleştiriyor? (yetkili, dolandırıcı veya potansiyel olarak dolandırıcı)

Geçmiş verileri toplanır: Soruyu tanımladıktan sonra, dahil olan veri faktörlerini belirlemeniz gerekir. Daha sonra tüm faktörler için geçmiş verileri toplarsınız. Örneğin, yukarıda gösterilen ilk soruyu cevaplamak üzere, son üç yılda her ay için yağmurlu günlerin sayısını ve aylık satış verilerinizi toplayabilirsiniz.

Regresyon analiz modelini eğitilir: Geçmiş verileri regresyon yazılımını kullanarak işlersiniz. Yazılım, farklı veri noktalarını işler ve denklemleri kullanıp bunları matematiksel olarak bağlar. Örneğin, üç aylık yağmurlu gün sayısı 3, 5 ve 8 ise ve o aylardaki satış sayısı 8, 12 ve 18 ise, regresyon algoritması faktörleri denklemle birleştirecektir:
Satış Sayısı = 2* (Yağmurlu Gün Sayısı) + 2

Bilinmeyen değerler için tahminlerde bulunur: Bilinmeyen değerler söz konusu olduğunda, yazılım bir tahmin yapmak için denklemi kullanır. Temmuz ayında altı gün yağmur yağacağını biliyorsanız yazılım, temmuz ayının satış değerini 14 olarak tahmin edecektir.

Lojistik regresyon modeli nasıl çalışır?

Lojistik regresyon modelini anlamak için önce denklemleri ve değişkenleri anlayalım. Denklemler: Matematikte denklemler iki değişken arasındaki ilişkiyi verir: *x* ve *y*. Bu denklemleri veya fonksiyonları, x ekseni ve y ekseni boyunca bir grafiği çizmek için farklı *x* ve *y* değerleri koyarak kullanabilirsiniz. Örneğin, *y* = 2**x* fonksiyonunun grafiğini çizerseniz aşağıda gösterildiği gibi düz bir çizgi elde edersiniz. Dolayısıyla bu fonksiyona doğrusal fonksiyon da denir.

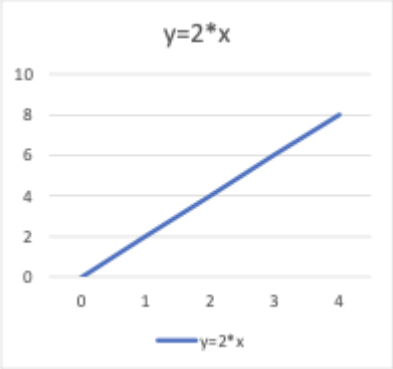

Değişkenler : İstatistikte değişkenler, veri faktörleri veya değerleri değişen özniteliklerdir. Herhangi bir analiz için, belirli değişkenler bağımsız veya açıklayıcı değişkenlerdir. Bu öznitelikler bir sonucun sebebidir. Diğer değişkenler; bağımlı değişkenler veya yanıt değişkenleridir ve değerleri bağımsız değişkenlere bağlıdır. Genel anlamda lojistik regresyon, her iki değişkenin geçmiş veri değerlerine bakarak bağımsız değişkenlerin bir bağımlı değişkeni nasıl etkilediğini araştırır.

Yukarıdaki örneğimizde *x*, bilinen bir değere sahip olduğundan bağımsız değişken, tahmin değişkeni veya açıklayıcı değişken olarak adlandırılır. *Y*'nin değeri bilinmediğinden buna bağımlı değişken, sonuç değişkeni veya yanıt değişkeni denir.

Lojistik regresyon fonksiyonu

Lojistik regresyon, matematikte *x* ve *y* arasındaki denklem olarak lojistik fonksiyonu veya logit fonksiyonu kullanan istatistiksel bir modeldir. Logit fonksiyonu, *y*'yi *x*'in sigmoid fonksiyonu olarak eşler.

$$f(x) = \frac{1}{1 + e^{-x}}$$

Bu lojistik regresyon denklemini çizerseniz aşağıda gösterildiği gibi bir S eğrisi elde edersiniz.

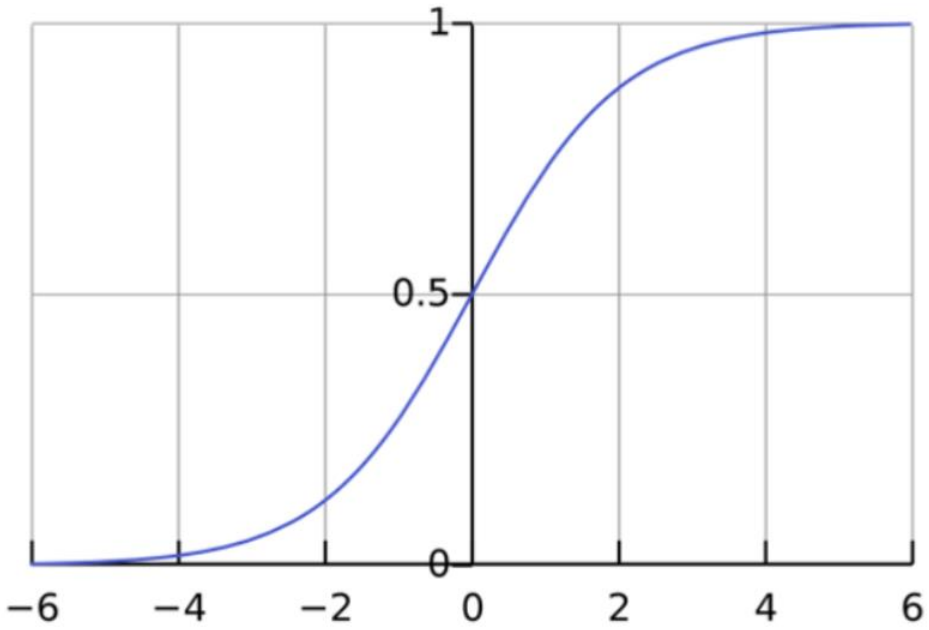

Gördüğünüz gibi, logit fonksiyonu bağımsız değişkenin değerlerinden bağımsız olarak bağımlı değişken için yalnızca 0 ile 1 arasındaki değerleri döndürür. Lojistik regresyon, bağımlı değişkenin değerini bu şekilde tahmin eder. Lojistik regresyon yöntemleri aynı zamanda çoklu bağımsız değişken ile bir bağımlı değişken arasındaki denklemleri de modellemektedir.

Sigmoid işlevi olarak da adlandırılan lojistik işlev, istatistikçiler tarafından geliştirildi, hızla yükseldi ve kapasitesini maksimuma çıkardı. 0 ile 1 arasındaki bir değerle eşleştirebilen, gerçek değerli herhangi bir sayı S şeklinde bir eğri üzerindeki deüere eşleştirilir.

Giriş değerleri (x), bir çıktı değerini (y) tahmin etmek için ağırlıklar veya katsayı değerleri kullanılır. Doğrusal regresyondan önemli bir fark, modellenen çıktı değerinin sayısal bir değerden ziyade ikili değerler (0 veya 1) olmasıdır. Aşağıda örnek bir lojistik regresyon denklemi verilmiştir:

$$y = \frac{e^{b_0+b_1x}}{1+e^{b_0+b_1x}}$$

e, doğal logaritmaların tabanıdır (Euler'in sayısı veya EXP () işlevi) ve değer, dönüştürmek istediğiniz gerçek sayısal değerdir. Aşağıda, lojistik fonksiyon kullanılarak 0 ve 1 aralığına dönüştürülmüş 0 ile 1 arasındaki sayıların bir grafiği bulunmaktadır.

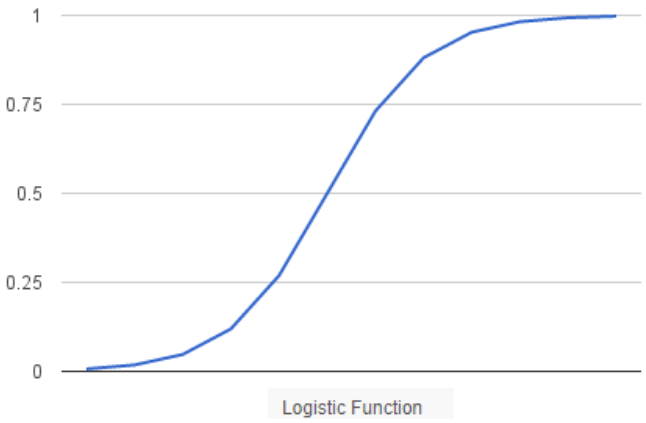

y'nin tahmin edilen çıktı olduğu durumlarda, b0 öngörü veya kesme terimidir ve b1, tek giriş değeri (x) için katsayıdır. Giriş verilerinizdeki her sütunun, eğitim verilerinizden öğrenilmesi gereken ilişkili bir b katsayısı (sabit bir gerçek değer) vardır. Bellekte veya bir dosyada depolayacağınız modelin gerçek temsili, denklemdeki katsayılardır.

Lojistik regresyon, varsayılan sınıfın olasılığını modeller:

Örneğin, eğer insanların cinsiyetini boylarından erkek veya kadın olarak modelliyorsak, lojistik regresyon modeli, bir kişinin boyuna göre erkek olma olasılığı olarak yazılabilir:

P (cinsiyet = erkek | boy)

Başka bir şekilde yazıldığında, bir girdinin (X) varsayılan sınıfa (Y = 1) ait olma olasılığını modelliyoruz, bu şu şekilde yazılır:

P (X) = P (Y = 1 | X)

Olasılıklar mı tahmin ediliyor? Oysa lLojistik regresyonun bir sınıflandırma algoritmasıdır. Gerçekte bir olasılık tahmini yapmak için olasılık tahmininin ikili değerlere (0 veya 1) dönüştürülmesi gerekir. Lojistik regresyon doğrusal bir yöntemdir, ancak tahminler lojistik fonksiyon kullanılarak dönüştürülür. Bunun etkisi, tahminleri artık doğrusal regresyonla yapabildiğimiz gibi girdilerin doğrusal bir kombinasyonu olarak anlayamayacağımızdır, örneğin yukarıdan devam edersek, model şu şekilde ifade edilebilir:

p (X) = e ^ (b0 + b1 * X) / (1 + e ^ (b0 + b1 * X))

Matematiğe çok fazla dalmak istemiyorum, ancak yukarıdaki denklemi aşağıdaki gibi döndürebiliriz (e'yi bir taraftan diğerine doğal bir logaritma (ln) ekleyerek kaldırabileceğimizi unutmayın):

ln (p (X) / 1 - p (X)) = b0 + b1 * X

Soldak orana varsayılan sınıfın olasılıkları denir. Oranlar, olayın olasılığının olay olmama olasılığına bölünmesiyle hesaplanır, ör. 0.8 / (1-0.8) olan 4'lük olasılık var. Yani bunun yerine şunu yazabiliriz:

ln (oranlar) = b0 + b1 * X

Oranlar log olarak dönüştürüldüğünden, sol tarafa log-olasılık denir.

Üssü sağa geri taşıyabilir ve şu şekilde yazabiliriz:

oran = e ^ (b0 + b1 * X)

Tüm bunlar, aslında modelin hala girdilerin doğrusal bir kombinasyonu olduğunu, ancak bu doğrusal kombinasyonun varsayılan sınıfın log-olasılıklarıyla ilgili olduğunu anlamamıza yardımcı olur.
Lojistik regresyon algoritmasının katsayıları (Beta değerleri b) eğitim verilerinizden tahmin edilmelidir. Bu, maksimum olasılık tahmini (maximum-likelihood estimation). kullanılarak yapılır.

Maksimum olasılık tahmini, çeşitli makine öğrenimi algoritmaları tarafından kullanılan ortak bir öğrenme algoritmasıdır, ancak verilerinizin dağıtımı hakkında varsayımlarda bulunur (verilerinizi hazırlamak hakkında konuştuğumuzda daha fazlası).

En iyi katsayılar, varsayılan sınıf için 1'e çok yakın bir değeri (örneğin erkek) ve diğer sınıf için 0'a çok yakın bir değeri (örneğin kadın) öngören bir modelle sonuçlanır. Lojistik regresyon için maksimum olasılık sezgisi, bir arama prosedürünün, model tarafından tahmin edilen olasılıklardaki hatayı verilerdekilerle en aza indiren katsayılar (Beta değerleri) için değerler aramasıdır (örneğin, veriler birincil ise 1 olasılığı sınıf).

Maksimum olasılığın matematiğine girmeyeceğiz. Eğitim verileriniz için katsayılar için en iyi değerleri optimize etmek için bir küçültme algoritmasının kullanıldığını söylemek yeterlidir. Bu genellikle pratikte verimli sayısal optimizasyon algoritması (Quasi-newton yöntemi gibi) kullanılarak uygulanır.

Lojistik öğrenirken, çok daha basit gradyan iniş algoritmasını kullanarak bunu kendiniz sıfırdan uygulayabilirsiniz.

Çok bağımsız değişkenli lojistik regresyon analizi

Çoğu durumda, birden fazla açıklayıcı değişken bağımlı değişkenin değerini etkiler. Lojistik regresyon formülleri, bu tür giriş verisi kümelerini modellemek için farklı bağımsız değişkenler arasında doğrusal bir ilişki olduğunu varsayar. Sigmoid fonksiyonunu değiştirebilir ve son çıktı değişkenini şu şekilde işleyebilirsiniz:

$y = f(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \ldots \beta_n x_n)$

β sembolü, regresyon katsayısını temsil eder. Logit modeli, hem bağımlı hem de bağımsız değişkenlerin bilinen değerlerine sahip yeterince büyük bir deneysel veri kümesi verdiğinizde bu katsayı değerlerini tersine hesaplayabilir.

Logaritmik olasılıklar

Logit modeli ayrıca başarının başarısızlığa oranını veya logaritmik olasılıkları da belirleyebilir. Örneğin, arkadaşlarınızla poker oynarken 10 maçtan dördünü kazanırsanız kazanma olasılığınız altıda dörttür ve bu da başarınızın başarısızlığa oranıdır. Öte yandan kazanma olasılığınız 10'da dörttür.

Matematiksel olarak, olasılık açısından olasılıklarınız $p/(1 - p)$ ve logaritmik olasılıklarınız $(p/(1 - p))$ şeklindedir. Lojistik fonksiyonu aşağıda gösterildiği gibi logaritmik olasılıklar olarak temsil edebilirsiniz:

$$\text{Logit Function} = \log\left(\frac{p}{1-p}\right)$$

Lojistik regresyon analizi türleri nelerdir?

Bağımlı değişkenin sonuçlarına dayalı olarak lojistik regresyon analizine ilişkin üç yaklaşım vardır.

- İkili lojistik regresyon: İkili lojistik regresyon, yalnızca iki olası sonucu olan ikili sınıflandırma problemlerinde işe yarar. Bağımlı değişkenin yalnızca "evet ve hayır" veya "0 ve 1" gibi iki değeri olabilir. Lojistik fonksiyon 0 ile 1 arasında bir değer aralığını hesaplasa da ikili regresyon modeli, cevabı en yakın değerlere yuvarlar. Çoğunlukla 0,5'in altındaki cevaplar 0'a yuvarlanır ve 0,5'in üzerindeki cevaplar 1'e yuvarlanır; böylece lojistik fonksiyon ikili bir sonuç döndürür.
- Çok terimli lojistik regresyon: Çok terimli regresyon, sonuçların sayısı sınırlı olduğu sürece birkaç olası sonucu olan problemleri analiz edebilir. Örneğin, konut fiyatlarının nüfus verilerine göre %25, %50, %75 veya %100 artacağını tahmin edebilir ancak bir evin tam değerini tahmin edemez. Çok terimli lojistik regresyon, sonuç değerlerini 0 ve 1 arasındaki farklı değerlerle eşleyerek çalışır. Lojistik fonksiyon 0,1; 0,11; 0,12 vb. gibi bir dizi sürekli veri döndürebildiğinden, çok terimli regresyon da çıktıyı mümkün olan en yakın değerlere göre gruplandırır.

- Sıralı lojistik regresyon: Sıralı lojistik regresyon veya sıralı logit modeli, sayıların gerçek değerlerden ziyade sıralamaları temsil ettiği problemler için özel bir çok terimli regresyon türüdür. Örneğin, müşterilerden sizden yıl boyunca satın aldıkları ürün sayısı gibi sayısal bir değere bağlı olarak hizmetinizi kötü, orta, iyi veya mükemmel şeklinde sıralamalarını isteyen bir anket sorusuna verdikleri yanıtı tahmin etmek için sıralı regresyon kullanırsınız.

Lojistik regresyon diğer ML tekniklerine kıyasla nasıl çalışır?

İki yaygın veri analizi tekniği; doğrusal regresyon analizi ve derin öğrenmedir.

Doğrusal regresyon analizi

Yukarıda açıklandığı gibi, doğrusal regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi doğrusal bir kombinasyon kullanarak modeller. Doğrusal regresyon denklemi $y= \beta_0X_0 + \beta_{1X1+\beta\ 2}X_2+... \beta\ _nX_n+$, burada β_1 ila β_n ve ε regresyon katsayısıdır.

Lojistik regresyon ve doğrusal regresyon karşılaştırması

Doğrusal regresyon, belirli bir bağımsız değişken kümesini kullanarak sürekli bağımlı bir değişkeni öngörür. Sürekli değişken, fiyat veya yaş gibi bir değer aralığına sahip olabilir. Dolayısıyla doğrusal regresyon, bağımlı değişkenin gerçek değerlerini tahmin edebilir. "10 yıl sonra pirinç fiyatı ne olacak?" gibi soruları yanıtlayabilir.

Doğrusal regresyonun aksine, lojistik regresyon bir sınıflandırma algoritmasıdır. Sürekli veriler için gerçek değerleri öngöremez. "Pirinç fiyatı 10 yılda% 50 artacak mı?" gibi soruları yanıtlayabilir.

Derin öğrenme

Derin öğrenme, bilgiyi analiz etmek için insan beynini simüle eden sinir ağlarını veya yazılım bileşenlerini kullanır. Derin öğrenme hesaplamaları, vektörlerin matematiksel kavramına dayanmaktadır.

Lojistik regresyon ve derin öğrenme karşılaştırması

Lojistik regresyon, derin öğrenmeye göre daha az karmaşıktır ve bilgi işlem açısından yoğunluğu daha azdır. Daha da önemlisi, derin öğrenme hesaplamaları, karmaşıklıkları ve makine odaklı doğaları gereği geliştiriciler tarafından araştırılamaz veya değiştirilemez. Diğer yandan, lojistik regresyon hesaplamaları şeffaftır ve sorunları gidermek daha kolaydır.

Lojistik Regresyon Modelini Öğrenmek:
Lojistik regresyon modeliyle tahmin yapmak, sayıları lojistik regresyon denklemine eklemek ve bir sonucu hesaplamak kadar basittir.

Bunu belirli bir örnekle somut hale getirelim. Diyelim ki bir kişinin boyuna göre erkek mi kadın mı olduğunu tahmin edebilen (tamamen hayal ürünü) bir modelimiz var. Boyu 150 cm olarak verildiğinde, erkek veya kadındır. b0 = -100 ve b1 = 0.6 katsayılarını öğrendik.

Yukarıdaki denklemi kullanarak, resmi olarak P (erkek | boy = 150) 150 cm veya daha fazla bir yükseklik verilen erkeğin olasılığını hesaplayabiliriz.

y = e ^ (b0 + b1 * X) / (1 + e ^ (b0 + b1 * X))
y = exp (-100 + 0.6 * 150) / (1 + exp (-100 + 0.6 * X))
y= 0,0000453978687

Kişinin erkek olma olasılığı sıfıra yakın. Pratikte olasılıkları doğrudan kullanabiliriz. Bu sınıflandırma olduğundan ve net bir cevap istediğimizden, olasılıkları ikili bir sınıf değerine yaslayabiliriz, örneğin: 0 eğer p (erkek) <0.5 1 eğer p (erkek)> = 0.5

Artık lojistik regresyon kullanarak nasıl tahminler yapacağımızı bildiğimize göre, teknikten en iyi şekilde yararlanmak için verilerimizi nasıl hazırlayabileceğimize bakalım.

Verilerin Lojistik Regresyon için Hazırlanması:
Verilerinizdeki dağılım ve ilişkiler hakkında lojistik regresyon tarafından yapılan varsayımlar, doğrusal regresyonda yapılan varsayımlarla büyük ölçüde aynıdır. Bu varsayımları tanımlamaya yönelik çok çalışma yapılmıştır ve kesin olasılık ve istatistiksel dil kullanılmıştır. Nihayetinde tahmine dayalı modelleme makine öğrenimi projelerinde, sonuçları yorumlamaktan çok doğru tahminler yapmaya odaklanırsınız.

Bu nedenle, model sağlam olduğu ve iyi performans gösterdiği sürece bazı varsayımları kırabilirsiniz.

İkili Çıktı Değişkeni: Lojistik regresyon ikili (iki sınıflı) sınıflandırma problemleri için tasarlanmıştır. Varsayılan sınıfa ait olan ve 0 veya 1 sınıflandırmasına dahil edilebilen bir örneğin olasılığını tahmin edecektir.

Gürültüyü Kaldır: Lojistik regresyon, çıktı değişkeninde (y) herhangi bir hata olmadığını varsayar, aykırı değerleri ve muhtemelen yanlış sınıflandırılmış örnekleri eğitim verilerinizden kaldırmayı düşünün.

Gauss Dağılımı: Lojistik regresyon doğrusal bir algoritmadır (çıktıda doğrusal olmayan bir dönüşüm ile). Girdi değişkenleri ile çıktı arasında doğrusal bir ilişki olduğunu varsayar. Bu doğrusal ilişkiyi daha iyi ortaya çıkaran girdi değişkenlerinizin veri dönüşümleri, daha doğru bir modelle sonuçlanabilir. Örneğin, bu ilişkiyi daha iyi ortaya çıkarmak için log, root, Box-Cox ve diğer tek değişkenli dönüşümleri kullanabilirsiniz.

İlişkili Girdileri Kaldır: Doğrusal regresyon gibi, çok sayıda yüksek korelasyonlu girdiniz varsa model gereğinden fazla sığabilir. Tüm girdiler arasındaki ikili korelasyonları hesaplamayı ve yüksek korelasyonlu girdileri kaldırmayı düşünün.

Yakınsama Başarısızlığı: Katsayıları öğrenen beklenen olasılık kestirim sürecinin yakınsamada başarısız olması mümkündür. Verilerinizde yüksek düzeyde ilişkili çok sayıda giriş varsa veya veriler çok seyrekse (örneğin, giriş verilerinizde çok fazla sıfır) bu durum meydana gelebilir.

Örnek: Logistic Regression

Lojistik regresyon, sınıflandırma problemlerini çözmeyi amaçlar. Bunu, sürekli bir sonucu öngören doğrusal regresyonun aksine, kategorik sonuçları tahmin ederek yapar.
En basit durumda, binom adı verilen iki sonuç vardır; buna bir örnek, bir tümörün kötü huylu mu yoksa iyi huylu mu olduğunu tahmin etmektir. Diğer durumların sınıflandırılması gereken ikiden fazla sonucu vardır, bu duruma multinomial denir. Çok terimli lojistik regresyon için yaygın bir örnek, 3 farklı tür arasında bir iris çiçeğinin sınıfını tahmin etmektir. Burada bir binom değişkenini tahmin etmek için temel lojistik regresyon kullanacağız. Bu, yalnızca iki olası sonucu olduğu anlamına gelir.

How does it work?
In Python we have modules that will do the work for us. Start by importing the NumPy module.

```
import numpy
```

Store the independent variables in X.
Store the dependent variable in y.
Below is a sample dataset:
#X represents the size of a tumor in centimeters.
X =

```
numpy.array([3.78, 2.44, 2.09, 0.14, 1.72, 1.65, 4.92, 4.37, 4.96, 4.52, 3.69, 5.88]).reshape(-1,1)
```

#Note: X has to be reshaped into a column from a row for the LogisticRegression() function to work.

#y represents whether or not the tumor is cancerous (0 for "No", 1 for "Yes").
y = numpy.array([0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1])

We will use a method from the sklearn module, so we will have to import that module as well:
from sklearn import linear_model
From the sklearn module we will use the LogisticRegression() method to create a logistic regression object.

This object has a method called fit() that takes the independent and dependent values as parameters and fills the regression object with data that describes the relationship:
logr = linear_model.LogisticRegression()
logr.fit(X,y)

Now we have a logistic regression object that is ready to whether a tumor is cancerous based on the tumor size:
#predict if tumor is cancerous where the size is 3.46mm:
predicted = logr.predict(numpy.array([3.46]).reshape(-1,1))

Example
See the whole example in action:
```
import numpy
from sklearn import linear_model
#Reshaped for Logistic function.
X =
numpy.array([3.78, 2.44, 2.09, 0.14, 1.72, 1.65, 4.92, 4.37, 4.96, 4.52, 3.69, 5.88]).reshape(-
1,1)
y = numpy.array([0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1])

logr = linear_model.LogisticRegression()
logr.fit(X,y)

#predict if tumor is cancerous where the size is 3.46mm:
predicted = logr.predict(numpy.array([3.46]).reshape(-1,1))
print(predicted)
```

Result: [0]

Uygulama:

Lojistik regresyon sınıflandırma problemlerini çözmeyi amaçlar. Bunu, sürekli bir sonucu öngören doğrusal regresyonun aksine, kategorik sonuçları tahmin ederek yapar. En basit durumda, bir tümörün kötü huylu mu yoksa iyi huylu mu olduğunu tahmin eden, binom olarak adlandırılan iki sonuç vardır. Diğer vakaların sınıflandırılması gereken ikiden fazla sonucu vardır, bu durumda buna çok terimli denir. Çok terimli lojistik regresyon için yaygın bir örnek, 3 farklı tür arasında bir iris çiçeğinin sınıfını tahmin etmek olabilir. Burada bir binom değişkenini tahmin etmek için temel lojistik regresyon kullanacağız. Bu, yalnızca iki olası sonucu olduğu anlamına gelir.

Nasıl çalışır?
Python'da işi yapacak modüller var. NumPy modülünü içe aktararak başlanır.
import numpy

Bağımsız değişkenleri X'te saklayın.
Bağımlı değişkeni y'de saklayın.

Aşağıda örnek bir veri seti verilmiştir:
#X represents the size of a tumor in centimeters.
X =
numpy.array([3.78, 2.44, 2.09, 0.14, 1.72, 1.65, 4.92, 4.37, 4.96, 4.52, 3.69, 5.88]).reshape(-1,1)

#Note: X has to be reshaped into a column from a row for the LogisticRegression() function to work.
#y represents whether or not the tumor is cancerous (0 for "No", 1 for "Yes").
y = numpy.array([0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1])

Sklearn modülünden bir metod kullanacağız, bu yüzden o modülü de import etmemiz gerekecek.
from sklearn import linear_model

Sklearn modülünden bir lojistik regresyon nesnesi oluşturmak için LogisticRegression() yöntemini kullanacağız. Bu nesnenin, bağımsız ve bağımlı değerleri parametre olarak alan ve regresyon nesnesini ilişkiyi tanımlayan verilerle dolduran fit() adlı bir yöntemi vardır:
logr = linear_model.LogisticRegression()
logr.fit(X,y)

Şimdi elimizde, tümör boyutuna göre bir tümörün kanserli olup olmadığına hazır olan bir lojistik regresyon nesnemiz var.

#predict if tumor is cancerous where the size is 3.46mm:
predicted = logr.predict(numpy.array([3.46]).reshape(-1,1))

Örnek: Tüm örneği çalışırken görülmesi.
import numpy
from sklearn import linear_model

#Reshaped for Logistic function.
X =
numpy.array([3.78, 2.44, 2.09, 0.14, 1.72, 1.65, 4.92, 4.37, 4.96, 4.52, 3.69, 5.88]).reshape(-1,1)
y = numpy.array([0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1])

logr = linear_model.LogisticRegression()
logr.fit(X,y)

#predict if tumor is cancerous where the size is 3.46mm:
predicted = logr.predict(numpy.array([3.46]).reshape(-1,1))
print(predicted)

Sonuç: 4.03541657

Bu bize bir tümörün boyutu 1 mm arttıkça tümör olma olasılığının 4 kat arttığını söyler.

Olasılık
Katsayı ve kesişme değerleri, her tümörün kanserli olma olasılığını bulmak için kullanılabilir. Yeni bir değer döndürmek için modelin katsayısını ve kesişme değerlerini kullanan bir işlev oluşturulur. Bu yeni değer, verilen gözlemin bir tümör olma olasılığını temsil eder.

```
def logit2prob(logr,x):
  log_odds = logr.coef_ * x + logr.intercept_
  odds = numpy.exp(log_odds)
  probability = odds / (1 + odds)
  return(probability)
```

İşlev Açıklaması: Her bir gözlem için log-oranları bulmak için, önce doğrusal regresyondan elde edilene benzeyen bir formül oluşturulmalıdır, katsayı ve kesişim çıkarılmalıdır.
*log_odds = logr.coef_ * x + logr.intercept_*

Daha sonra log oranlarını oranlara dönüştürmek için log oranlarının üssü alınır.
odds = numpy.exp(log_odds)

Artık oranlarımız olduğuna göre, onu 1 artı oranlara bölerek olasılığa dönüştürebiliriz.
probability = odds / (1 + odds)

Şimdi her tümörün kanserli olma olasılığını bulmak için öğrendiklerimizle işlevi kullanalım.

Örnek: Tüm örneğin çalışırken görülmesi.

```
import numpy
from sklearn import linear_model
X =
numpy.array([3.78, 2.44, 2.09, 0.14, 1.72, 1.65, 4.92, 4.37, 4.96, 4.52, 3.69, 5.88]).reshape(-
1,1)
y = numpy.array([0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1])
logr = linear_model.LogisticRegression()
logr.fit(X,y)

def logit2prob(logr, X):
  log_odds = logr.coef_ * X + logr.intercept_
  odds = numpy.exp(log_odds)
  probability = odds / (1 + odds)
  return(probability)

print(logit2prob(logr, X))
```

Sonuç:

```
  [[0.60749955]
   [0.19268876]
   [0.12775886]
   [0.00955221]
   [0.08038616]
   [0.07345637]
   [0.88362743]
   [0.77901378]
   [0.88924409]
   [0.81293497]
   [0.57719129]
   [0.96664243]]
```

Sonuçlar Açıklanması:
3,78 0,61 3,78 cm büyüklüğünde bir tümörün kanserli olma olasılığı %61'dir.
2,44 0,19 2,44 cm büyüklüğündeki bir tümörün kanserli olma olasılığı %60'tır.
2,09 0,13 2,09 cm büyüklüğündeki bir tümörün kanserli olma olasılığı %13'tür.

7. Kümeleme (Clustering) Algoritmaları

Verilerin yakınlık, uzaklık, benzerlik gibi ölçütlere göre analiz edilerek sınıflara ayrılmasına kümeleme denir. Kümeleme, denetimsiz öğrenmenin bir yöntemidir ve birçok alanda kullanılan istatistiksel veri analizi için yaygın bir tekniktir. Denetimsiz öğrenme, veri kümesi ile çıktıların olmadığı bir öğrenme metodudur. Veri kümesindeki verileri yorumlayarak ortak noktaları bulmak ve bunları kümeleştirme işlemi yapılarak anlamlı bir veri elde edebilmektir. Sistem, öğreten olmadan öğrenmeye çalışır. Ham verileri organize verilere dönüştüren bir makine öğrenimi türüdür.

Denetimsiz öğrenmede sadece sınıflandırılmamış veriler vardır bu verilerden sonuçlar çıkarılmaya çalışılır. Veriyi değişkenler arasındaki ilişkilere dayalı olarak kümeleyerek çeşitli modeller, yapılar oluşturulur.

Örneğin, bir alışveriş sitesinde alınan bir ürünün yanında kullanıcıların alabileceği diğer ürünlerin tavsiye olarak belirlenmesi. Ya da bir hizmet satın aldığında, o hizmetle etkileşimli diğer hizmetlerin müşterinin ilgi alanına girmesi.

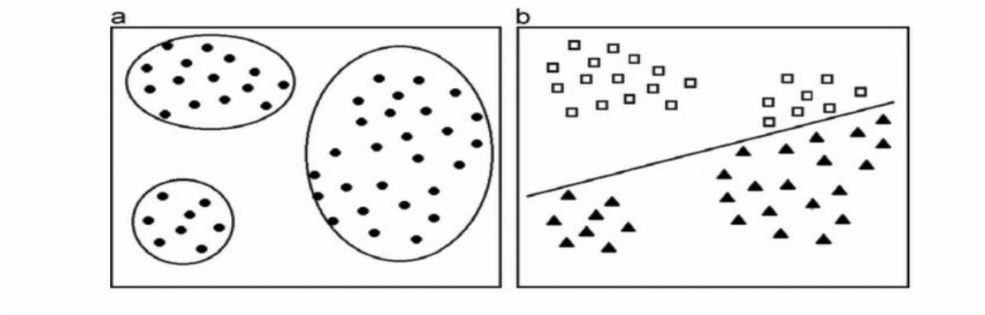

Kümeleme Sınıflandırma

Kümeleme algoritmaları, veri kümesindeki bileşenleri kendi aralarında benzerliklerinden gruplamaya çalışır. Burada kaç grup olacağı veya en uygun küme sayısını algoritmanın kendisi belirler.

Örnek: Bir sandık dolusu meyve içerisinden bir tane elmayı belirlesin. Ardından tüm elmaları bulan bir senaryo sizce nasıl olmalıdır? En sonunda sandıkta bir tane elma kalmaması yazdığın senrayonun hangi özelliği sağlanmış olur. Performans artmış, deneyim kazanmış olur.

Alışveriş yapılan bir markette kasiyerin bir robot olduğun düşünün ve tüm ürünler birbirine karışmış olsun. Elma bulup, onu tanıyıp diğer elemanları yığın içerisinde topladığını düşünün. Seçme işlemi devam ederken yetenek kazanarak performansını atırabilir; hatalı seçtiği

ürünler var ise ayıklayabilir. Böylece ürünlerin birbirlerine benzeme yakınlığı uzaklaşarak, ayrım yapma yeteneği artırılmış olur. Böylece sınılandırma da yapılmış olur.

Elmalar da kendi aralarında kümeleme yapılabilir mi? Aynı tipte verilerin değişik segmentlere bölünmüş halidir. Elinde örnekler var ama hangi veya kaç sınıfa ait olduğunu bilmiyor. Sınıfları(kümeleri) kendisi inşaa ediyor. Örneğin elimizde sadece domatesler varsa, ve bunları kalitelerine göre ayırılırsa bu kümeleme işlemidir.

Kümelemenin uygulama alanları:
Tıp'da elde edilen görüntülemeler üzerindeki farklıları analiz edilerek değişik nitelikler çıkartılabilir.

Suç Yerlerinin Belirlenmesi: Bir şehirdeki belirli bölgelerde mevcut olan suçlarla ilgili veriler, suç kategorisi, suç alanı ve ikisi arasındaki ilişki, bir şehirdeki ya da bölgedeki suça eğilimli alanlara ilişkin kaliteli bilgiler verebilir.

Oyuncu istatistiklerini analiz etmek: Oyuncu istatistiklerini analiz etmek, spor dünyasının her zaman kritik bir unsuru olmuştur ve artan rekabetle birlikte, makine öğrenmenin burada oynayacağı kritik bir rol vardır.

Çağrı Kaydı Detay Analizi: Bir çağrı detay kaydı (CDR), telekom şirketleri tarafından bir müşterinin araması, SMS ve internet etkinliği sırasında elde edilen bilgilerdir. Bu bilgiler, müşteri demografisiyle birlikte kullanıldığında, müşterinin ihtiyaçları hakkında daha fazla bilgi sağlar.

Müşteri Segmentasyonu:
Collaborative Filtering: Davranışları birbirine benzeyen insanların yaptıklarına bakılarak kümedeki birinin ne yapacağını kestirmek.
Tehdit ve Sahtekarlık Yakalama: Sınıflandırmada tehditlerin özellikleri makineye öğretilir. Kümelemede ise kümelerin dışında kalan , herhangi bir kümeye girmeyen örnek bir tehdit unsuru olarak tanımlanabilir.
Eksik Verilerin Tanımlanması: Örneğin birinin maaş bilgisi eksikse segmentte benzer kişilerin maaş ortalamasına göre bir maaş hesaplanabilir.

Pazar Segmentasyonu:
Davranışsal Segmentasyon: Örneğin ücretsiz uygulamaları yükleyenler neyi seçiyiorlar?
Demografik Segmentasyon: Müşterilerin yaşı, cinsiyeti, eğitim düzeyi ile davranışlarının entegre edilmesi.
Psikolojik Segmentasyon: Müşterilerin hayal-beklentilerine göre farklı ürünler sunulabilir.
Coğrafi Segmentasyon: Ülkelere şehirlere göre vs.

Kümeleme Çeşitleri:

- Hiyerarşik Kümeleme
- Gürültülü Uygulamaların Yoğunluğa Dayalı Konumsal Kümelenmesi (DBSCAN) (DBSCAN)
- K-means Kümeleme
- Ağırlık Ortalama Kaydırma Kümelemesi
- Gauss Karışım Modelleri (GMM) kullanarak Beklenti-Maksimizasyon (EM) Kümeleme

Ağırlık Ortalama Kaydırma Kümelemesi:

Ortalama kaydırma kümeleme, veri noktalarının yoğun alanlarını bulmaya çalışan kayan pencere tabanlı bir algoritmadır. Centroid tabanlı bir algoritmadır, yani amacın her bir grubun / sınıfın merkez noktalarını bulmaktır, bu da kayan pencere içindeki noktaların ortalaması olacak merkez noktaları için adayları güncelleyerek çalışır. Bu aday pencereler daha sonra, neredeyse kopyaları ortadan kaldırmak için bir işlem sonrası aşamasında filtrelenir ve nihai merkez noktaları ve bunlara karşılık gelen grupları oluşturur.

Sürgülü pencerelerin tümü ile uçtan uca tüm sürecin bir örneği aşağıda gösterilmiştir. Her siyah nokta, kayan bir pencerenin merkezini temsil eder ve her gri nokta bir veri noktasıdır.
Sınav sorusu: En son ağırlık ortalama burasıdır denmesi için nasıl bir senaryo hazırlanmalı?

1) Ortalama-kaymayı açıklamak için, yukarıdaki resimde olduğu gibi iki boyutlu uzayda bir dizi noktayı ele alacağız. Bir C noktasında ortalanmış (rastgele seçilmiş) ve çekirdek olarak r yarıçapına sahip dairesel bir kayan pencere ile başlıyoruz. Ortalama kayma, bu çekirdeği yakınsamaya kadar her adımda yinelemeli olarak daha yüksek yoğunluklu bir bölgeye kaydırmayı içeren bir tepe tırmanma algoritmasıdır.

2) Her yinelemede, kayan pencere, merkez noktası pencere içindeki noktaların ortalamasına kaydırılarak (dolayısıyla adı) daha yüksek yoğunluklu bölgelere kaydırılır. Sürgülü pencere içindeki yoğunluk, içindeki noktaların sayısı ile orantılıdır.

Doğal olarak, penceredeki noktaların ortalamasına geçerek, yavaş yavaş daha yüksek nokta yoğunluğuna sahip alanlara doğru hareket edecektir.

3) Bir kaymanın çekirdek içinde daha fazla noktayı barındırabileceği bir yön olmayana kadar ortalamaya göre kayan pencereyi kaydırmaya devam ediyoruz. Yukarıdaki grafiğe bakın; Artık yoğunluğu artırmayana kadar (yani penceredeki nokta sayısı) daireyi hareket ettirmeye devam ediyoruz.

4) 1'den 3'e kadar olan bu adım süreci, tüm noktalar bir pencerenin içinde kalana kadar birçok sürgülü pencerede yapılır. Birden çok sürgülü pencere örtüştüğünde, en çok noktayı içeren pencere korunur. Veri noktaları daha sonra bulundukları kayan pencereye göre kümelenir.

Gürültülü Uygulamaların Yoğunluğa Dayalı Konumsal Kümelenmesi (DBSCAN):
DBSCAN, ortalama kaymaya ekseninde, benzer ve yoğunluklu bölgeleri kümeleyen bir algoritmadır, ancak birkaç önemli avantajı vardır. Minimum bölge sayısında ve uzaklıkta maksimum yoğunluk bölgesi oluşturulması hedeflenir.

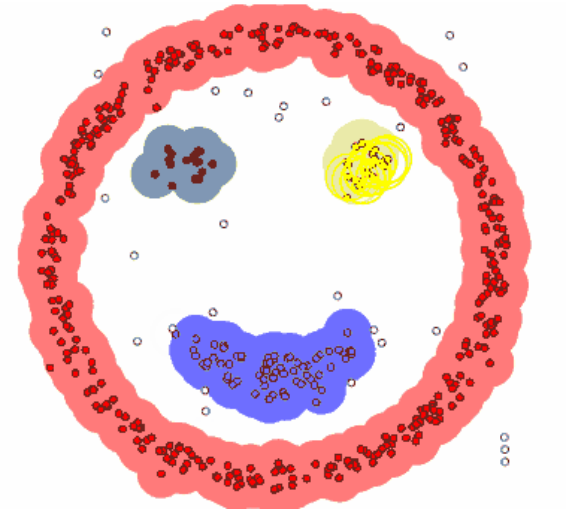

- DBSCAN, keyfi bir başlangıç veri noktasıyla başlar. Bu noktanın komşuluğu bir epsilon ε uzaklığı kullanılarak çıkarılır (ε mesafesi içindeki tüm noktalar komşuluk noktalarıdır).
- Bu mahalle içinde yeterli sayıda nokta (minPoints'e göre) varsa, kümeleme işlemi başlar ve mevcut veri noktası yeni kümedeki ilk nokta olur. Aksi takdirde, nokta gürültü olarak etiketlenecektir (daha sonra bu gürültülü nokta kümenin parçası haline gelebilir). Her iki durumda da bu nokta "ziyaret edildi" olarak işaretlenir.

- Yeni kümedeki bu ilk nokta için, ε mesafesi komşuluğundaki noktalar da aynı kümenin parçası olur. ε mahallesindeki tüm noktaları aynı kümeye ait yapma prosedürü, küme grubuna yeni eklenen tüm yeni noktalar için tekrarlanır.
- 2. ve 3. adımlardan oluşan bu süreç, kümedeki tüm noktalar belirlenene kadar, yani kümenin ε mahallesindeki tüm noktalar ziyaret edilip etiketlenene kadar tekrar edilir. Mevcut kümeyle işimiz bittiğinde, yeni bir ziyaret edilmemiş nokta alınır ve işlenir, bu da başka bir küme veya gürültü keşfine yol açar. Bu işlem, tüm noktalar ziyaret edildi olarak işaretlenene kadar tekrar eder.
- Bunun sonunda tüm noktalar ziyaret edildiğinden, her nokta bir kümeye ait veya gürültü olarak işaretlenecektir.

DBSCAN, diğer kümeleme algoritmalarına göre bazı büyük avantajlar sunar. İlk olarak, hiç bir küme gerektirmez. Ayrıca, veri noktası çok farklı olsa bile, aykırı değerleri basitçe bir kümeye atan ortalama kaymanın aksine, gürültü olarak tanımlar. Ek olarak, keyfi olarak boyutlandırılmış ve keyfi olarak şekillendirilmiş kümeleri oldukça iyi bulabilir. DBSCAN'ın ana dezavantajı, kümeler farklı yoğunlukta olduğunda diğerleri kadar iyi performans göstermemesidir. Bunun nedeni, komşu noktaların belirlenmesi için mesafe eşiği ε ve minPoints'in, yoğunluk değiştiğinde kümeden kümeye değişmesidir. Bu dezavantaj, çok yüksek boyutlu verilerde de ortaya çıkar, çünkü yine mesafe eşiğini ε tahmin etmek zorlaşır.

Gauss Karışım Modelleri (GMM) kullanarak Beklenti-Maksimizasyon (EM) Kümeleme:
K-Ortalamalarının en büyük dezavantajlarından biri, küme merkezi için ortalama değerin naif kullanımıdır. Aşağıdaki resme bakarak bunun bir şeyleri yapmanın en iyi yolu olmadığını anlayabiliriz. Sol tarafta, aynı ortalamaya merkezlenmiş farklı yarıçaplara sahip iki dairesel küme olduğu insan gözüne oldukça açık görünüyor. K-Ortalamalar bunun üstesinden gelemez çünkü kümelerin ortalama değerleri birbirine çok yakındır. K-Ortalamalar, yine ortalamanın küme merkezi olarak kullanılması sonucunda kümelerin dairesel olmadığı durumlarda başarısız olur.

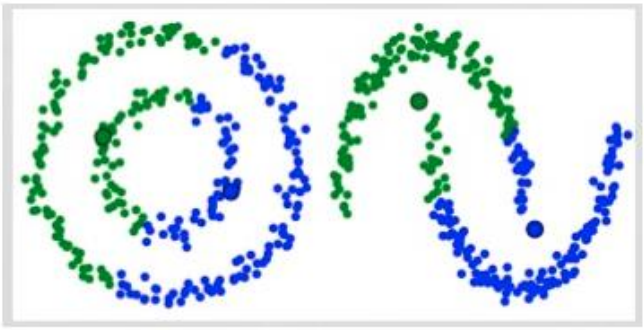

Two failure cases for K-Means

Gauss Karışım Modelleri (GMM'ler) bize K-Ortalamalarından daha fazla esneklik sağlar. GMM'ler ile veri noktalarının Gauss olarak dağıtıldığını varsayıyoruz; bu, ortalamayı

kullanarak döngüsel olduklarını söylemekten daha az kısıtlayıcı bir varsayımdır. Bu şekilde, kümelerin şeklini açıklamak için iki parametremiz var: ortalama ve standart sapma! İki boyutlu bir örnek alırsak, bu, kümelerin her türlü eliptik şekli alabileceği anlamına gelir (çünkü hem x hem de y yönlerinde standart bir sapmaya sahibiz). Böylece, her Gauss dağılımı tek bir kümeye atanır.

Her küme için Gauss'un parametrelerini bulmak için (örneğin ortalama ve standart sapma), Beklenti-Maksimizasyon (EM) adı verilen bir optimizasyon algoritması kullanacağız. Kümelere uydurulan Gaussian'ların bir örneği olarak aşağıdaki grafiğe bir göz atın. Daha sonra GMM'leri kullanarak Beklenti-Maksimizasyon kümeleme sürecine geçebiliriz.

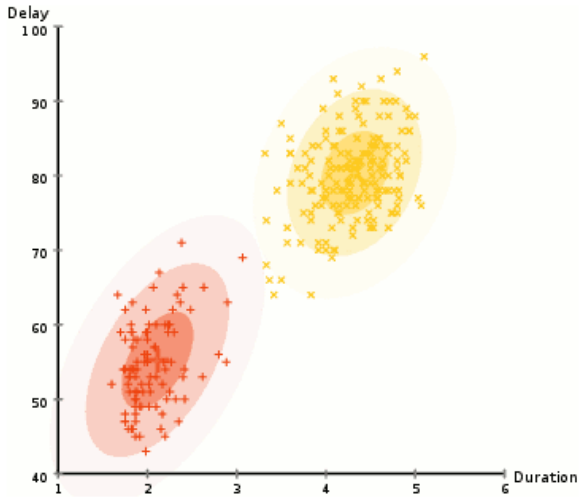

EM Clustering using GMMs

1) Küme sayısını seçerek (K-Means'ın yaptığı gibi) ve her küme için Gauss dağılım parametrelerini rastgele başlatarak başlıyoruz. Verilere de hızlıca göz atarak ilk parametreler için iyi bir tahmin sağlamaya çalışılabilir. Yine de, yukarıdaki grafikte de görülebileceği gibi, bu% 100 gerekli değildir çünkü Gauss bize çok zayıf olarak başlarlar, ancak hızla optimize edilirler.
2) Her küme için bu Gauss dağılımları göz önüne alındığında, her veri noktasının belirli bir kümeye ait olma olasılığı hesaplanır. Bir nokta Gauss'un merkezine ne kadar yakınsa, o kümeye ait olma olasılığı o kadar artar. Gauss dağılımında verilerin çoğunun kümenin merkezine daha yakın olduğunu varsaydığımız için, bu sezgisel bir anlam ifade etmelidir.
3) Bu olasılıklara dayanarak, kümeler içindeki veri noktalarının olasılıklarını maksimize edecek şekilde Gauss dağılımları için yeni bir dizi parametre hesaplıyoruz. Bu yeni parametreleri, veri noktası konumlarının ağırlıklı toplamını kullanarak hesaplıyoruz; burada ağırlıklar, o belirli kümeye ait veri noktasının olasılıklarıdır. Bunu görsel olarak açıklamak için yukarıdaki grafiğe, özellikle örnek olarak sarı kümeye bakabiliriz. Dağıtım ilk yinelemede rastgele başlar, ancak sarı noktaların çoğunun bu dağılımın

sağında olduğunu görebiliriz. Olasılıklara göre ağırlıklandırılmış bir toplamı hesapladığımızda, merkeze yakın bazı noktalar olmasına rağmen çoğu sağdadır. Dolayısıyla, doğal olarak dağılımın ortalaması bu noktalar kümesine daha da yakınlaşır. Ayrıca noktaların çoğunun "üstten-sağdan-aşağıya" olduğunu da görebiliriz. Bu nedenle standart sapma, olasılıkların ağırlıklandırdığı toplamı maksimize etmek için bu noktalara daha uygun bir elips oluşturmak üzere değişir.

4) Dağıtımların yinelemeden yinelemeye pek değişmediği yakınsamaya kadar 2. ve 3. adımlar yinelemeli olarak tekrarlanır.

GMM kullanmanın 2 önemli avantajı vardır. Birincisi, GMM'ler küme kovaryansı açısından K-Ortalamalarına göre çok daha esnektir; standart sapma parametresi nedeniyle, kümeler dairelerle sınırlı olmak yerine herhangi bir elips şeklini alabilir. K-Ortalamaları aslında her kümenin tüm boyutlardaki kovaryansının 0'a yaklaştığı özel bir GMM durumudur. İkinci olarak, GMM'ler olasılıkları kullandığından, veri noktası başına birden çok kümeye sahip olabilirler. Dolayısıyla, bir veri noktası üst üste binen iki kümenin ortasındaysa, sınıf 1'e yüzde X ve yüzde Y yüzde 2'ye ait olduğunu söyleyerek sınıfını tanımlayabiliriz. Yani GMM'ler karma üyeliği destekler.

Kümeleme Türleri:

Kümeleme, veri noktalarının benzerlik derecelerine göre farklı kümeler halinde gruplandırıldığı bir denetimsiz öğrenme türüdür.

Çeşitli kümeleme türleri şunlardır:

- Hiyerarşik kümeleme
- Bölümleme kümeleme

Hiyerarşik kümeleme ayrıca alt bölümlere ayrılır:

- Toplu kümeleme
- Bölücü kümeleme

Bölümleme kümeleme ayrıca şu alt bölümlere ayrılır:

- K-Ortalamalar kümeleme
- Bulanık C-Ortalamalar kümeleme

Hiyerarşik kümeleme, aşağıdaki gibi ağaç benzeri bir yapı kullanır:

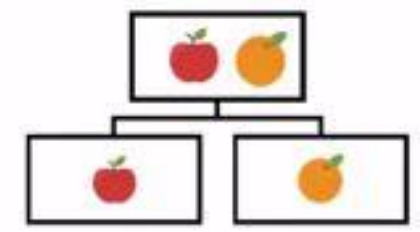

Aglomeratif kümelemede (agglomerative clustering) aşağıdan yukarıya bir yaklaşım vardır. Her bir öğeyle ayrı bir küme olarak başlıyoruz ve bunları aşağıda gösterildiği gibi art arda daha büyük kümeler halinde birleştiriyoruz:

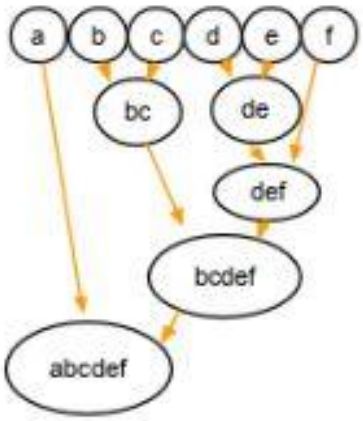

Bölücü kümelem **(Divisive clustering)** e yukarıdan aşağıya bir yaklaşımdır. Tüm setle başlıyoruz ve aşağıda görebileceğiniz gibi, onu art arda daha küçük kümelere bölmeye devam ediyoruz:

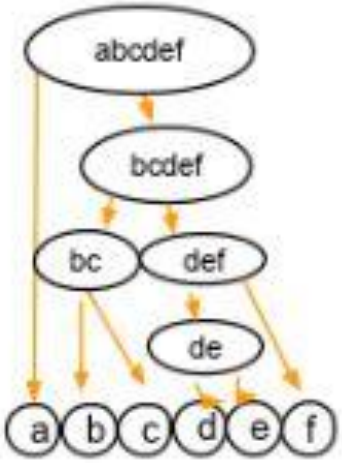

Bölümleme Kümeleme (Partitioning Clustering) iki alt türe ayrılır - K-Ortalamalar kümeleme ve Bulanık C-Ortalamalar. k-ortalama kümelemede, nesneler 'K' sayısı ile belirtilen birkaç kümeye ayrılır. Yani K = 2 dersek, nesneler gösterildiği gibi c1 ve c2 olmak üzere iki kümeye ayrılır:

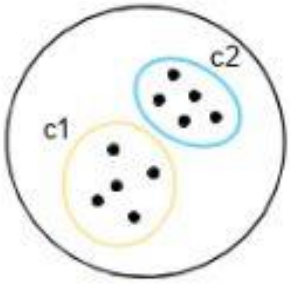

Burada özellikler veya özellikler karşılaştırılır ve benzer özelliklere sahip tüm nesneler birlikte kümelenir.

Bulanık c-ortalamalar (Fuzzy c-means), benzer özelliklere sahip nesneleri bir arada kümelemesi anlamında k-araçlarına çok benzer. k-ortalama kümelemede, tek bir nesne iki farklı kümeye ait olamaz. Ancak c-ortalamada nesneler gösterildiği gibi birden fazla kümeye ait olabilir.

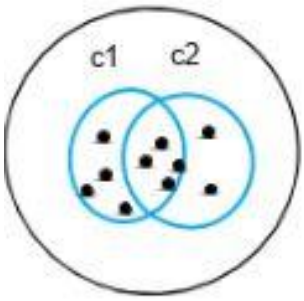

7.1. Hiyerarşik Kümeleme

Hiyerarşik kümeleme algoritmaları 2 kategoriye ayrılır: yukarıdan aşağıya veya aşağıdan yukarıya. Aşağıdan yukarıya algoritmalar, her veri noktasını başlangıçta tek bir küme olarak ele alır ve ardından tüm kümeler tüm veri noktalarını içeren tek bir kümede birleştirilene kadar küme çiftlerini art arda birleştirir (veya toplar). Bu nedenle aşağıdan yukarıya hiyerarşik kümeleme, hiyerarşik kümelemeli kümeleme (hierarchical agglomerative clustering) veya HAC olarak adlandırılır. Bu küme hiyerarşisi bir ağaç (veya dendrogram) olarak temsil edilir. Ağacın kökü, tüm örnekleri toplayan benzersiz kümedir, yapraklar yalnızca bir örnek içeren kümelerdir. Algoritma adımlarına geçmeden önce bir örnek için aşağıdaki grafiğe bakın

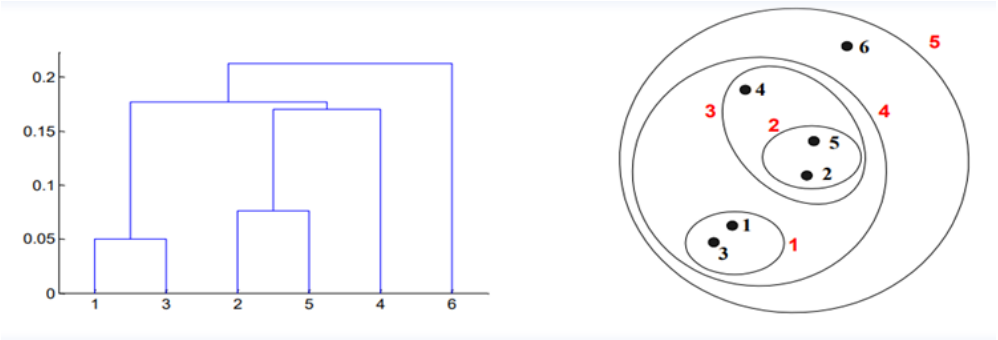

- Her veri noktasını tek bir küme olarak ele alarak başlıyoruz, yani veri kümemizde X veri noktası varsa, o zaman X kümemiz var. Daha sonra iki küme arasındaki mesafeyi ölçen bir mesafe ölçüsü seçiyoruz. Örnek olarak, iki küme arasındaki mesafeyi, birinci kümedeki veri noktaları ile ikinci kümedeki veri noktaları arasındaki ortalama mesafe olarak tanımlayan ortalama bağlantıyı kullanacağız.
- Her yinelemede, iki kümeyi tek bir kümede birleştiriyoruz. Birleştirilecek iki küme, en küçük ortalama bağlantıya sahip olanlar olarak seçilir. Yani, seçtiğimiz uzaklık ölçütümüze göre, bu iki küme birbirleri arasındaki en küçük mesafeye sahiptir ve bu nedenle en benzer olanlardır ve birleştirilmeleri gerekir.
- Adım 2, ağacın köküne ulaşana kadar tekrar edilir, yani tüm veri noktalarını içeren tek bir kümeye sahibiz. Bu şekilde sonunda kaç tane küme istediğimizi seçebiliriz, sadece kümeleri birleştirmeyi ne zaman durduracağımızı seçerek, yani ağacı oluşturmayı bıraktığımızda!

Hiyerarşik kümeleme, küme sayısını belirlememizi gerektirmez ve hatta bir ağaç oluşturduğumuz için hangi küme sayısının en iyi görüneceğini seçebiliriz. Ek olarak, algoritma mesafe ölçüsü seçimine duyarlı değildir; hepsi eşit derecede iyi çalışma eğilimindeyken, diğer kümeleme algoritmalarında uzaklık ölçüsü seçimi kritiktir. Hiyerarşik kümeleme yöntemlerinin özellikle iyi bir kullanım durumu, temeldeki verilerin hiyerarşik bir yapıya sahip olması ve hiyerarşiyi kurtarmak istemenizdir; diğer kümeleme algoritmaları bunu yapamaz. Hiyerarşik kümelemenin bu avantajları, K-Ortalamalarının ve GMM'nin doğrusal

karmaşıklığından farklı olarak, O (n^3) zaman karmaşıklığına sahip olduğundan, daha düşük verimlilik pahasına gelir.

Hiyerarşik kümeleme, veri noktalarını kümelemek için denetimsiz bir öğrenme yöntemidir. Algoritma, veriler arasındaki farklılıkları ölçerek kümeler oluşturur. Denetimsiz öğrenme, bir modelin eğitilmesi gerekmediği ve bir "hedef" değişkene ihtiyacımız olmadığı anlamına gelir. Bu yöntem, tek tek veri noktaları arasındaki ilişkiyi görselleştirmek ve yorumlamak için herhangi bir veri üzerinde kullanılabilir.

Burada veri noktalarını gruplamak ve hem bir dendrogram hem de dağılım grafiği kullanarak kümeleri görselleştirmek için hiyerarşik kümeleme kullanılacaktır.

Nasıl çalışır?
Aşağıdan yukarıya bir yaklaşımı izleyen bir tür hiyerarşik kümeleme olan Aglomeratif Kümeleme kullanılacaktır. Her veri noktası kendi kümesi olarak ele alınarak başlanır. Ardından, daha büyük kümeler oluşturmak için aralarında en kısa mesafeye sahip kümeler birleştirilir. Bu adım, tüm veri noktalarını içeren büyük bir küme oluşana kadar tekrarlanır. Hiyerarşik kümeleme, hem mesafe hem de bağlantı yöntemine karar verilmesini gerektirir. Öklid mesafesini ve kümeler arasındaki varyansı en aza indirmeye çalışan Ward bağlantı yöntemi kullanılacaktır.

Örnek: Bazı veri noktaları görselleştirilerek başlanır.
Pyhon kod örneği:

```
import numpy as np
import matplotlib.pyplot as plt
x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]
plt.scatter(x, y)
plt.show()
```

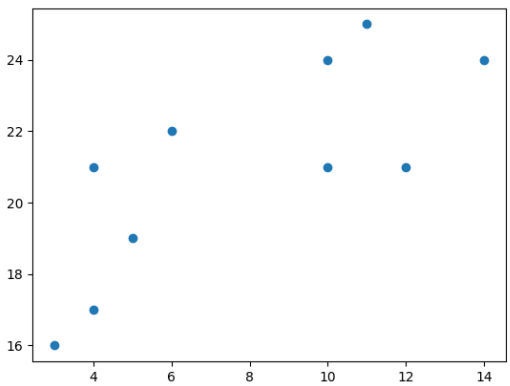

Şimdi koğuş bağlantısı (ward linkage) öklid mesafesi kullanılarak hesaplanır ve bu bir dendrogram kullanılarak görselleştirilir.

Python kod örneği:

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.cluster.hierarchy import dendrogram, linkage
x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]

data = list(zip(x, y))

linkage_data = linkage(data, method='ward', metric='euclidean')
dendrogram(linkage_data)

plt.show()
```

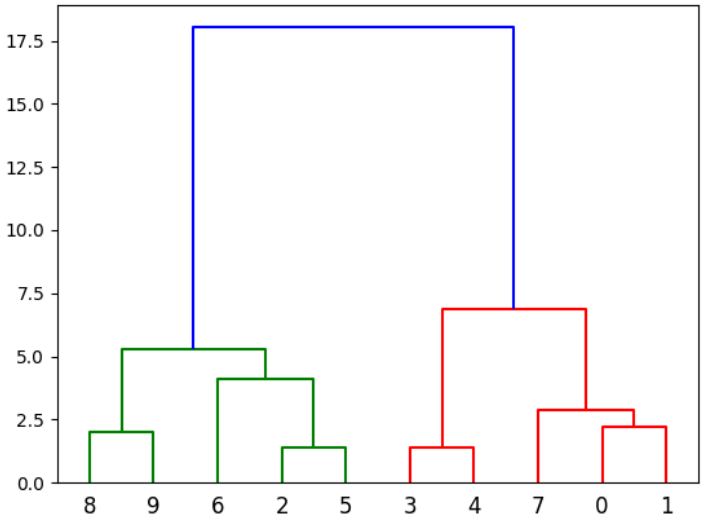

Burada aynı şeyi Python'un scikit-learn kütüphanesi ile yapılabilir. Ardından, 2 boyutlu bir alan üzerinde görselleştirilir.

Example

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.cluster import AgglomerativeClustering

x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]
```

data = list(zip(x, y))

hierarchical_cluster = AgglomerativeClustering(n_clusters=2,
affinity='euclidean', linkage='ward')
labels = hierarchical_cluster.fit_predict(data)

plt.scatter(x, y, c=labels)
plt.show()

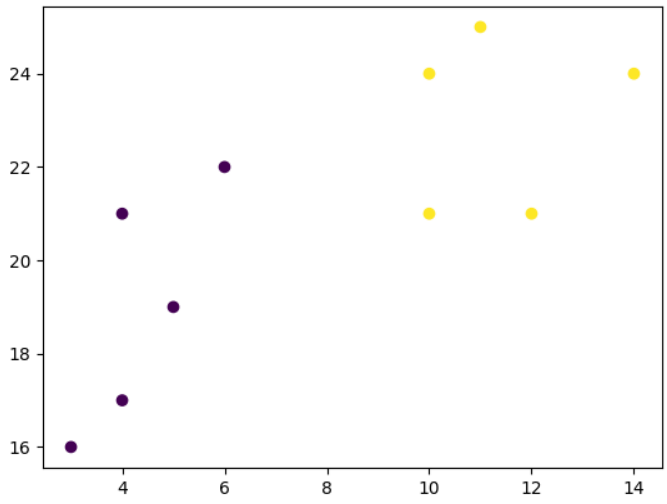

Örneğin açıklanması:
Import the modules you need.
import numpy as np
import matplotlib.pyplot as plt
from scipy.cluster.hierarchy import dendrogram, linkage
from sklearn.cluster import AgglomerativeClustering

NumPy, Python'da diziler ve matrislerle çalışmak için bir kütüphanedir.
scikit-learn, makine öğrenimi için popüler bir kütüphanedir.
Bir veri kümesinde iki değişkene benzeyen diziler oluşturulur. Burada sadece iki değişkenimiz olmasına rağmen, bu yöntemin herhangi bir sayıda değişkenle çalışacağı unutulmamalıdır:

x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]
Turn the data into a set of points:
data = list(zip(x, y))
print(data)

Sonuç:

[(4, 21), (5, 19), (10, 24), (4, 17), (3, 16), (11, 25), (14, 24), (6, 22), (10, 21), (12, 21)]

Tüm farklı noktalar arasındaki bağlantı hesaplanır. Burada basit bir öklid uzaklık ölçüsü ve kümeler arasındaki varyansı en aza indirmeye çalışan Ward'ın bağlantısı kullanılır.
linkage_data = linkage(data, method='ward', metric='euclidean')

Son olarak, sonuçlar bir dendrogramda çizilir. Bu çizim bize alttan (bireysel noktalar) yukarıya (tüm veri noktalarından oluşan tek bir küme) kümelerin hiyerarşisini gösterecektir. plt.show() sadece ham bağlantı verisi yerine dendrogramı görselleştirmemizi sağlar.

dendrogram(linkage_data)
plt.show()
Result:

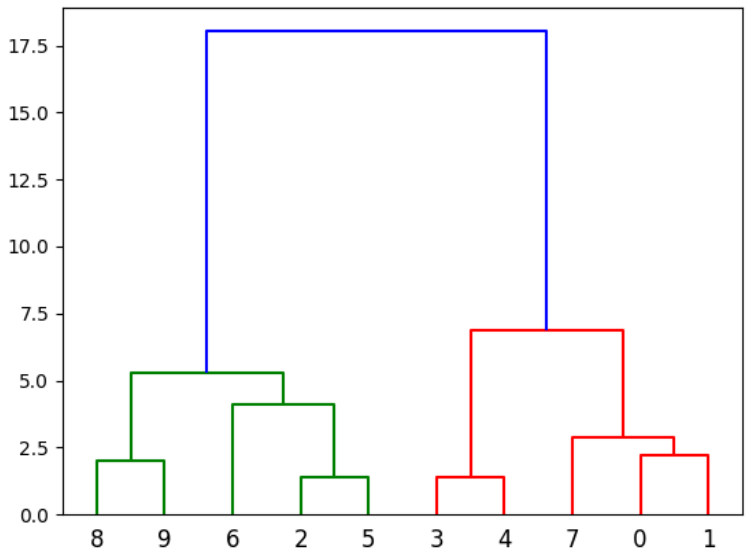

scikit-learn kitaplığı, hiyerarşik kümelemenin farklı bir şekilde kullanılmasına izin verir. İlk olarak, aynı öklid mesafesi ve Ward bağlantısı kullanılarak AgglomerativeClustering sınıfını 2 kümeyle başlatılır.
hierarchical_cluster = AgglomerativeClustering(n_clusters=2, affinity='euclidean', linkage='ward')

.fit_predict yöntemi, seçilen küme sayımızda tanımlanan parametreleri kullanarak kümeleri hesaplamak için verilerimiz üzerinde çağrılabilir.
scikit-learn kitaplığı, hiyerarşik kümelemeyi farklı bir şekilde kullanmamıza izin verir. İlk olarak, aynı öklid mesafesi ve Ward bağlantısı kullanılarak AgglomerativeClustering sınıfı 2 kümeyle başlatılır.
labels = hierarchical_cluster.fit_predict(data) print(labels)

Sonuç: [0 0 1 0 0 1 1 0 1 1]

Son olarak, hiyerarşik kümeleme yöntemiyle her bir dizine atanan etiketler kullanılarak aynı veriler çizilir ve noktalar renklendirilirse, her noktanın atandığı küme görülebilir:
plt.scatter(x, y, c=labels)
plt.show()

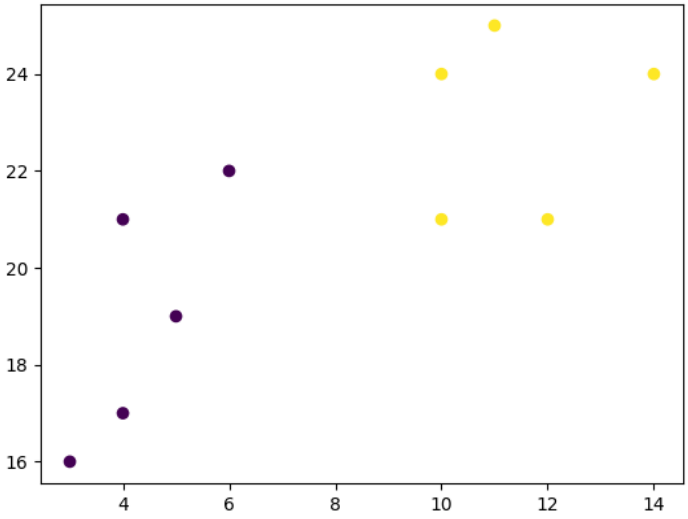

7.2. K-ortalama

K-Means Algoritması:

K-means algoritmasında kullanılan örneklem, k adet kümeye bölünür. Algoritmanın özü birbirlerine benzerlik gösteren verilerin aynı küme içerisine alınmasına dayanır. Algoritmadaki benzerlik terimi, veriler arasıdaki uzaklığa göre belirlenmektedir. Uzaklığın az olması benzerliğin yüksek, çok olması ise düşük olduğu anlamına gelmektedir.

K-means algoritmasının yapısı aşağıdaki gibidir;

1) K adet rastgele küme oluştur
2) Kare hata oranını hesapla
3) Verilerin kümelerin orta noktalarına olan uzaklıklarını bul
4) Her veri için en yakın kümeyi, o verinin kümesi olarak belirle
5) Yeni yerleşim düzenine göre hata oranını hesapla
6) Eğer önceki hata oranı ile şimdiki hata oranı eşit değilse 2,3,4,5 ve 6. adımları tekrarla
7) Eğer önceki hata oranı ile şimdiki hata oranı eşitse kümeleme işlemini sonlandır

Dirsek yöntemi, kümelere nasıl ihtiyaç duyacağımız konusunda kullanışlı olur. Dirsek noktasının belirlenmesi gerekir.

K-means, veri noktalarını kümelemek için denetimsiz bir öğrenme yöntemidir. Algoritma, her kümedeki varyansı en aza indirerek veri noktalarını yinelemeli olarak K kümelerine böler.

Nasıl çalışır?

İlk olarak, herhangi veri noktası rastgele olarak K kümelerinden birine atanır. Ardından, her kümenin ağırlık merkezini (işlevsel olarak merkez) hesaplarız ve her veri noktasını en yakın ağırlık merkezine sahip kümeye yeniden atarız. Her veri noktası için küme atamaları artık değişmeyene kadar bu işlemi tekrarlıyoruz.

K-ortalama kümeleme, verileri gruplandırmak istediğimiz küme sayısı olan K'yi seçmemizi gerektirir. Dirsek yöntemi, eylemsizliği (mesafeye dayalı bir ölçüm) grafiğini çıkarmamıza ve doğrusal olarak azalmaya başladığı noktayı görselleştirmemize olanak tanır. Bu nokta "elow" olarak adlandırılır ve verilerimize dayalı olarak K için en iyi değer için iyi bir tahmindir.

Örnek: Bazı veri noktalarını görselleştirerek başlayın.

```
import matplotlib.pyplot as plt
x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12,13,7,15,17,7,5,8]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21,18,20,29,21,22,15,14]
plt.scatter(x, y)
plt.show()
```

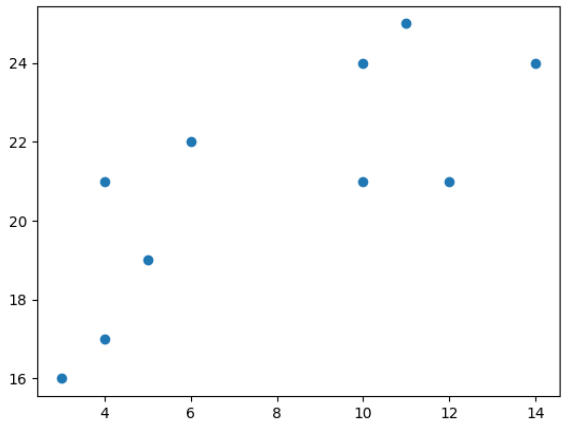

Şimdi farklı K değerleri için ataleti görselleştirmek için dirsek yöntemini (elbow method) kullanıyoruz.

Kod örneği:

```
from sklearn.cluster import KMeans
data = list(zip(x, y))
inertias = []

for i in range(1,11):
    kmeans = KMeans(n_clusters=i)
    kmeans.fit(data)
    inertias.append(kmeans.inertia_)

plt.plot(range(1,11), inertias, marker='o')
plt.title('Elbow method')
plt.xlabel('Number of clusters')
plt.ylabel('Inertia')
plt.show()
```

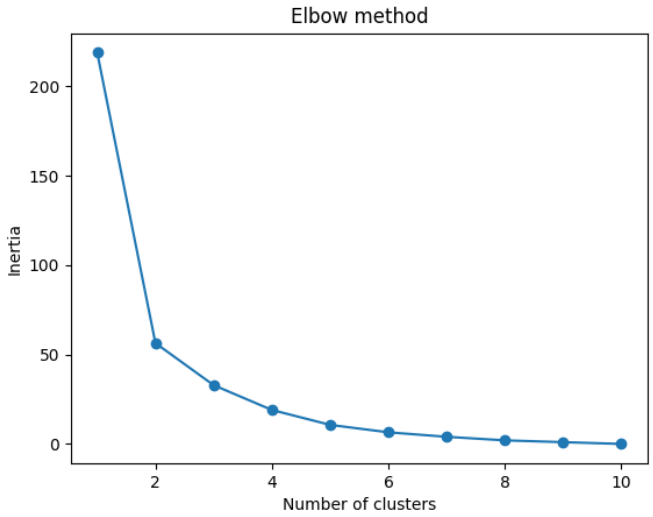

Dirsek yöntemi, 2'nin K için iyi bir değer olduğunu gösterir, bu nedenle sonucu yeniden eğitir ve görselleştiririz.

Kod Örneği:

kmeans = KMeans(n_clusters=2)
kmeans.fit(data)
plt.scatter(x, y, c=kmeans.labels_)
plt.show()

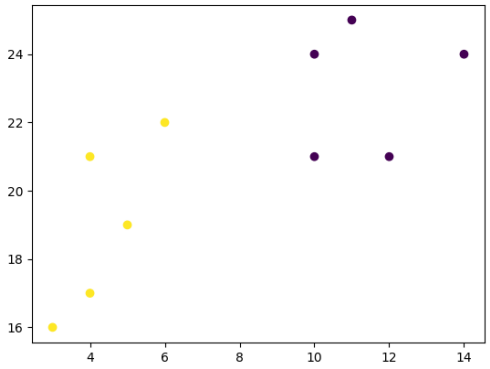

Örneğin açıklanması:
İhtiyaç duyulan modüller içe aktarılır.
import matplotlib.pyplot as plt
from sklearn.cluster import KMeans

from sklearn.cluster import Kmeans, K-Ortalama algoritmasına ait yazılımı kütüphaneden transfer eder.

scikit-learn, makine öğrenimi için popüler bir kütüphanedir. Bir veri kümesinde iki değişkene benzeyen diziler oluşturulur. Burada yalnızca iki değişken kullanırken, bu yöntemin herhangi bir sayıda değişkenle çalışacağını unutmayın:
x = [4, 5, 10, 4, 3, 11, 14 , 6, 10, 12]
y = [21, 19, 24, 17, 16, 25, 24, 22, 21, 21]

Veriler bir dizi noktaya dönüştürülür:
data = list(zip(x, y))
print(data)

Sonuç:
[(4, 21), (5, 19), (10, 24), (4, 17), (3, 16), (11, 25), (14, 24), (6, 22), (10, 21), (12, 21)]

K için en iyi değeri bulmak için, bir dizi olası değer için verilerimizde K-araçlarını çalıştırmamız gerekir. Yalnızca 10 veri noktamız var, dolayısıyla maksimum küme sayısı 10'dur. Böylece, (1,11) aralığındaki her K değeri için bir K-ortalama modeli eğitiriz ve bu küme sayısındaki intertia'yı çizeriz:

```
inertias = []

for i in range(1,11):
    kmeans = KMeans(n_clusters=i)
    kmeans.fit(data)
    inertias.append(kmeans.inertia_)

plt.plot(range(1,11), inertias, marker='o')
plt.title('Elbow method')
plt.xlabel('Number of clusters')
plt.ylabel('Inertia')
plt.show()
```

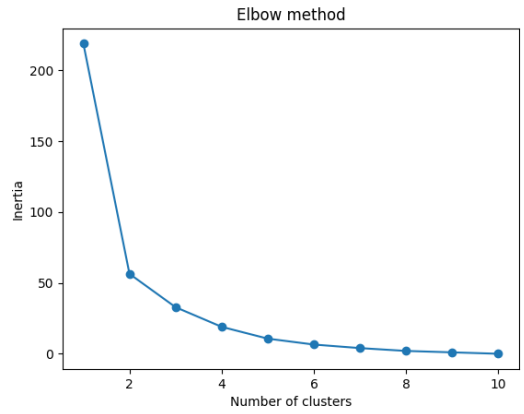

Yukarıdaki grafikte (interia'nın daha lineer hale geldiği) "dirsek"in K=2'de olduğunu görebiliriz. Daha sonra K-araç algoritmamızı bir kez daha uydurabilir ve verilere atanan farklı kümeleri çizebiliriz:

kmeans = KMeans(n_clusters=2)
kmeans.fit(data)

plt.scatter(x, y, c=kmeans.labels_)
plt.show()
Result:

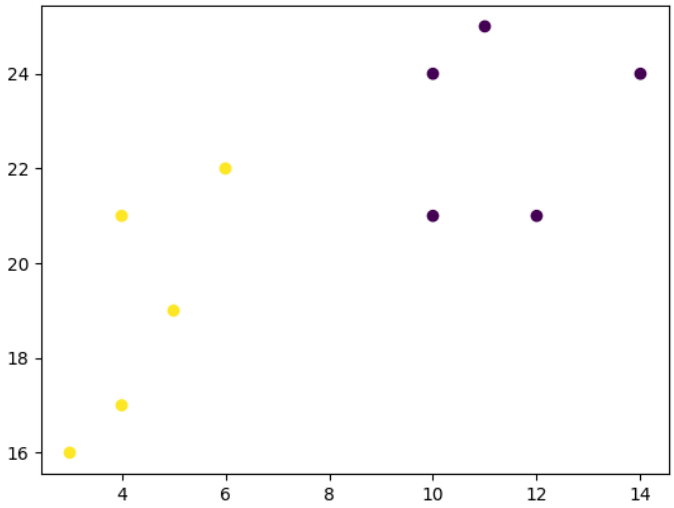

7.3. Temel Bileşen Analizi (Principal Component Analysis - PCA)

PCA (Principal Component Analysis) Temel Bileşenler Analizi

Türkçesi "Temel Bileşenler Analizi" olan PCA tanıma, sınıflandırma, görüntü sıkıştırma alanlarında kullanılan yararlı bir istatistiksel tekniktir. Temel amacı yüksek boyutlu verilerde en yüksek varyans ile veri setini tutmak ancak bunu yaparken boyut indirgemeyi sağlamak olan bir tekniktir. Fazla boyutlu verilerdeki genel özellikleri bularak boyut sayısının azaltılmasını, verinin sıkıştırılmasını sağlar. Boyut azalmasıyla bazı özelliklerin kaybedileceği kesindir; fakat amaçlanan, bu kaybolan özelliklerin veri yığını hakkında çok az bilgi içeriyor olmasıdır. Bu yöntem, yüksek korelasyonlu değişkenleri bir araya getirerek, verilerdeki en çok varyasyonu oluşturan "temel bileşenler" olarak adlandırılan daha az sayıda yapay değişken kümesi oluşturulur.

PCA verideki gerekli bilgileri ortaya çıkarmada oldukça etkili bir yöntemdir. PCA'in arkasında yatan temel mantık çok boyutlu bir veriyi, verideki temel özellikleri yakalayarak daha az sayıda değişkenle göstermektir.

PCA'yı daha iyi anlayabilmek için 2 boyutlu bir veri setimiz olduğunu hayal edin. Her boyut bir özellik sütunu olarak temsil edilebilir:

Feature 1	Feature 2
4	2
6	3
13	6
...	...

Aynı veri kümesini bir dağılım grafiği olarak temsil edebiliriz:

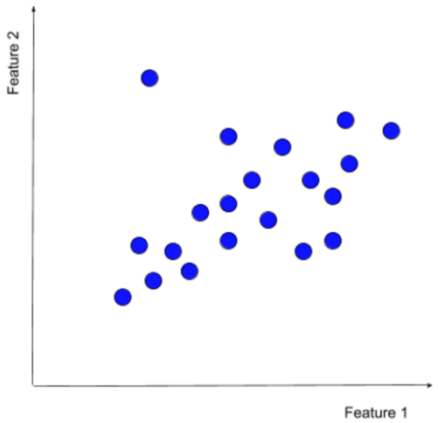

PCA'nın temel amacı, veri noktalarını bir dizi temel bileşenle tanımlayabilen bu tür temel bileşenleri bulmaktır.

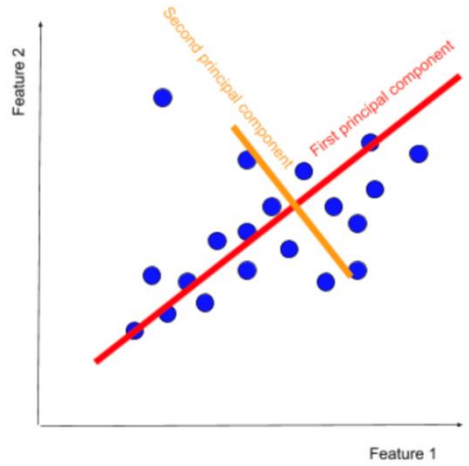

PCA'da Temel bileşenler vektörlerdir, ancak rastgele seçilmezler. İlk temel bileşen, orijinal özelliklerdeki en büyük varyansı (En küçük kareler metotu) açıklayacak şekilde hesaplanır. İkinci bileşen birinci bileşene diktir ve birinci ana bileşenden sonra kalan en büyük varyansı açıklar.

Orijinal veriler, özellik vektörleri olarak temsil edilebilir. PCA, bir adım daha ileri gitmemize ve verileri temel bileşenlerin doğrusal kombinasyonları olarak temsil etmemize olanak tanır. Temel bileşenlerin alınması, verilerin özellik1 x özellik2 ekseninden PCA1 x PCA2 eksenine doğrusal bir şekilde dönüştürülmesine eşdeğerdir.

Bu neden yararlıdır?

Yukarıdaki küçük 2 boyutlu örnekte, formun bir özellik vektörü (özellik1, özellik2), formun bir vektörüne (birinci ana bileşen (PCA1), ikinci asıl bileşen) çok benzer olacağından, PCA kullanarak fazla bir şey elde etmiyoruz. bileşen (PCA2)). Ancak çok büyük veri kümelerinde (boyut sayısının 100 farklı değişkeni geçebildiği), ana bileşenler çok sayıda özelliği yalnızca birkaç temel bileşene indirgeyerek gürültüyü ortadan kaldırır. Temel bileşenler, verilerin düşük boyutlu uzaya dikey projeksiyonlarıdır.

PCA ne için kullanılır?

Algoritma kendi başına kullanılabilir veya başka bir makine öğrenme algoritmasından önce kullanılan bir veri temizleme veya veri ön işleme tekniği olarak hizmet edebilir.

Kendi başına PCA, çeşitli kullanım durumlarında kullanılır:

1. Çok boyutlu verileri görselleştirir. Veri görselleştirmeleri, çok boyutlu verileri 2 veya 3 boyutlu grafikler olarak iletmek için harika bir araçtır.
2. Bilgileri sıkıştırır. Temel Bileşen Analizi, verileri daha verimli bir şekilde depolamak ve iletmek için bilgileri sıkıştırmak için kullanılır. Örneğin çok fazla kalite kaybetmeden görüntüleri sıkıştırmak için veya sinyal işlemede kullanılabilir. Teknik, örüntü tanıma

(özellikle yüz tanıma), görüntü tanıma ve daha fazlasında çok çeşitli sıkıştırma problemlerinde başarıyla uygulanmıştır.
3. Karmaşık iş kararlarını basitleştirir. PCA, geleneksel olarak karmaşık iş kararlarını basitleştirmek için kullanılmıştır. Örneğin, tüccarlar portföyleri yönetmek için 300'den fazla finansal araç kullanır. Algoritma, faiz oranı türev portföylerinin risk yönetiminde başarılı olduğunu kanıtladı ve finansal araçların sayısını 300'den fazla olanlardan 3-4 ana bileşene indirdi.
4. Kıvrımlı bilimsel süreçleri netleştirir. Algoritma, sinirsel toplulukların aksiyon potansiyellerini tetikleme olasılığını artıran dolambaçlı ve çok yönlü faktörlerin anlaşılmasında kapsamlı bir şekilde uygulanmıştır.

Ön işlemenin bir parçası olarak PCA kullanıldığında, algoritma şunlara uygulanır:
1. Eğitim veri kümesindeki boyutların sayısını azaltır.
2. Verilerin gürültüsünü giderir. PCA, en büyük varyansı açıklayan bileşenleri bularak hesaplandığından, verilerdeki sinyali yakalar ve gürültüyü atlar.

PCA'yı hesaplamanın birden fazla yolu vardır:
1. Kovaryans matrisinin öz bileşimi
2. Veri matrisinin tekil değer ayrıştırması
3. Güç yinelemeli hesaplama yoluyla özdeğer yaklaşımı
4. Doğrusal olmayan yinelemeli kısmi en küçük kareler (NIPALS) hesaplaması
5. … ve daha fazlası.

PCA'nın daha derin bir takdirini kazanmak için ilk yönteme - kovaryans matrisinin öz bileşimine - daha yakından bakalım. PCA'nın hesaplanmasında birkaç adım vardır:
1. Özellik standardizasyonu. Her özelliği ortalama 0 ve varyansı 1 olacak şekilde standartlaştırıyoruz. Daha sonra varsayımlarda ve sınırlamalarda açıklayacağımız gibi, farklı büyüklük sıralarında değerlere sahip özellikler PCA'nın en iyi temel bileşenleri hesaplamasını engeller.
2. Kovaryans matrisi hesaplamasını elde edin. Kovaryans matrisi, d'nin "boyut" (veya verilerimiz tablo halindeyse özellik veya sütun) anlamına geldiği d x d boyutlarında bir kare matristir. Her bir özellik arasındaki ikili özellik korelasyonunu gösterir.
3. Kovaryans matrisinin öz bileşimini hesaplayın. Kovaryans matrisinin özvektörlerini (birim vektörler) ve bunlarla ilişkili özdeğerlerini (özvektörü çarptığımız skalerler) hesaplarız. Lineer cebirinizi tazelemek istiyorsanız, bu özbileşim bilginizi yenilemek için iyi bir kaynaktır.
4. Özvektörleri en yüksek özdeğerden en düşüğe doğru sıralayın. En yüksek özdeğere sahip özvektör, ilk temel bileşendir. Daha yüksek özdeğerler, açıklanan daha fazla paylaşılan varyansa karşılık gelir.
5. Ana bileşenlerin sayısını seçin. N ana bileşen olmak için en üstteki N özvektörleri (özdeğerlerine göre) seçin. Optimum temel bileşen sayısı hem öznel hem de soruna bağlıdır. Genellikle, temel bileşenlerin kombinasyonu tarafından açıklanan paylaşılan varyansın

kümülatif miktarına bakarız ve paylaşılan varyansı hala önemli ölçüde açıklayan bu sayıda bileşen seçeriz.

Veri bilimcilerinin çoğunun PCA'yı elle hesaplamayacağını, bunun yerine Python'da ScikitLearn ile uygulayacağını veya hesaplamak için R'yi kullanacağını unutmayın. Bu matematiksel temeller, PCA anlayışımızı zenginleştirir, ancak uygulanması için gerekli değildir. PCA'yı anlamak, avantajları ve dezavantajları hakkında daha iyi bir fikre sahip olmamızı sağlar.

PCA'nın avantajları ve dezavantajları nelerdir?

PCA birden fazla fayda sağlar, ancak aynı zamanda bazı eksikliklerden de muzdariptir.

PCA'nın Avantajları:

1. Hesaplaması kolaydır. PCA, bilgisayarlar tarafından hesaplanması kolay olan doğrusal cebire dayanmaktadır.
2. Diğer makine öğrenimi algoritmalarını hızlandırır. Makine öğrenimi algoritmaları, orijinal veri kümesi yerine temel bileşenler üzerinde eğitildiğinde daha hızlı birleşir.
3. Yüksek boyutlu veri sorunlarına karşı koyar. Yüksek boyutlu veriler, regresyona dayalı algoritmaların kolayca fazla uyum sağlamasına neden olur. Eğitim veri kümesinin boyutlarını azaltmak için önceden PCA'yı kullanarak, tahmine dayalı algoritmaların gereğinden fazla takılmasını önleriz.

PCA'nın Dezavantajları:

1. Temel bileşenlerin düşük yorumlanabilirliği. Temel bileşenler, orijinal verilerdeki özelliklerin doğrusal kombinasyonlarıdır, ancak yorumlanması o kadar kolay değildir. Örneğin, temel bileşenleri hesapladıktan sonra veri kümesindeki en önemli özelliklerin hangileri olduğunu söylemek zordur.
2. Bilgi kaybı ve boyutsallık azaltma arasındaki değiş tokuş. Boyut azaltma yararlı olsa da, bir bedeli vardır. Bilgi kaybı, PCA'nın gerekli bir parçasıdır. Boyut azaltma ve bilgi kaybı arasındaki dengeyi dengelemek, ne yazık ki PCA kullanırken yapmamız gereken gerekli bir uzlaşmadır.

4. PCA'nın varsayımları ve sınırlamaları nelerdir?

PCA, Pearson korelasyonundaki bir dizi işlemle ilgilidir, bu nedenle benzer varsayımları ve sınırlamaları devralır:

1) PCA, özellikler arasında bir korelasyon olduğunu varsayar. Özellikler (veya tablo verilerindeki boyutlar veya sütunlar) ilişkili değilse, PCA temel bileşenleri belirleyemez.
2) PCA, özelliklerin ölçeğine duyarlıdır. İki özelliğimiz olduğunu hayal edin - biri 0 ile 1000 arasında değerler alırken, diğeri 0 ile 1 arasında değerler alır. PCA, verilerdeki gerçek maksimum varyanstan bağımsız olarak birinci ilke bileşeni olan ilk özelliğe aşırı derecede yanlı olacaktır. Bu yüzden önce değerleri standartlaştırmak çok önemlidir.

3) PCA aykırı değerlere karşı dayanıklı değildir. Yukarıdaki noktaya benzer şekilde, algoritma güçlü aykırı değerlere sahip veri kümelerinde yanlı olacaktır. Bu nedenle, PCA gerçekleştirmeden önce aykırı değerlerin kaldırılması önerilir.
4) PCA, özellikler arasında doğrusal bir ilişki olduğunu varsayar. Algoritma, doğrusal olmayan ilişkileri yakalamak için pek uygun değildir. Bu nedenle, doğrusal olmayan özelliklerin veya özellikler arasındaki ilişkilerin, günlük dönüşümleri gibi standart yöntemler kullanılarak doğrusal hale getirilmesi önerilir.
5) Teknik uygulamalar genellikle hiçbir eksik değer olmadığını varsayar. İstatistiksel yazılım araçlarını kullanarak PCA'yı hesaplarken, genellikle özellik kümesinin eksik değerleri (boş satırlar) olmadığını varsayarlar. Eksik değerlere sahip satırları ve/veya sütunları kaldırdığınızdan veya eksik değerleri yakın bir tahminle (örneğin, sütunun ortalaması) eklediğinizden emin olun.

PCA, verilerdeki makul olduğu kadar çok bilgiyi işleyen bir projeksiyon yapmaya çalışır. Bu bir boyut küçültme tekniğidir. En yüksek varyansa sahip yönleri bulur ve boyutları küçültmek için verileri bunlarla birlikte yansıtır.

Calculation steps of PCA:
Let there is an **N*1** vector with values x*1*, x*2*, ….., x*m.*

- Calculate the sample mean:

$$\bar{x} = 1/M \sum_{i=1}^{M} x_i$$

- Subtract sample mean with vector value:

$$\Phi = x_i - \bar{x}$$

- Calculate the sample covariance matrix:

$$\Sigma_x = 1/M \sum_{i=1}^{M} \Phi_i \Phi_i^T = 1/MAA^T$$

$$\text{Where, } A = [\Phi_1 \ \Phi_2 \ .... \ \Phi_n]$$

n * m matrix

- Calculate the eigenvalues and eigenvectors of the covariance matrix

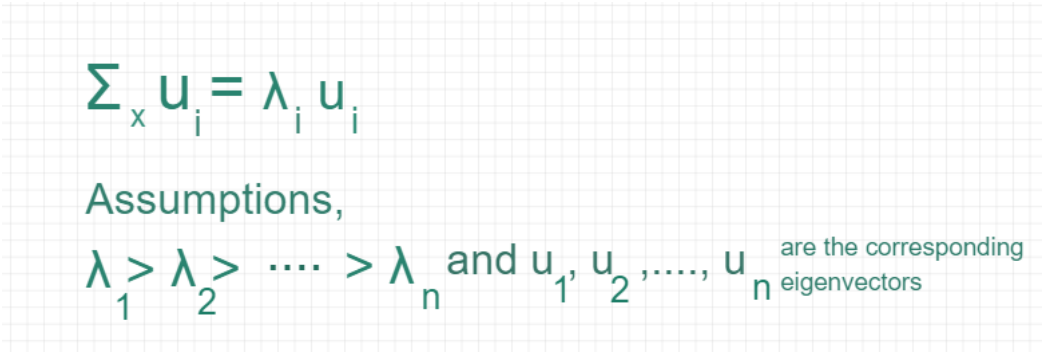

- **Dimensionality reduction**: approximate x using only the first k eigenvectors (k< N).

Python Implementation of the Principal Component Analysis (PCA)

The main goal of Python's implementation of the PCA:

- Implement the covariance matrix.
- Derive eigenvalues and eigenvectors.
- Understand the concept of dimensionality reduction from the PCA.

Loading the Iris data

import numpy as npimport pylab as plimport pandas as pdfrom sklearn import datasetsimport matplotlib.pyplot as pltfrom sklearn.preprocessing import StandardScalerload_iris = datasets.load_iris()iris_df = pd.DataFrame(load_iris.data, columns=[load_iris.feature_names])iris_df.head()

	sepal length (cm)	sepal width (cm)	petal length (cm)	petal width (cm)
0	5.1	3.5	1.4	0.2
1	4.9	3.0	1.4	0.2
2	4.7	3.2	1.3	0.2
3	4.6	3.1	1.5	0.2
4	5.0	3.6	1.4	0.2

Standardization

It is always good to standardize the data to keep all features of the data in the same scale.

standardized_x = StandardScaler().fit_transform(load_iris.data)standardized_x[:2]

```
array([[-0.90068117,  1.01900435, -1.34022653, -1.3154443 ],
       [-1.14301691, -0.13197948, -1.34022653, -1.3154443 ]])
```

Compute Covariance Matrix

covariance_matrix_x = np.cov(standardized_x.T)covariance_matrix_x

```
array([[ 1.00671141, -0.11835884,  0.87760447,  0.82343066],
       [-0.11835884,  1.00671141, -0.43131554, -0.36858315],
       [ 0.87760447, -0.43131554,  1.00671141,  0.96932762],
       [ 0.82343066, -0.36858315,  0.96932762,  1.00671141]])
```

Compute Eigenvalues and Eigenvectors from Covariance Matrix

eigenvalues, eigenvectors = np.linalg.eig(covariance_matrix_x)eigenvalues

```
array([2.93808505, 0.9201649 , 0.14774182, 0.02085386])
```

eigenvectors

```
array([[ 0.52106591, -0.37741762, -0.71956635,  0.26128628],
       [-0.26934744, -0.92329566,  0.24438178, -0.12350962],
       [ 0.5804131 , -0.02449161,  0.14212637, -0.80144925],
       [ 0.56485654, -0.06694199,  0.63427274,  0.52359713]])
```

Check variance in Eigenvalues

total_of_eigenvalues = sum(eigenvalues)vararianc = [(i / total_of_eigenvalues)*100 for i in sorted(eigenvalues, reverse=True)]vararianc

```
[72.96244541329989, 22.850761786701753, 3.668921889282865, 0.5178709107154905]
```

The values shown in figure indicate the variance giving the analysis below:

- 1st Component = 72.96%
- 2nd Component = 22.85%
- 3rd Component = 3.5%
- 4th Component = 0.5%

So, the **third** and **fourth** Components have very low variance respectively. These can be dropped. Because these components can't add any value.

Taking 1st and 2nd Components only and Reshaping

eigenpairs = [(np.abs(eigenvalues[i]), eigenvectors[:,i]) for i in range(len(eigenvalues))]# Sorting from Higher values to lower valueeigenpairs.sort(key=lambda x: x[0], reverse=True)eigenpairs

```
[(2.938085050199995,
  array([ 0.52106591, -0.26934744,  0.5804131 ,  0.56485654])),
 (0.9201649041624864,
  array([-0.37741762, -0.92329566, -0.02449161, -0.06694199])),
 (0.1477418210449475,
  array([-0.71956635,  0.24438178,  0.14212637,  0.63427274])),
 (0.020853862176462696,
  array([ 0.26128628, -0.12350962, -0.80144925,  0.52359713]))]
```

Perform Matrix Weighing of Eigenparis

matrix_weighing =

np.hstack((eigenpairs[0][1].reshape(4,1),eigenpairs[1][1].reshape(4,1)))matrix_weighing

```
array([[ 0.52106591, -0.37741762],
       [-0.26934744, -0.92329566],
       [ 0.5804131 , -0.02449161],
       [ 0.56485654, -0.06694199]])
```

Multiply the standardized matrix with matrix weighing:

Y = standardized_x.dot(matrix_weighing)Y

```
array([[-2.26470281, -0.4800266 ],
       [-2.08096115,  0.67413356],
       [-2.36422905,  0.34190802],
       [-2.29938422,  0.59739451],
       [-2.38984217, -0.64683538],
       [-2.07563095, -1.48917752],
       [-2.44402884, -0.0476442 ],
       [-2.23284716, -0.22314807],
       [-2.33464048,  1.11532768],
       [-2.18432817,  0.46901356],
       [-2.1663101 , -1.04369065],
       [-2.32613087, -0.13307834],
       [-2.2184509 ,  0.72867617],
       [-2.6331007 ,  0.96150673],
```

Plotting

plt.figure()target_names = load_iris.target_names

y = load_iris.targetfor c, i, target_name in zip("rgb", [0, 1, 2], target_names):

plt.scatter(Y[y==i,0], Y[y==i,1], c=c, label=target_name)plt.xlabel('PCA 1')

plt.ylabel('PCA 2')

plt.legend()

plt.title('PCA')

plt.show()

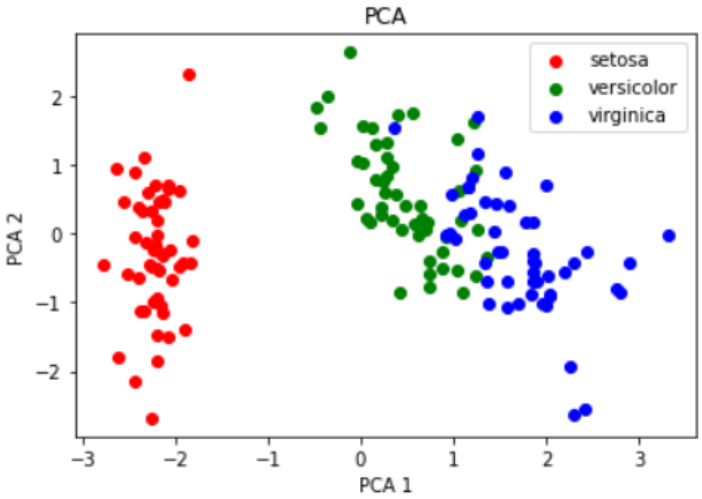

Matrix Decomposition or Matrix Factorization

Matrix Decomposition or factorization is also an important part of linear algebra used in machine learning. Basically, it is a factorization of the matrix into a product of matrices. There are several techniques of matrix decomposition like LU decomposition, Singular value decomposition (SVD), etc.

Singular Value Decomposition (SVD)

It is a technique for the reduction of dimension. As per singular value decomposition matrix: Let M is a rectangular matrix and can be broken down into three products of matrix — (1) orthogonal matrix (U), (2) diagonal matrix (S), and (3) transpose of the orthogonal matrix (V).

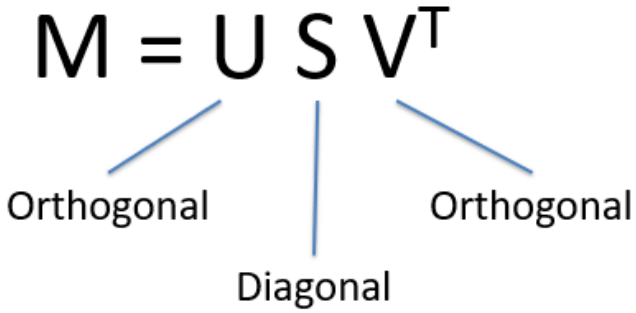

Conclusion

Machine learning and deep learning has been build upon the concept of mathematics. A vast area of mathematics is used to build algorithms and also for the computation of data. Linear algebra is the study of vectors [10] and several rules to manipulate vectors. It is a key infrastructure, and it covers many areas of machine learning like linear regression, one-hot encoding in the categorical variable, PCA (Principle component analysis) for the dimensionality reduction, matrix factorization for recommender systems.

Deep learning is completely based on linear algebra and calculus. It is also used in several optimization techniques like gradient descent, stochastic gradient descent, and others. Matrices are an essential part of linear algebra that we use to compactly represent systems of linear equations, linear mapping, and others. Also, vectors are unique objects that can be added together and multiplied by scalars that produce another object of similar kinds. Any suggestions or feedback is crucial to continue to improve. Please let us know in the comments if you have any.

Uygulama:

Veri setimiz üzerinde PCA yapabilmek için sklearn kütüphanesinden PCA metotunu çağırmamız gereklidir. Öncelikle iris veri setimizi sklearn'den indirelim. iris veri setimizde 3 farklı sınıfa ait 4 öznitelik bulunmaktadır.

```
In [1]: ## import load_iris dataset
        from sklearn.datasets import load_iris
        import matplotlib.pyplot as plt
        import pandas as pd
        import numpy as np
        import seaborn as sns

In [2]: iris = load_iris()
        data = iris.data
        feature_names = iris.feature_names
        y = iris.target

In [3]: y

Out[3]: array([0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
               0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
               0, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,
               1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,
               1, 1, 1, 1, 1, 1, 1, 1, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2,
               2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2,
               2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2])

In [4]: df = pd.DataFrame(data,columns = feature_names)
        df["sinif"] = y
        x = data
        df.head()

Out[4]:
```

	sepal length (cm)	sepal width (cm)	petal length (cm)	petal width (cm)	sinif
0	5.1	3.5	1.4	0.2	0
1	4.9	3.0	1.4	0.2	0
2	4.7	3.2	1.3	0.2	0
3	4.6	3.1	1.5	0.2	0
4	5.0	3.6	1.4	0.2	0

Veri seti üzerinde yapmış olduğumuz PCA dönüşümü bize 2 bileşen seçmenin, verilerin toplam varyansının yaklaşık % 97.7'sini koruyabileceğimizi söylemektedir. Tüm bileşenleri kullanmak istemediğimiz sadece **ana bileşenleri** kullanmak istediğimiz için bu varyans oranı bizim için yeterlidir.

```
In [5]: ##88 PCA
        from sklearn.decomposition import PCA
        pca = PCA(n_components = 2, whiten= True )  # whitten = normalize
        pca.fit(x)

        x_pca = pca.transform(x)

        print("variance ratio: ", pca.explained_variance_ratio_)

        print("sum: ",sum(pca.explained_variance_ratio_))

        variance ratio:  [ 0.92461621  0.05301557]
        sum:  0.977631775025

In [6]: pca = PCA( whiten= True).fit(x)
        plt.plot(np.cumsum(pca.explained_variance_ratio_))
        plt.xlabel('number of components')
        plt.ylabel('cumulative explained variance');
        plt.show()
```

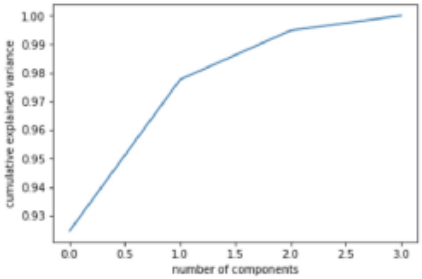

```
In [7]: df_sns = pd.DataFrame({'var':pca.explained_variance_ratio_,
                               'PC':['PC1','PC2','PC3','PC4']})

        df_sns
```

Out[7]:

	PC	var
0	PC1	0.924616
1	PC2	0.053016
2	PC3	0.017185
3	PC4	0.005183

```
In [8]: sns.barplot(x='PC',y="var",data=df_sns, color="c")
        plt.ylabel("Variance Explained")
        plt.xlabel("Principle Components")
        plt.show()
```

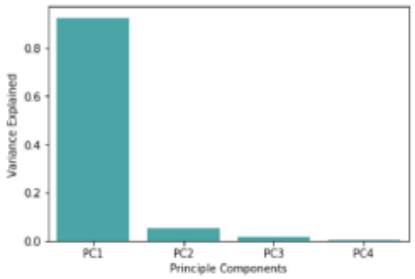

PCA dönüşümü işlemini tamamladıktan sonra sınıfların iki boyutlu vektörlerini aşağıdaki grafikte görebiliriz.

```
In [9]: df["p1"] = x_pca[:,0]
        df["p2"] = x_pca[:,1]

        color = ["red","green","blue"]
```

```
In [10]: for each in range(3):
             plt.scatter(df.p1[df.sinif == each],df.p2[df.sinif == each],color = color[each],label = iris.target_names[each])

         plt.legend()
         plt.xlabel("p1")
         plt.ylabel("p2")
         plt.show()
```

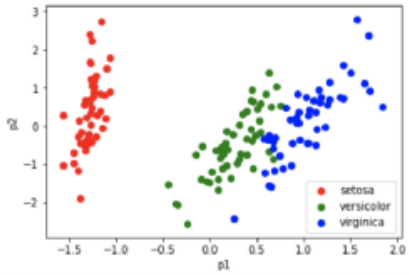

8. Derin Öğrenme Algoritmaları

Derin öğrenme, tamamen yapay sinir ağlarına dayanan bir makine öğrenimi alt kümesidir. Sinir ağları insan beynini taklit edecek şekilde tasarlandığından, derin öğrenme de aynı şekilde bir insan beyni taklitçisidir.

Derin öğrenmede her şeyi açıkça programlamak zorunda değiliz. Bir modeli eğitim veri kümesi üzerinde eğitiriz ve model, test ve doğrulama veri kümesinde de neredeyse doğru tahminde bulunana kadar onu doğaçlama yaparız.

Derin öğrenme modelleri, programcıdan yalnızca küçük bir girdi ile kendi başlarına doğru özelliklere odaklanabilir ve boyutsallık sorununu çözmede oldukça faydalıdır. Derin öğrenme yeni bir kavram değildir. Bir süredir ortalıkta dolaşıyor. Şu anda sahip olduğumuz kadar fazla işlem gücüne veya veriye sahip olmadığımız için bu günlerde tüm işlem gücü son 20 yılda muazzam bir şekilde arttığından, sahneye derin öğrenme ve makine öğrenimi girdi.

1960'ların ortalarında bir derin öğrenme ağı üzerinde çalışırken, Alexey Grigorevich Ivakhnenko ilk yayını yayınladı. Esasen, çok sayıda doğrusal olmayan işlem birimi kullanarak özellik çıkarma ve dönüştürme yapan bir makine öğrenimi alt kümesidir. Sonraki katmanların her biri, bir önceki katmanın çıktısını girdi olarak kullanır. Derin öğrenme, bilgisayarla görme, konuşma tanıma, doğal dil işleme vb. dahil olmak üzere çeşitli uygulamalar için uygundur.

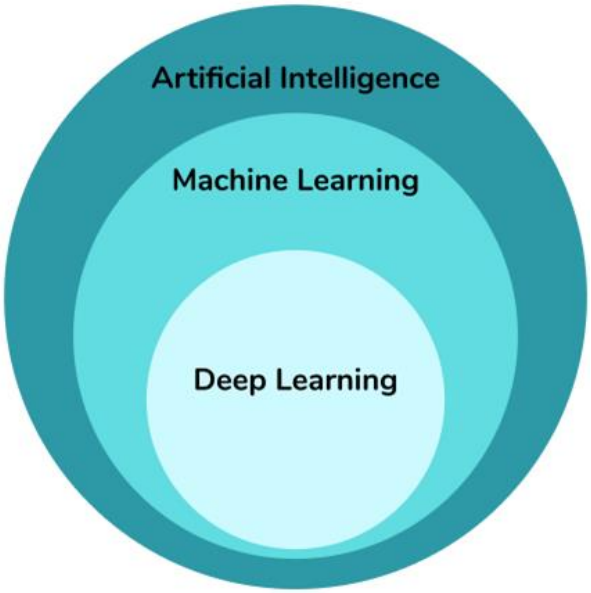

Yukarıdaki görüntü, Makine Öğreniminin Yapay Zekanın bir alt kümesi olduğunu ve Derin Öğrenmenin, Makine Öğreniminin bir alt kümesi olduğunu göstermektedir.

Derin öğrenme (aynı zamanda derin yapılandırılmış öğrenme, hiyerarşik öğrenme ya da derin makine öğrenmesi) bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Yani en az bir adet yapay sinir ağının (YSA) kullanıldığı ve birçok algoritma ile, bilgisayarın eldeki verilerden yeni veriler elde etmesidir. Derin öğrenme gözetimli, yarı gözetimli veya gözetimsiz olarak gerçekleştirilebilir. Derin yapay sinir ağları pekiştirmeli öğrenme yaklaşımıyla da başarılı sonuçlar vermiştir.

Derin öğrenme, Yüksek bilgi işleme gücü ve büyük veri kümeleriyle birlikte katmanlı yapay sinir ağlarının güçlü matematiksel modelleri oluşturabildiği bir makine öğrenimi alt kümesidir. Verinin yapısına göre hangi parametrelere ne ağırlık verileceğini kendisi keşfetmektedir. Derin öğrenme, ham girdiden daha yüksek seviyedeki özellikleri aşamalı olarak çıkarmak için birden çok katman kullanan bir makine öğrenme algoritmaları sınıfıdır.

Modern derin öğrenme modellerinin çoğu, yapay sinir ağlarına, özellikle de Konvolüsyonel Sinir Ağlarına (CNN - Convolutional Neural Networks) dayanmaktadır, ancak aynı zamanda derin düşünce ağları ve derin düğümler gibi derin üretken modellerde katmansal olarak düzenlenmiş öneri formülleri veya gizli değişkenleri de içerebilirler. Yapay sinir ağları (YSA) biyolojik sistemlerde bilgi işleme ve dağıtılmış iletişim düğümlerinden esinlenmiştir. YSA'ların biyolojik beyinlerden çeşitli farklılıkları vardır. Özellikle, sinir ağları statik ve sembolik olma eğilimindeyken, çoğu canlı organizmanın biyolojik beyni dinamik (plastik) ve analogdur.

Derin öğrenme, her seviye girdi verilerini biraz daha soyut ve bileşik bir temsile dönüştürmeyi öğrenir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsili katman pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman kenar düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir; ve dördüncü katman görüntünün bir yüz içerdiğini tanıyabilir. Daha da önemlisi, derin bir öğrenme süreci hangi özelliklerin hangi seviyeye en uygun şekilde yerleştirileceğini öğrenebilir. Elbette bu, elle ayarlama ihtiyacını tamamen ortadan kaldırmaz; örneğin, değişen sayıda katman ve katman boyutu farklı derecelerde soyutlama sağlayabilir.

Derin öğrenme, Yapay Zekada (AI) Makine Öğreniminin bir alt kümesidir. Bir yapay zeka, verileri işlemek, kalıplar oluşturmak ve kararlar almak için insan beynini taklit ettiğinde, bu Derin Öğrenmedir. Ham girdiden aşamalı olarak üst düzey özellikleri çıkarmak için birden çok katman kullanır. "Derin öğrenmedeki" "derin" kelimesi, verilerin dönüştürüldüğü katman sayısını ifade eder. Bu sayede yapılandırılmamış ve etiketsiz verilerden örüntüler öğrenmek mümkündür. Derin öğrenme algoritması, deneyimlerden nasıl öğrendiğimize benzer şekilde, her seferinde sonucunu iyileştiren bir görevi tekrar tekrar gerçekleştirir.

Arama motorlarında, sosyal medyada, e-ticaret platformlarında her saniye yaratılan muazzam miktarda veri, derin öğrenmeyi büyük bir potansiyele dönüştürdü. Buna ek olarak, bugün mevcut olan güçlü bilgi işlem gücü, derin öğrenmede kullanılan algoritmalar üzerinde

büyük bir etki yarattı. Dahası, kendi kendine giden arabalar, AlphaGo, sesli asistanlar gibi yapay zekadaki atılımlar, derin öğrenme sayesinde mümkün.

Derin öğrenmede, her seviye girdi verilerini biraz daha soyut ve bileşik bir temsile dönüştürmeyi öğrenir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsil katmanı pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman, kenar düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir; ve dördüncü katman, görüntünün bir yüz içerdiğini fark edebilir. Daha da önemlisi, derin öğrenme süreci hangi özelliklerin hangi seviyeye en uygun şekilde yerleştirileceğini kendi başına öğrenebilir. (Elbette bu, elle ayarlama ihtiyacını tamamen ortadan kaldırmaz; örneğin, değişen sayıda katman ve katman boyutu, farklı soyutlama dereceleri sağlayabilir.)

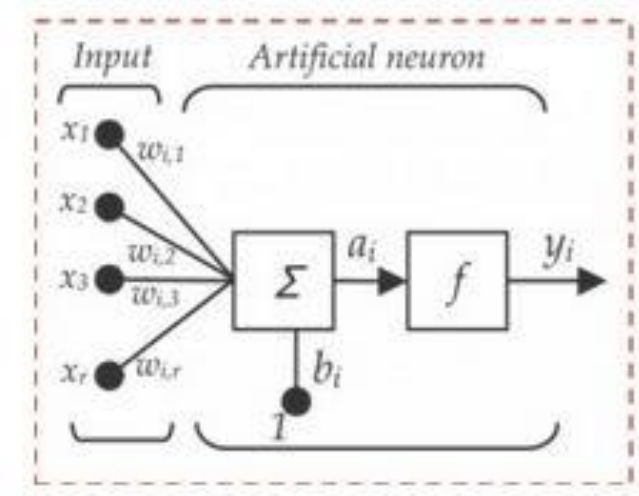

Nöronun farklı bileşenleri şu şekilde belirtilir:

• x1, x2,…, xN: Bunlar nöronun girdileridir. Bunlar, giriş katmanındaki gerçek gözlemler veya gizli katmanlardan birinin ara değeri olabilir.

• w1, w2,…, wN: Her girişin ağırlığı.

• bi: Eğilim ya da Sapma birimleri olarak adlandırılır. Bunlar, her ağırlığa karşılık gelen aktivasyon fonksiyonunun girişine eklenen sabit değerlerdir. Kesişme terimine benzer şekilde çalışır.

• a: Şu şekilde temsil edilebilen nöronun aktivasyonu olarak adlandırılır

• ve y: nöronun çıktısıdır

$$a = f(\sum_{i=0}^{N} w_i x_i)$$

Derin Öğrenme Algoritmaları:
Gözetimli öğrenme
Kümeleme
Boyut indirgeme
Yapılandırılmış tahmin
Anomali tespiti
Sinir ağları
Pekiştirmeli öğrenme

8.1. Anomali Tespiti

Veri analizinde, anomali tespiti (aynı zamanda aykırı değer tespiti), verilerin çoğunluğundan önemli ölçüde farklılaşarak şüphe uyandıran nadir öğelerin, olayların veya gözlemlerin tanımlanmasıdır. Tipik olarak anormal öğeler, banka dolandırıcılığı, yapısal bir kusur, tıbbi sorunlar veya bir metindeki hatalar gibi bir tür soruna dönüşecektir. Anormallikler ayrıca aykırı değerler, yenilikler, gürültü, sapmalar ve istisnalar olarak da adlandırılmaktadır.

Özellikle, kötüye kullanım ve ağa izinsiz giriş tespiti bağlamında, ilginç nesneler genellikle nadir nesneler değil, beklenmedik etkinlik patlamalarıdır. Bu model, bir aykırı değerin nadir bir nesne olarak genel istatistiksel tanımına uymaz ve uygun şekilde bir araya getirilmediği sürece birçok aykırı değer algılama yöntemi (özellikle denetimsiz yöntemler) bu tür verilerde başarısız olmaktadır. Bunun yerine, bir küme analizi algoritması, bu modellerin oluşturduğu mikro kümeleri tespit edebilmektedir.

Üç geniş anomali tespit tekniği kategorisi mevcuttur[4]. Denetimsiz anomali tespit teknikleri, veri setindeki örneklerin çoğunluğunun normal olduğu varsayımı altında, veri setinin geri kalanına en az uyan örnekleri arayarak etiketlenmemiş bir test veri setindeki anormallikleri tespit etmektedir. Denetimli anomali tespit teknikleri, "normal" ve "anormal" olarak etiketlenmiş bir veri seti gerektirir ve bir sınıflandırıcının eğitimini içermektedir (diğer birçok istatistiksel sınıflandırma probleminden temel fark, aykırı değer tespitinin doğal dengesiz doğasıdır). Yarı denetimli anomali tespit teknikleri, belirli bir normal eğitim veri setinden normal davranışı temsil eden bir model oluşturur ve ardından kullanılan model tarafından bir test örneğinin oluşturulma olasılığını test etmektedir.

8.2. Yapay Sinir Ağları

İnsan beyni:

İnsan beyninin nasıl çalıştığını daha yeni anlamaya başladık ; daha yolun başındayız. Akıllı makineler yapmanın bir yolu, insan beynini özellikle organizasyonel prensiplerini taklit etmeye çalışmaktır.

Beyin son derece karmaşık, doğrusal olmayan ve paralel bir bilgisayardır ve yoğun şekilde bağlı 10^{11} nörondan oluşur (nöron başına ~ 10^4 bağlantı). Bir nöron, silikon mantık geçidine (10^{-9}sn) kıyasla çok daha yavaştır (10^{-3}sn), doğrudur, nöronlar arasındaki muazzam bağlantı, nispeten yavaş hızı oluşturur. Ancak, *karmaşık algısal kararlara çok hızlı bir şekilde ulaşılır* (birkaç yüz milisaniye içinde)

100 Adım kuralı: Bireysel nöronlar birkaç milisaniye içinde çalıştığından, hesaplamalar yaklaşık 100'den fazla seri adım içermez ve bir nörondan diğerine gönderilen bilgi çok küçüktür (birkaç bit)

Plastisite: Beynin nöral yapısının bir kısmı doğumda bulunurken, diğer kısımları çevreye uyum sağlamak için özellikle yaşamın erken dönemlerinde öğrenme yoluyla geliştirilir (yeni girdiler). Biyolojik Nöronlarda, farklı dallanma yapılarına sahip çeşitli farklı nöronlar (motor nöron, merkez üstü çevresel olmayan görsel hücreler…) mevcuttur. Ağın bağlantıları ve tek tek sinapsların güçleri ağın işlevini oluşturur.

Beyindeki Biyolojik Nöronlar:

İnsan beyni yaklaşık 100 milyar nörondan oluşur.

dendritler: hücrelere elektrik sinyalleri taşıyan sinir lifleri

hücre gövdesi: girdilerinin doğrusal olmayan bir işlevini hesaplar

akson: elektrik sinyalini hücre gövdesinden diğer nöronlara taşıyan tek uzun lif. Nöronun aksonu, diğer birçok nöronun dendritlerine bağlıdır. Nöronlar, dendritlerden elektrik sinyalleri alır ve bunları aksona gönderir.

sinaps: gücü hücreye girişi etkileyen kimyasal bir bağlantıyı düzenleyen, bir hücrenin aksonu ile diğerinin dendriti arasındaki temas noktası.

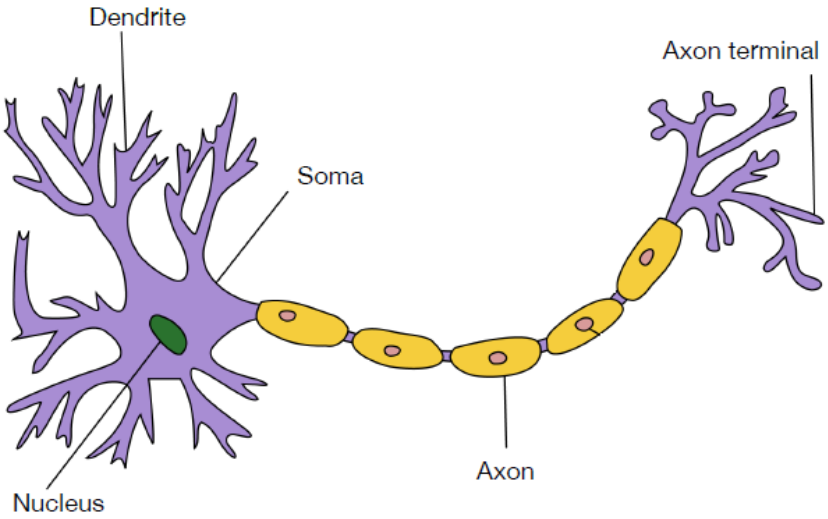

İnsan beyninden ilham alan hesaplama model, Yapay Sinir Ağları:

- Basit işlem birimlerinden (nöronlar) oluşan büyük ölçüde paralel, dağıtılmış sistem
- Edinilen bilgiyi depolamak için nöronlar arasındaki sinaptik bağlantı güçleri kullanılır.
- Bilgi, ağ tarafından bir öğrenme süreci aracılığıyla çevresinden edinilir.

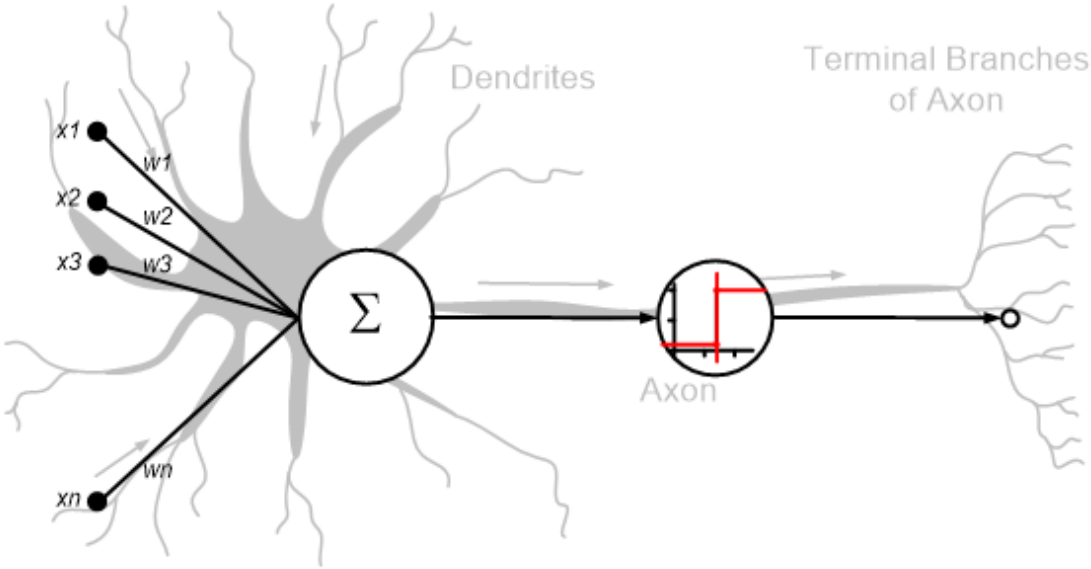

- Basit işlem birimlerinden (nöronlar) oluşan büyük ölçüde paralel, dağıtılmış sistem
- Edinilen bilgiyi depolamak için nöronlar arasındaki sinaptik bağlantı güçleri kullanılır.
- Bilgi, ağ tarafından bir öğrenme süreci aracılığıyla çevresinden edinilir.
- Örneklerden öğrenmek: etiketli veya etiketsiz
- Adaptivite: bir şeyler öğrenmek için bağlantı güçlerini değiştirmek
- Doğrusal olmama: doğrusal olmayan aktivasyon fonksiyonları gereklidir

- Hata toleransı: Nöronlardan veya bağlantılardan biri hasar görürse, tüm ağ hala oldukça iyi çalışıyor.
- Bu nedenle, aşağıdakilerle karakterize edilen sorunlar için klasik çözümlerden daha iyi alternatifler olabilirler: Yüksek boyutluluk, gürültülü, kesin olmayan veya eksik veriler; ve açıkça ifade edilmiş matematiksel bir çözüm veya algoritmanın olmaması

Beyin ve Yapay Sinir Ağları:

Benzerlikler:
- Nöronlar, nöronlar arasındaki bağlantılar
- Öğrenme = bağlantıların değişmesi, nöronların değişmesi değil
- Büyük paralel işleme

Ancak yapay sinir ağları çok daha basit:
- nöron içindeki hesaplama büyük ölçüde basitleştirildi
- ayrık zaman adımları
- tipik olarak çok sayıda uyaran içeren bir tür denetimli öğrenim

Bir sinir ağı, basit işlem birimlerinden (yapay nöronlar) oluşan büyük ölçüde paralel, dağıtılmış bir işlemcidir. Beyne iki açıdan benziyor:
- Bilgi, ağ tarafından bir öğrenme süreci aracılığıyla çevresinden edinilir
- Edinilen bilgiyi depolamak için nöronlar arasındaki sinaptik bağlantı güçleri kullanılır.

Yapay sinir ağları (YSA) veya bağlantı sistemi, hayvan beyinlerini oluşturan biyolojik sinir ağlarından belirsiz bir şekilde esinlenen bilgisayar sistemleridir. Bu tür sistemler, genellikle herhangi bir göreve özgü kural ile programlanmadan, örnekleri dikkate alarak görevleri yerine getirmeyi "öğrenir".

YSA, biyolojik bir beyindeki nöronları gevşek bir şekilde modelleyen "yapay nöronlar" adı verilen bağlı birimler veya düğümler koleksiyonuna dayanan bir modeldir. Her bağlantı, biyolojik bir beyindeki sinapslar gibi, bir yapay nörondan diğerine bilgi, bir "sinyal" iletebilir. Bir sinyal alan yapay bir nöron, onu işleyebilir ve daha sonra ona bağlı ek yapay nöronları işaret edebilir. Ortak YSA uygulamalarında, yapay nöronlar arasındaki bağlantıdaki sinyal gerçek bir sayıdır ve her bir yapay nöronun çıkışı, girdilerinin toplamının doğrusal olmayan bir fonksiyonu tarafından hesaplanır. Yapay nöronlar arasındaki bağlantılara "kenarlar" denir. Yapay nöronlar ve kenarlar tipik olarak öğrenme ilerledikçe ayarlanan bir ağırlığa sahiptir. Ağırlık, bir bağlantıdaki sinyalin gücünü arttırır veya azaltır. Yapay nöronlar, sadece toplam sinyal bu eşiği geçtiğinde sinyalin gönderileceği bir eşik değerine sahip olabilir. Tipik olarak, yapay nöronlar katmanlar halinde toplanır. Farklı katmanlar, girdilerinde farklı türde dönüşümler gerçekleştirebilir. Sinyaller, muhtemelen katmanları birden çok kez geçtikten sonra, ilk katmandan (giriş katmanı) son katmana (çıkış katmanı) gider.

YSA yaklaşımının asıl amacı, problemleri bir insan beyninde olduğu gibi çözmekti. Bununla birlikte, zamanla dikkat, belirli görevlerin yerine getirilmesine ve biyolojiden sapmalara yol açtı. Yapay sinir ağları, bilgisayar görme, konuşma tanıma, makine çevirisi, sosyal ağ filtreleme, oyun tahtası ve video oyunları ve tıbbi teşhis gibi çeşitli görevlerde kullanılmıştır.

Derin öğrenme yapay bir sinir ağında birden fazla gizli katmandan oluşur. Bu yaklaşım, insan beyninin ışığı ve sesi görme ve işitme biçimini modellemeye çalışır. Derin öğrenmenin bazı başarılı uygulamaları bilgisayarla görme ve konuşma tanımadır.

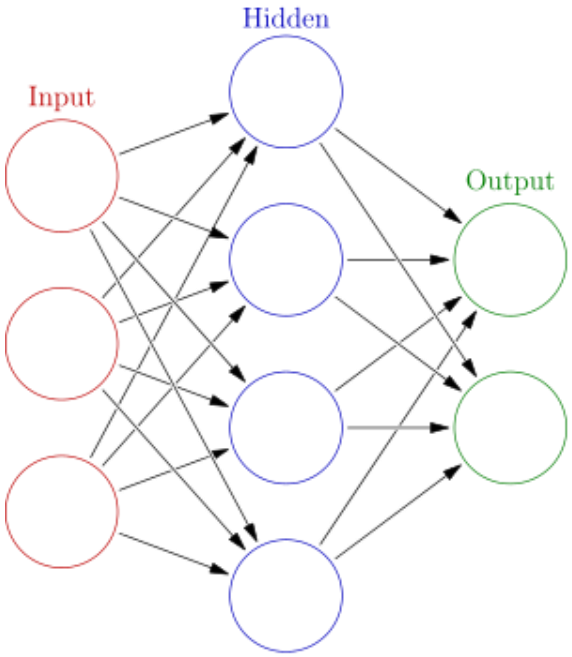

Yapay bir sinir ağı, bir beyindeki geniş nöron ağına benzer şekilde birbirine bağlı bir düğüm grubudur. Burada, her dairesel düğüm bir yapay nöronu temsil eder ve bir ok, bir yapay nöronun çıkışından diğerinin girişine bir bağlantıyı temsil eder.

Yapay Nöron Modeli

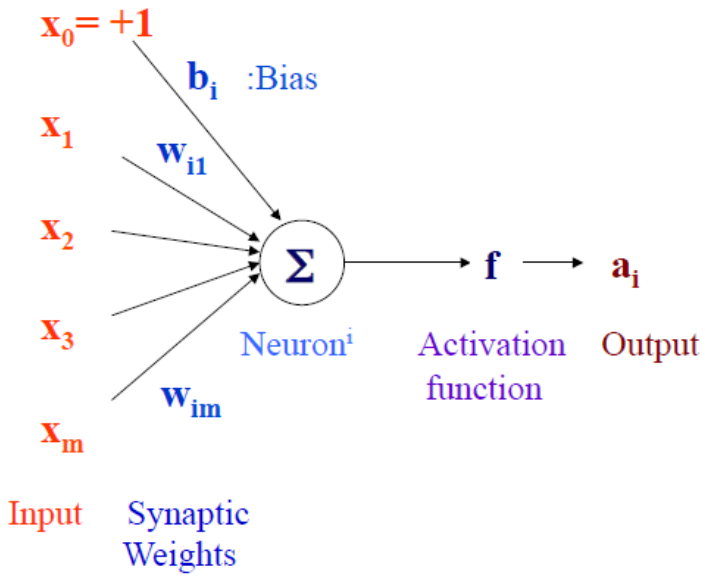

Eğilim – Meyillenme (Bias):

Bias: eşik değer, eğilim ya da sapma değeri.

Yapay bir nöron: Girdisinin ağırlıklı toplamını hesaplar (net girdisi denir). Sapmasını ekler. Bu değeri bir aktivasyon işlevinden geçirir. Nöronun çıkışı sıfırın üzerindeyse tetiklendiğini, "ateşlendiğini" (yani aktif hale geldiğini) söylüyoruz. Sapma, sabit +1.0 girdisine kenetlenen başka bir ağırlık olarak dahil edilebilir. Bu ekstra serbest değişken (eğilim ya da sapma), nöronu daha güçlü hale getirir.

$$a_i = f(n_i) = f\left(\sum_{j=1}^{n} w_{ij}x_j + b_i\right)$$

Yapay Sinir Ağları (YSA) Unsurları:

- İşleme öğesi (Processing element - PE)
- Ağ Mimarisi
  - Gömülü Katmanlar

- Paralel İşlem

- Ağ Bilgisi İşleme
  - Girişler
  - Çıkışlar
  - Bağlantı Ağırlıkları (Connection weights)
  - Toplama İşlevi (Summation function)

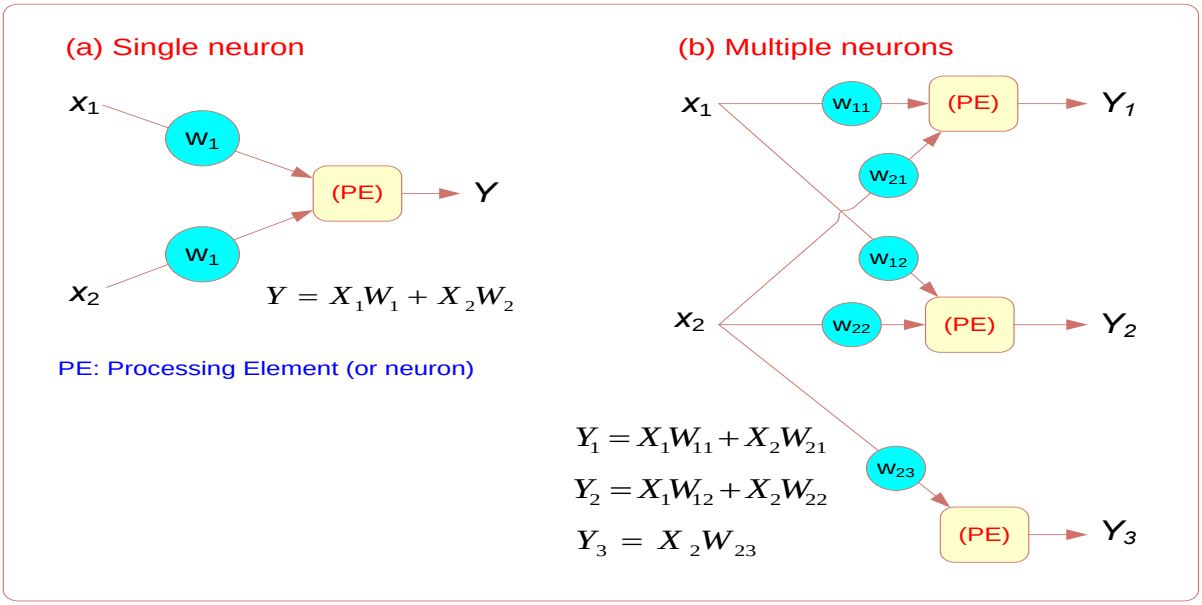

Transformation (Transfer) Function:

- Linear function
- Sigmoid (logical activation) function [0 1]
- Tangent Hyperbolic function [-1 1]

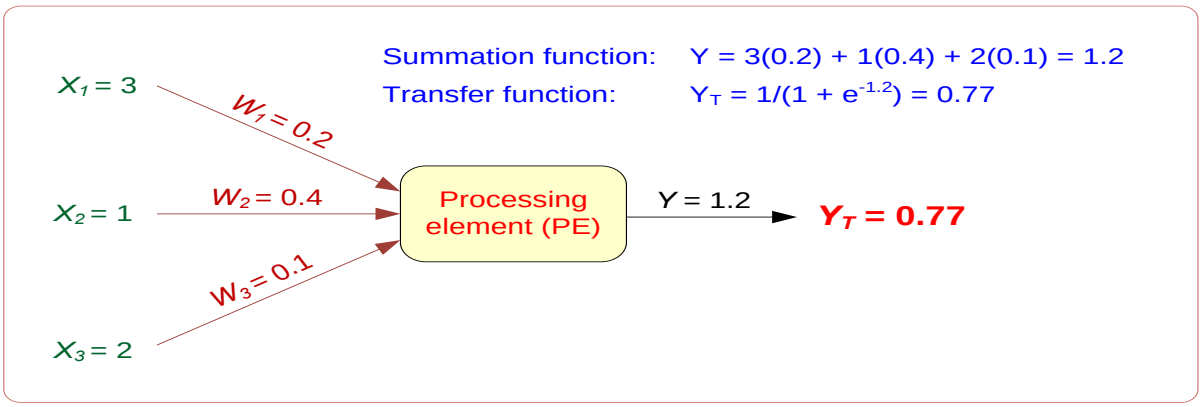

Farklı Ağ Topolojileri:

- **Tek katmanlı ileri beslemeli ağlar:** Çıktı katmanına yansıyan girdi katmanı.

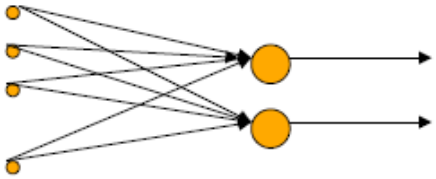

Input layer Output layer

- **Çok katmanlı ileri beslemeli ağlar:** Bir veya daha fazla gömülü katman. Girdi projeleri yalnızca önceki katmanlardan bir katmana yansıtılır. Tipik olarak, yalnızca bir katmandan diğerine bağlanırlar.

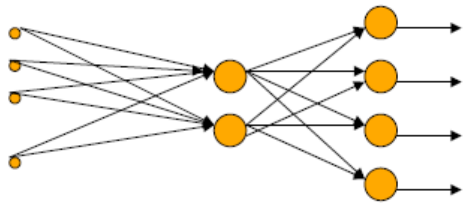

Input layer Hidden layer Output layer

2-layer or
1-hidden layer
fully connected
network

- **Tekrarlayan ağlar:** Bazı girişlerinin bazı çıkışlarına (ayrık zaman) bağlı olduğu geri beslemeli bir ağ.

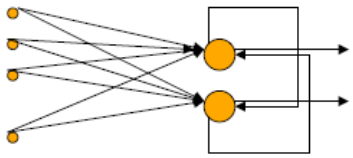

Input layer Output layer

Aktivasyon fonksiyonları:

Nöronun çıktısının genliğini sınırladığı için limit işlevi olarak da adlandırılır.

Many types of activations functions are used:

- linear: $a = f(n) = n$
- threshold: $a = \{1 \text{ if } n >= 0$ (hardlimiting)
  $0 \text{ if } n < 0$
- sigmoid: $a = 1/(1+e^{-n})$
- ...

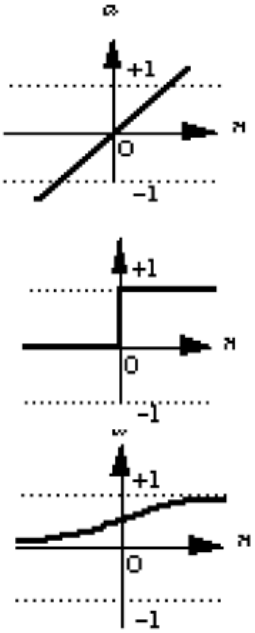

Name	Input/Output Relation	Icon	MATLAB Function
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1+e^{-n}}$		logsig
Hyperbolic Tangent Sigmoid	$a = \frac{e^{n}-e^{-n}}{e^{n}+e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin
Competitive	$a = 1$ neuron with max n $a = 0$ all other neurons		compet

Sigmoid unit:

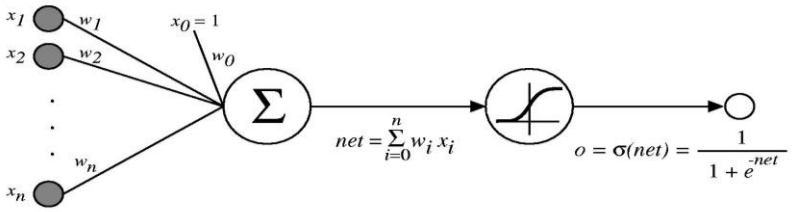

$\sigma(x)$ is the sigmoid function

$$\frac{1}{1+e^{-x}}$$

Nice property: $\frac{d\sigma(x)}{dx} = \sigma(x)(1-\sigma(x))$

Örnek: Basit Sinir Ağı

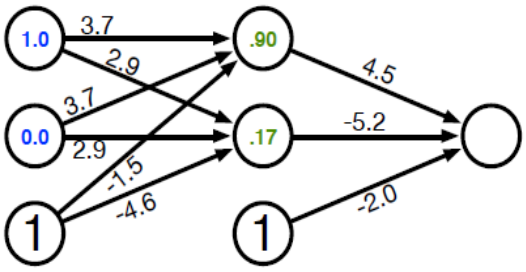

$$\text{sigmoid}(1.0 \times 3.7 + 0.0 \times 3.7 + 1 \times -1.5) = \text{sigmoid}(2.2) = \frac{1}{1+e^{-2.2}} = 0.90$$

$$\text{sigmoid}(1.0 \times 2.9 + 0.0 \times 2.9 + 1 \times -4.5) = \text{sigmoid}(-1.6) = \frac{1}{1+e^{1.6}} = 0.17$$

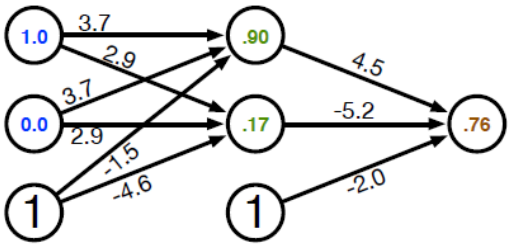

- Output

$$\text{sigmoid}(.90 \times 4.5 + .17 \times -5.2 + 1 \times -2.0) = \text{sigmoid}(1.17) = \frac{1}{1+e^{-1.17}} = 0.76$$

Bir numuneyi işleme örneği:

X_1	X_2	X_3	Y
1	0	1	1

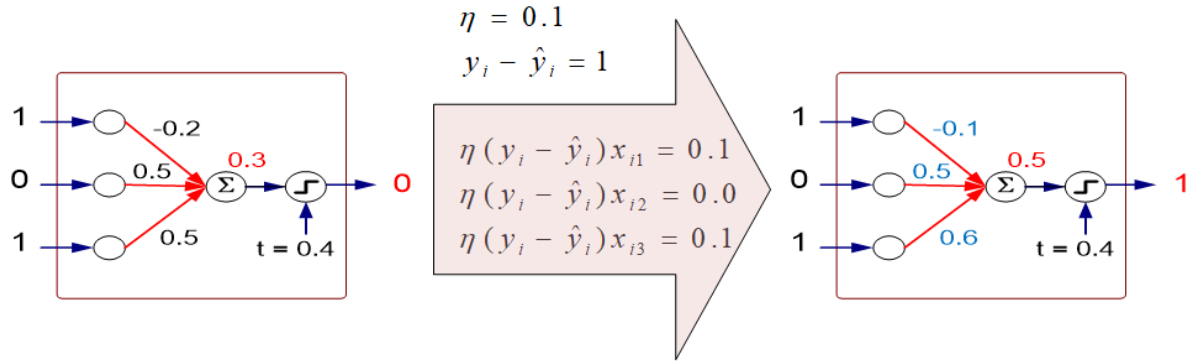

Örnek:

Girişler	Ağırlıklar
$x_1 = 0.5$	$w_1 = -0.2$
$x_2 = 0.6$	$w_2 = 0.6$
$x_3 = 0.2$	$w_3 = 0.2$
$x_4 = 0.7$	$w_4 = -0.1$

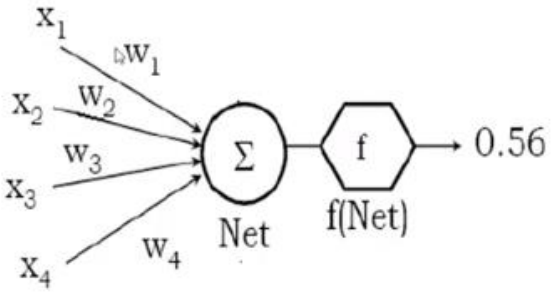

Hücrenin net girdisi;

$Net = \Sigma x_i w_i \qquad i=1...4$

$Net = 0.5*(-0.2)+0.6*0.6+0.2*0.2+0.7*(-0.1)$

$Net = 0.23$

- **Sigmoid aktivasyon fonksiyonuna göre hücrenin çıkışı;**

$f(Net) = 1 / (1+e^{-0.23})$

$f(Net) = 0.56$

8.3. Types of Algorithms used in Deep Learning

Here is the list of top 10 most popular deep learning algorithms:

1. Convolutional Neural Networks (CNNs)
2. Long Short Term Memory Networks (LSTMs)
3. Recurrent Neural Networks (RNNs)
4. Generative Adversarial Networks (GANs)
5. Radial Basis Function Networks (RBFNs)
6. Multilayer Perceptrons (MLPs)
7. Self Organizing Maps (SOMs)
8. Deep Belief Networks (DBNs)
9. Restricted Boltzmann Machines(RBMs)
10. Autoencoders

Derin öğrenme algoritmaları neredeyse her tür veriyle çalışır ve karmaşık sorunları çözmek için büyük miktarda bilgi işlem gücü ve bilgi gerektirir.

What do you understand about Neural Networks in the context of Deep Learning?

Derin Öğrenme bağlamında Sinir Ağları hakkında ne anlıyorsunuz?

Sinir Ağları, insan vücudundaki biyolojik sinir ağlarına çok benzeyen yapay sistemlerdir. Bir sinir ağı, insan beyninin nasıl çalıştığını taklit eden bir yöntem kullanarak bir veri yığınındaki temel ilişkileri tanımaya çalışan bir dizi algoritmadır. Göreve özel kurallar olmadan, bu sistemler çeşitli veri kümelerine ve örneklere maruz kalarak görevleri yapmayı öğrenirler. Buradaki fikir, bu veri kümelerinin önceden kodlanmış bir anlayışıyla programlanmak yerine, sistemin beslendiği verilerden tanımlayıcı özellikleri türetmesidir. Sinir ağları, eşik mantık hesaplama modelleri üzerine kuruludur. Sinir ağları, değişen girdilere uyum sağlayabildiğinden, çıktı kriterlerinin yeniden tasarlanmasını gerektirmeden mümkün olan en iyi sonucu üretebilirler.

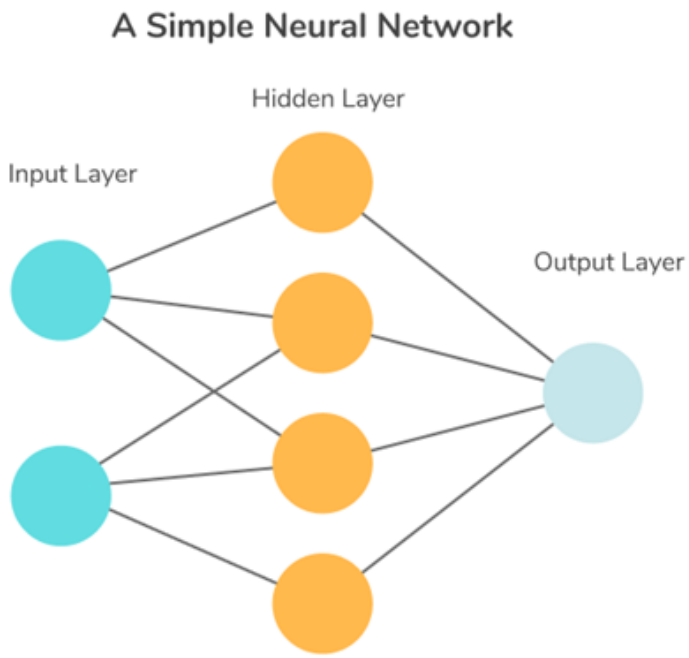

What are the applications of deep learning?

Derin öğrenme uygulamalarından bazıları şunlardır: -

- Örüntü tanıma ve doğal dil işleme.
- Görüntülerin tanınması ve işlenmesi.
- Otomatik çeviri.
- Duygu analizi.
- Soruları yanıtlamak için sistem.
- Nesnelerin Sınıflandırılması ve Tespiti.
- Makineye Göre El Yazısı Oluşturma.
- Otomatik metin oluşturma.
- Siyah Beyaz görüntülerin renklendirilmesi.

Explain learning rate in the context of neural network models. What happens if the learning rate is too high or too low?
Öğrenme hızını sinir ağı modelleri bağlamında açıklayın. Öğrenme oranı çok yüksek veya çok düşükse ne olur?

Öğrenme hızı 0 ile 1 arasında değişen bir sayıdır. Sinir ağı eğitim modellerinde en önemli ayarlanabilir hiperparametrelerden biridir. Öğrenme oranı, bir sinir ağı modelinin belirli bir duruma ne kadar hızlı veya yavaş adapte olduğunu ve öğrendiğini belirler. Daha yüksek bir öğrenme oranı değeri, modelin yalnızca birkaç eğitim dönemine ihtiyaç duyduğunu ve hızlı değişiklikler ürettiğini gösterirken, daha düşük bir öğrenme oranı, modelin yakınsamasının uzun zaman alabileceğini veya hiçbir zaman yakınsayıp kötü bir çözümde takılıp kalmayacağını gösterir. Sonuç olarak, çok düşük veya çok yüksek bir öğrenme oranı kullanmak yerine, deneme yanılma yoluyla iyi bir öğrenme oranı değeri oluşturulması önerilir.

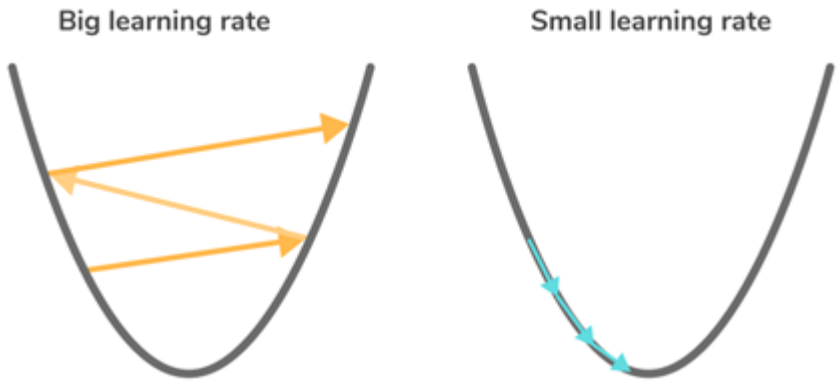

Yukarıdaki görüntüde, büyük bir öğrenme oranının bizi istenen çıktıdan uzaklaşmaya yönlendirdiğini açıkça görebiliriz. Ancak, küçük bir öğrenme oranına sahip olmak, sonunda bizi istenen çıktıya götürür.

What are the advantages of neural networks?

Sinir ağlarının avantajları şunlardır:

• Sinir ağları son derece uyarlanabilirdir ve hem sınıflandırma hem de regresyon problemlerinin yanı sıra çok daha karmaşık problemler için kullanılabilirler. Sinir ağları da oldukça ölçeklenebilir. Her biri kendi nöron setine sahip, istediğimiz kadar katman oluşturabiliriz. Çok fazla veri noktası olduğunda, sinir ağlarının en iyi sonuçları ürettiği gösterilmiştir. Görüntüler, metinler vb. gibi doğrusal olmayan verilerle en iyi şekilde kullanılırlar. Sayısal bir değere dönüştürülebilen herhangi bir veriye uygulanabilirler.

• Sinir ağı modu bir kez eğitildikten sonra, çıktıları çok hızlı bir şekilde verirler. Böylece zamandan tasarruf sağlarlar.

What are the disadvantages of neural networks?

Sinir ağlarının dezavantajları şunlardır: -

- Sinir ağlarının "kara kutu" yönü, iyi bilinen bir dezavantajdır. Yani, sinir ağının nasıl veya neden belirli bir sonuç ürettiği hakkında hiçbir fikrimiz yok. Bir sinir ağına bir köpek görüntüsü girdiğimizde ve bunun bir ördek olduğunu tahmin ettiğinde, onu bu tahmini yapmaya neyin sevk ettiğini anlamakta zorlanabiliriz.
- Bir sinir ağı modeli oluşturmak uzun zaman alır.
- Sinir ağları modelleri, her katmanda çok sayıda hesaplama yapılması gerektiğinden, hesaplama açısından pahalıdır.
- Bir sinir ağı modeli, eğitmek için geleneksel bir makine öğrenimi modelinden önemli ölçüde daha fazla veri gerektirir.

Explain what a deep neural network (DNN) is.
Derin sinir ağının ne olduğunu açıklayın.

Giriş ve çıkış katmanları arasında çok sayıda katmana sahip bir yapay sinir ağı (YSA), derin sinir ağı (DNN) olarak bilinir. Derin sinir ağları, derin mimarileri kullanan sinir ağlarıdır. "Derin" terimi, tek bir katmanda daha fazla sayıda katmana ve birime sahip olan işlevleri ifade eder. Daha yüksek düzeyde desenler yakalamak için daha fazla ve daha büyük katmanlar ekleyerek daha doğru modeller oluşturmak mümkündür. Aşağıdaki görüntü derin bir sinir ağını göstermektedir.

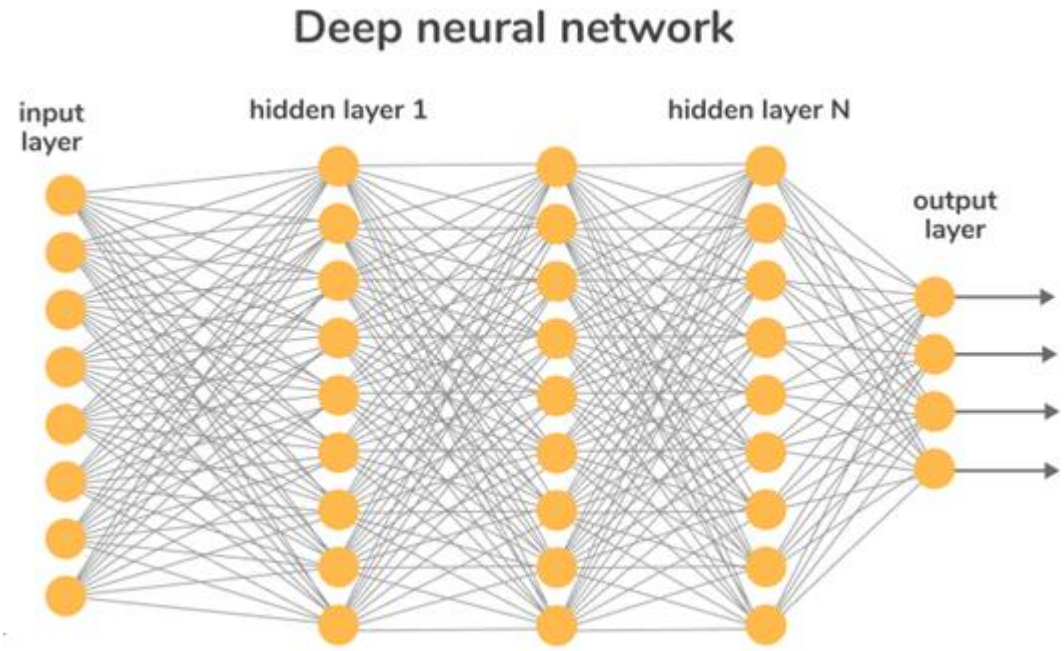

What are the different types of deep neural networks?

Derin sinir ağlarının farklı türleri nelerdir?

Aşağıda derin sinir ağlarının farklı türleri verilmiştir:

Feed Forward Sinir Ağı:

Akış kontrolünün giriş katmanında başladığı ve çıkış katmanına geçtiği en temel sinir ağı türüdür. Bu ağlar yalnızca tek bir katmana veya tek bir gizli katmana sahiptir. Bu ağda geri yayılım mekanizması yoktur çünkü veriler yalnızca tek bir şekilde akar. Bu ağın giriş katmanı, girişte bulunan ağırlıkların toplamını alır. Bu ağlar, bilgisayarla görme tabanlı yüz tanıma yönteminde kullanılmaktadır.

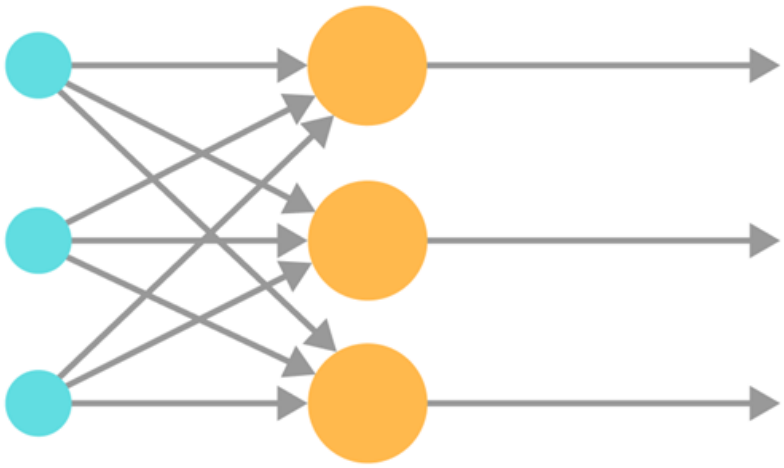

Radial Basis Function Neural Network:

Radyal Temel Fonksiyonlu Sinir Ağı:

Bu tür sinir ağı genellikle birden fazla katmana, tercihen iki katmana sahiptir. Bu ağ türünde herhangi bir konumdan merkeze olan bağıl uzaklık belirlenir ve bir sonraki katmana aktarılır. Kesintileri önlemek için, gücü mümkün olan en kısa sürede geri yüklemek için güç restorasyon sistemlerinde yaygın olarak radyal tabanlı ağlar kullanılır.

Multi-Layer Perceptrons (MLP):

Çok Katmanlı Algılayıcılar (MLP):

Çok katmanlı algılayıcı (MLP), bir tür ileri beslemeli yapay sinir ağıdır (YSA). MLP'ler, birbirini takip eden tamamen bağlantılı katmanlardan oluşan en basit derin sinir ağlarıdır. Her ardışık katman, önceki katmanın tüm çıktılarının ağırlıklı toplamı olan (tamamen bağlantılı) doğrusal olmayan işlevler koleksiyonundan oluşur. Konuşma tanıma ve diğer makine öğrenimi sistemleri büyük ölçüde bu ağlara dayanır.

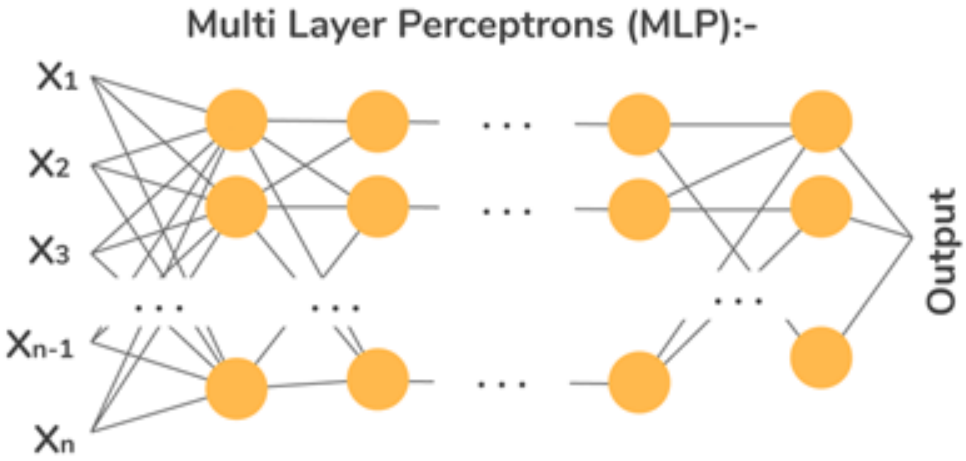

What do you mean by end-to-end learning?

Uçtan uca öğrenmeden kastınız nedir?

Bir modelin ham verilerle beslendiği ve tüm verilerin aynı anda herhangi bir ara adım olmadan istenen sonucu oluşturmak için eğitildiği bir derin öğrenme prosedürüdür. Tüm farklı adımların sıralı olarak değil aynı anda eğitildiği bir derin öğrenme yöntemidir. Uçtan uca öğrenme, genellikle daha düşük sapma ile sonuçlanan örtük özellik mühendisliği gereksinimini ortadan kaldırma avantajına sahiptir. Sürücüsüz otomobiller, uçtan uca öğrenme içeriğinizde kullanabileceğiniz mükemmel bir örnektir. İnsan girdisi tarafından yönlendirilirler ve görevleri yerine getirmek için bir CNN (**Convolutional Neural Network)** kullanarak bilgileri otomatik olarak öğrenmek ve yorumlamak üzere programlanırlar. Bir başka iyi örnek, kaydedilmiş bir ses klibinden (giriş) yazılı bir dökümün (çıktı) üretilmesidir. Buradaki model, tüm adımları ve görevleri yönetebileceği gerçeğine odaklanarak ortadaki tüm adımları atlar.

What do you understand about gradient clipping in the context of deep learning?

Derin öğrenme bağlamında gradyan kırpma hakkında ne anlıyorsunuz?

Gradyan Kırpma, geri yayılım sırasında meydana gelen gradyanların patlaması (zaman içinde büyük hata gradyanlarının biriktiği ve eğitim sırasında sinir ağı model ağırlıklarında büyük değişikliklere neden olduğu bir durum) sorunuyla başa çıkmak için bir tekniktir. Eğimlerin patlaması sorunu, eğitim sırasında eğimler aşırı büyüdüğünde ve modelin kararsız hale gelmesine neden olduğunda ortaya çıkar. Gradyan beklenen aralığı geçtiyse, gradyan değerleri, belirli bir minimum veya maksimum değere tek tek yönlendirilir. Gradyan kırpma, bir sinir ağını eğitirken sayısal kararlılığı artırır, ancak modelin performansı üzerinde çok az etkisi vardır.

Explain Forward and Back Propagation in the context of deep learning.
İleri ve Geri Yayılımı derin öğrenme bağlamında açıklayın.

İleri Yayılım: Ağın girdi katmanı ile çıktı katmanı arasındaki gizli katman, girdileri ağırlıklarla alır. Her gizli katmandaki her düğümdeki aktivasyonun çıktısını hesaplıyoruz ve bu, son çıktı katmanına ulaşana kadar bir sonraki katmana yayılıyor. Girdilerden ileriye doğru yayılma olarak bilinen son çıktı katmanına geçiyoruz.

Geri Yayılım: Ağın son katmanından hata bilgilerini ağ içindeki tüm ağırlıklara gönderir. Önceki çağın (yani yineleme) hata oranına dayalı olarak bir sinir ağının ağırlıklarının ince ayarını yapmak için kullanılan bir tekniktir. Ağırlıklara ince ayar yaparak hata oranlarını düşürebilir ve modelin genellemesini iyileştirebilir, böylece daha güvenilir hale getirebilirsiniz. Geri yayılım süreci aşağıdaki adımlara ayrılabilir: Eğitim verilerini ağ üzerinden yayarak çıktı üretebilir. Ardından, hedef ve çıkış değerlerini kullanarak çıkış aktivasyonları için hata türevini hesaplar. Önceki katmanın çıktı aktivasyonundaki hatanın türevini hesaplamak için geri yayılabilir ve tüm gizli katmanlar için böyle devam edebilir. Daha önce elde edilen türevleri ve tüm gizli katmanları kullanarak ağırlıklar için hata türevini hesaplar. Ağırlıklar, bir sonraki katmandan elde edilen hata türevlerine göre güncellenir.

What do you mean by hyperparameters in the context of deep learning?
Derin öğrenme bağlamında hiperparametreler ile ne demek istiyorsunuz?
Hiperparametreler, ağ topolojisini (örneğin, gizli birimlerin sayısı) ve ağın nasıl eğitildiğini (Örn: Öğrenme Hızı) belirleyen değişkenlerdir. Modeli eğitmeden önce, yani ağırlıkları ve sapmayı optimize etmeden önce ayarlanırlar.

Aşağıda bazı hiperparametre örnekleri verilmiştir:
Gizli katman sayısı: Düzenlileştirme teknikleri ile bir katman içindeki birçok gizli birim doğruluğu artırabilir. Birim sayısı azaltılırsa, eksik yerleştirme meydana gelebilir.

Öğrenme Hızı: Öğrenme hızı, bir ağın parametrelerinin güncellenme hızıdır. Öğrenme süreci, düşük bir öğrenme oranı ile yavaşlar, ancak sonunda birleşir. Daha hızlı bir öğrenme oranı, öğrenme sürecini hızlandırır, ancak yakınsamayabilir. Düşen bir Öğrenme oranı genellikle arzu edilir.

Difference between multi-class and multi-label classification problems.

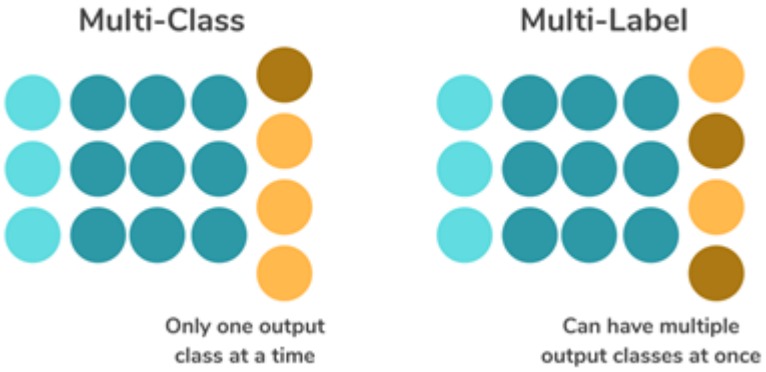

Çok sınıflı bir sınıflandırma probleminde sınıflandırma görevi, birbirini dışlayan ikiden fazla sınıfa (kesişimi olmayan veya ortak özelliği olmayan sınıflar) sahipken, çok etiketli bir sınıflandırma probleminde, görevler farklı olmasına rağmen, her etiketin farklı bir sınıflandırma görevi vardır. bir şekilde ilişkilidir. Örneğin, kedi, köpek veya ayı olabilecek bir grup hayvan fotoğrafını sınıflandırmak, her örneğin yalnızca bir tür olabileceğini varsayan çok sınıflı bir sınıflandırma problemidir, bu da bir görüntünün kedi veya kedi olarak kategorize edilebileceğini gösterir. köpek, ama ikisi aynı anda değil.
Şimdi aşağıdaki resmi değiştirmek istediğinizi varsayalım.

Yukarıdaki resim, her iki canlıyı da betimlediği için hem kedi hem de köpek olarak kategorize edilmelidir. Çok etiketli bir sınıflandırma sorununda her örneğe bir etiket kümesi tahsis edilir ve sınıflar birbirini dışlamaz. Çok etiketli bir sınıflandırma probleminde, bir örüntü bir veya daha fazla sınıfa ait olabilir.

Explain transfer learning in the context of deep learning.
Derin öğrenme bağlamında transfer öğrenmeyi açıklar.

Aktarım öğrenimi, veri bilimcilerinin benzer bir görev için kullanılan önceki bir makine öğrenimi modelinden öğrendiklerini kullanmalarına olanak tanıyan bir öğrenme tekniğidir. Bu öğrenmede, insanların bilgilerini aktarma yeteneği örnek olarak kullanılmaktadır. Bisiklete binmeyi öğrenirseniz, diğer iki tekerlekli araçları kullanmayı daha kolay öğrenebilirsiniz. Otonom otomobil sürüşü için eğitilmiş bir model otonom kamyon sürüşü için de kullanılabilir. Özellikler ve ağırlıklar, yeni modeli eğitmek için kullanılabilir ve yeniden kullanılmasına izin verir. Sınırlı veri olduğunda, bir modeli hızlı bir şekilde eğitmek için aktarım öğrenimi etkili bir şekilde çalışır.

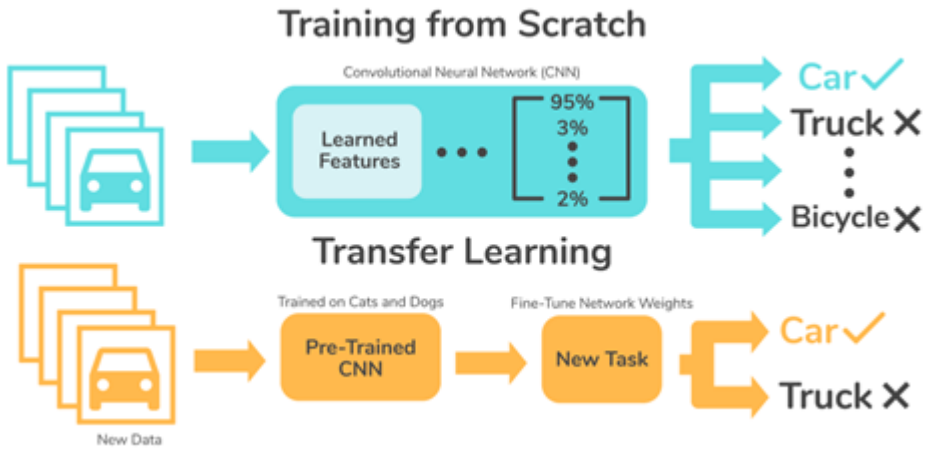

Yukarıdaki görüntüde, ilk diyagram bir modeli sıfırdan eğitmeyi temsil ederken, ikinci diyagram, farklı araç sınıflarını sınıflandırmak için kediler ve köpekler üzerinde önceden eğitilmiş bir modelin kullanılmasını temsil eder, böylece transfer öğrenmeyi temsil eder.

What are the advantages of transfer learning?
Aktarım yoluyla öğrenmenin avantajları nelerdir?

Transfer öğrenmenin avantajları şunlardır:
Daha iyi başlangıç modeli: Diğer öğrenme yöntemlerinde, sıfırdan bir model oluşturmalısınız. Transfer öğrenme daha iyi bir başlangıç noktasıdır çünkü başlangıç modelinin ayrıntılarını bilmeden görevleri daha üst düzeyde gerçekleştirmemizi sağlar.

Daha yüksek öğrenme oranı: Problem zaten benzer bir görev için öğretildiği için, transfer öğrenme eğitim sırasında daha hızlı bir öğrenme oranına izin verir.

Eğitimden sonra daha yüksek doğruluk: Transfer öğrenimi, daha iyi bir başlangıç noktası ve daha yüksek öğrenme oranı sayesinde daha doğru çıktıyla sonuçlanan bir derin öğrenme modelinin daha yüksek bir performans düzeyinde yakınsamasına olanak tanır.

Is it possible to train a neural network model by setting all biases to 0? Also, is it possible to train a neural network model by setting all of the weights to 0?
Tüm yanlılıkları 0'a ayarlayarak bir sinir ağı modeli eğitmek mümkün müdür? Ayrıca, tüm ağırlıkları 0'a ayarlayarak bir sinir ağı modeli eğitmek mümkün müdür?

Evet, tüm yanlılıklar sıfıra ayarlansa bile, sinir ağı modelinin öğrenme şansı vardır.
Hayır, sinir ağı bir görevi tamamlamayı asla öğrenemeyeceğinden, tüm ağırlıkları 0'a ayarlayarak bir modeli eğitmek imkansızdır. Tüm ağırlıklar sıfıra ayarlandığında, her w için türevler sabit kalır, bu da nöronların her yinelemede aynı özellikleri öğrenmesine neden olur. Ağırlıkların herhangi bir sabit başlatılması, sadece sıfır değil, muhtemelen kötü bir sonuç üretecektir.

What is a tensor in deep learning?
Derin öğrenmede tensör nedir?

Tensör, vektörlerin ve matrislerin genelleştirilmesini temsil eden çok boyutlu bir dizidir. Derin öğrenmede kullanılan temel veri yapılarından biridir. Tensörler, temel veri türlerinin n boyutlu dizileri olarak temsil edilir. Tensördeki her elemanın veri tipi aynıdır ve veri tipi her zaman bilinir. Şeklin yalnızca bir bölümünün (yani boyutların sayısı ve her boyutun boyutu) bilinmesi mümkündür. Çoğu işlem, girdileri aynı şekilde tam olarak biliniyorsa, tam olarak bilinen tensörler verir, ancak diğer durumlarda, bir tensörün şekli yalnızca grafik yürütme zamanında belirlenebilir.

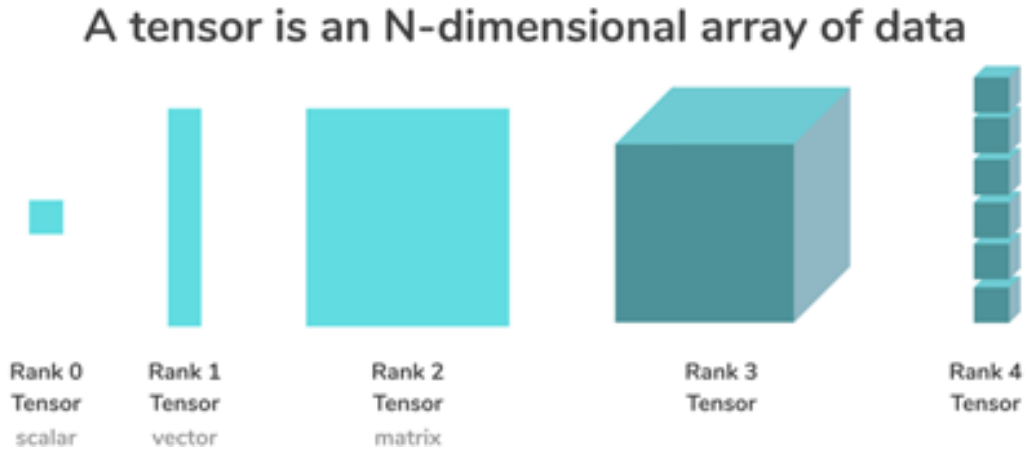

Explain the difference between a shallow network and a deep network.
Sığ ağ ile derin ağ arasındaki farkı açıklayın.

Her sinir ağında bir gizli katman ile giriş ve çıkış katmanları bulunur. Sığ sinir ağları, yalnızca bir gizli katmana sahip olanlardır, oysa derin sinir ağları çok sayıda gizli katman içerir. Hem sığ hem de derin ağlar herhangi bir işleve sığabilir, ancak sığ ağlar çok sayıda girdi parametresi gerektirirken, derin ağlar birkaç katmanları nedeniyle az sayıda girdi parametresi ile işlevlere uyabilir. Model, her katmandaki girdinin yeni ve soyut bir temsilini öğrendiğinden, şu anda sığ ağlar yerine derin ağlar tercih edilmektedir. Sığ ağlara kıyasla, parametre sayısı ve hesaplamalar açısından da çok daha verimlidirler.

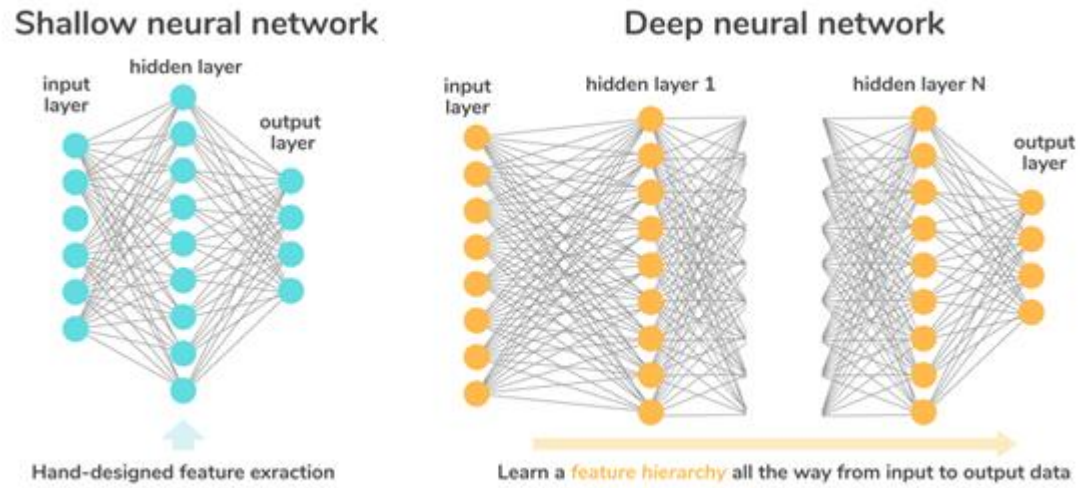

Explain Batch Gradient Descent.

Toplu Dereceli İniş: Toplu Dereceli İniş, her adımda tüm eğitim seti üzerinde hesaplama gerektirir (gradyan inişinin her adımında yer alır) ve bu nedenle çok büyük eğitim setlerinde oldukça yavaştır. Sonuç olarak, Batch Gradient Descent, hesaplama açısından son derece pahalı hale gelir. Bu, dışbükey veya biraz pürüzsüz olan hata manifoldları için idealdir. Batch Gradient Descent, özelliklerin sayısı arttıkça güzel bir şekilde ölçeklenir.

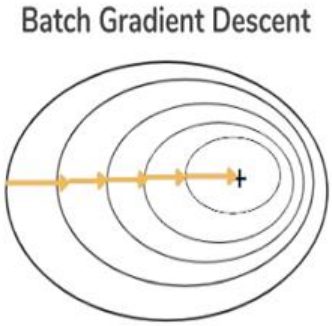

Explain Stochastic Gradient Descent. How is it different from Batch Gradient Descent?

Stochastic Gradient Descent:

Stokastik Gradyan İnişini açıklayın. Batch Gradient Descent'den farkı nedir?

Stokastik Dereceli İniş: Stokastik Dereceli İniş, her adımda degradeleri hesaplamak için tüm eğitim setinin kullanılması olan Toplu Dereceli İniş ile büyük zorluğun üstesinden gelmeyi amaçlar. Bu, doğası gereği stokastiktir, yani her adımda eğitim verilerinin "rastgele" bir örneğini seçer ve ardından gradyanı hesaplar; bu, aynı anda değiştirilecek çok daha az veri olduğundan Toplu Gradyan İniş'ten önemli ölçüde daha hızlıdır. Stokastik Gradyan İnişi, kısıtlanmamış optimizasyon problemleri için en uygun olanıdır. SGD'nin stokastik doğasının bir dezavantajı vardır, çünkü bir kez minimum değere yaklaştığında sabitlenmez ve bunun yerine sekerek bize model parametreleri için iyi ama optimal olmayan bir değer verir. Bu, zıplamayı azaltacak ve bir süre sonra SGD'nin küresel minimumda yerleşmesine izin verecek olan her adımda öğrenme oranını düşürerek çözülebilir.

İkisi arasındaki farklar şunlardır:

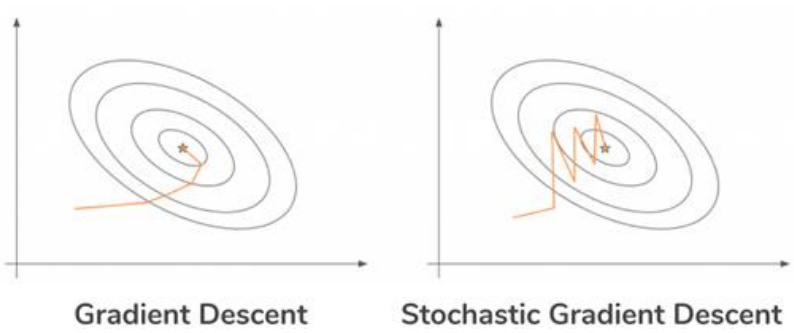

Toplu Gradyan İniş

- Gradyan, tüm eğitim veri kümesi kullanılarak hesaplanır.
- Stokastik Gradyan İnişten daha yavaştır ve hesaplama açısından daha pahalıdır.
- Büyük eğitim örnekleri için önerilmez.
- Doğada deterministiktir (rastgele değil).
- Yakınsamak için yeterli zaman verildiğinde, en iyi cevabı verir.
- Veri noktalarını rastgele karıştırmaya gerek yoktur.
- Bunda sığ yerel minimumlardan çıkmak zordur.
- Bu durumda yakınsama yavaştır.

Stokastik Gradyan İniş

- Gradyanı hesaplamak için tek bir eğitim örneği kullanılır.
- Batch Gradient Descent'den daha hızlı ve hesaplama açısından daha ucuzdur.
- Büyük eğitim örnekleri için önerilir.
- Doğası gereği stokastiktir (rastgele).
- İyi bir çözüm sağlar, ancak en iyisi değildir.
- Veri örneğinin rastgele bir sırada olmasını istediğimiz için, her dönem için eğitim setini karıştıracağız.
- Sığ yerel minimumlardan kaçma şansı daha yüksektir.
- Yakınsama noktasına çok daha hızlı ulaşır**.**

Which deep learning algorithm is the best for face detection?

Yüz tanıma, çeşitli makine öğrenimi yöntemleri kullanılarak gerçekleştirilebilir, ancak en iyileri Evrişimli Sinir Ağları ve derin öğrenmeyi kullanır. Aşağıdakiler bazı dikkate değer yüz algılama algoritmalarıdır: FaceNet, Probablisit, Face Embedding, ArcFace, Cosface ve Spherface.

What is an activation function? What is the use of an activation function?

Aktivasyon fonksiyonu nedir? Aktivasyon fonksiyonunun kullanımı nedir?

Bir yapay sinir ağının etkinleştirme işlevi, ağın verilerdeki karmaşık kalıpları öğrenmesine yardımcı olmak için tanıtılan bir işlevdir. Beynimizde görülen nöron tabanlı bir modelle karşılaştırıldığında, sürecin sonunda bir sonraki nörona neyin ateşleneceğini belirlemekten aktivasyon işlevi sorumludur. Bir YSA'da bir aktivasyon işlevi aynı işi gerçekleştirir. Bir önceki hücrenin çıkış sinyalini alır ve onu bir sonraki hücreye giriş olarak kullanılabilecek bir formata dönüştürür.

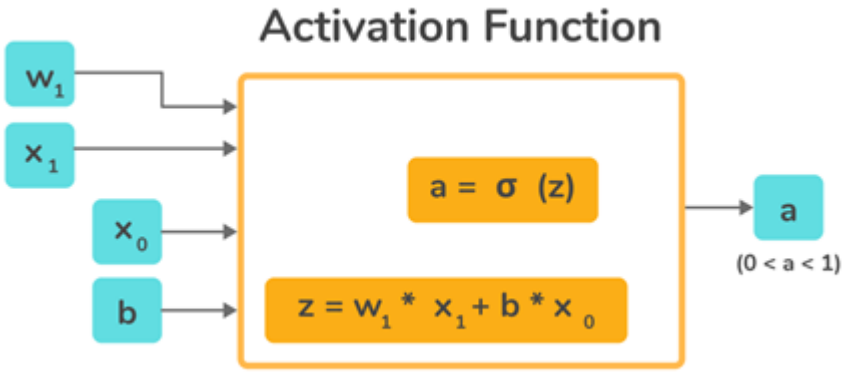

What do you mean by an epochs in the context of deep learning?
Derin öğrenme bağlamında bir devirden kastınız nedir?

Epoch, derin öğrenmede kullanılan ve derin öğrenme algoritmasının tam eğitim veri kümesinde yaptığı geçiş sayısını ifade eden bir terminolojidir. Gruplar genellikle veri kümelerini gruplamak için kullanılır (özellikle veri miktarı çok büyük olduğunda). "Yineleme" terimi, modelde bir toplu iş yürütme sürecini ifade eder.

Toplu iş boyutu eğitim veri kümesinin tamamıysa, dönem sayısı yineleme sayısına eşittir. Pratik nedenlerden dolayı bu genellikle böyle değildir. Birçok modelin oluşturulmasında birkaç dönem kullanılır.

Genel bir ilişki:
d * e = ben * b
burada,
d veri kümesi boyutudur
e dönem sayısıdır
ben yineleme sayısı
b yığın, grup boyutudur

While building a neural network architecture, how will you decide how many neurons and the hidden layers should the neural network have?

Bir sinir ağı mimarisi oluştururken, sinir ağının kaç nörona ve gizli katmanlara sahip olması gerektiğine nasıl karar vereceksiniz?

Bir iş problemi göz önüne alındığında, bir sinir ağı mimarisi tasarlamak için gereken nöronların ve gizli katmanların tam sayısını belirlemek için açık ve hızlı bir kural yoktur. Bir sinir ağındaki gizli katmanın boyutu, çıktı katmanlarının boyutu ile girdi katmanlarının boyutu arasında bir yerde olmalıdır. Bununla birlikte, bir sinir ağı mimarisi oluşturmaya başlamanıza yardımcı olabilecek birkaç temel yol vardır:

- Herhangi bir benzersiz gerçek dünya öngörücü modelleme problemine yaklaşmanın en iyi yöntemi, benzer gerçek dünya durumlarında sinir ağlarıyla çalışma önceki deneyimlerine dayalı olarak herhangi bir veri kümesi için neyin en iyi performansı göstereceğini görmek için bazı temel sistematik deneylerle başlamaktır. Ağ yapılandırması, kişinin problem alanı anlayışına ve sinir ağlarıyla ilgili önceki uzmanlığına dayalı olarak seçilebilir. Benzer konularda kullanılan katmanların ve nöronların sayısı, bir sinir ağının konfigürasyonunu değerlendirirken her zaman iyi bir başlangıç noktasıdır.
- Basit sinir ağı mimarisiyle başlamak ve tahmin edilen çıktı ve doğruluğa dayalı olarak sinir ağının karmaşıklığını kademeli olarak artırmak en iyisidir.

Can a deep learning model be solely built on linear regression?

Derin öğrenme modeli yalnızca doğrusal regresyon üzerine inşa edilebilir mi?

Evet, sorun doğrusal bir denklemle temsil ediliyorsa, her katman için aktivasyon işlevi olarak doğrusal bir işlev kullanılarak derin ağlar oluşturulabilir. Öte yandan, doğrusal işlevlerin bileşimi olan bir sorun doğrusal bir işlevdir ve derin bir ağ uygulayarak başarılabilecek olağanüstü bir şey yoktur çünkü ağa daha fazla düğüm eklemek makine öğrenme modelinin tahmin kapasitesini artırmaz. .

According to you, which one is more powerful - a two layer neural network without any activation function or a two layer decision tree?

Size göre hangisi daha güçlü - aktivasyon fonksiyonu olmayan iki katmanlı bir sinir ağı mı yoksa iki katmanlı bir karar ağacı mı?

İki katmanlı bir sinir ağı, üç katmandan oluşur: bir giriş katmanı, bir gizli katman ve bir çıkış katmanı. Sinir ağlarıyla uğraşırken, girdiler ve yanıt değişkenleri arasındaki karmaşık ve doğrusal olmayan işlevsel eşlemelerle uğraşırken gerekli olduğu için bir etkinleştirme işlevi önemlidir. İki katmanlı bir sinir ağında aktivasyon fonksiyonu olmadığında, bu sadece

doğrusal bir ağdır. Aktivasyon işlevi olmayan bir Sinir Ağı, yalnızca sınırlı kapasiteye sahip olan ve sıklıkla iyi performans göstermeyen bir Lineer Regresyon Modelidir.

İki katman derinliğine sahip bir karar ağacı, iki katmanlı bir karar ağacı olarak bilinir. Karar Ağaçları, verilerin bir parametreye göre sürekli olarak bölündüğü bir tür denetimli makine öğrenimidir (yani, makine, eğitim verilerinde girdinin ne olduğu ve ilgili çıktının ne olduğu ile beslenir). Ağacı açıklamak için iki varlık, karar düğümleri ve yapraklar kullanılabilir. Kararlar veya nihai sonuçlar yapraklarla temsil edilir. Ve veriler karar düğümlerinde ayrılır.

Bu iki modeli karşılaştırırken, iki katmanlı sinir ağı (aktivasyon fonksiyonu olmadan) iki katmanlı karar ağacından daha güçlüdür, çünkü iki katmanlı sinir ağı bir model oluştururken daha fazla özelliği dikkate alacaktır, oysa iki katmanlı karar ağaç yalnızca 2 veya 3 özelliği dikkate alacaktır.

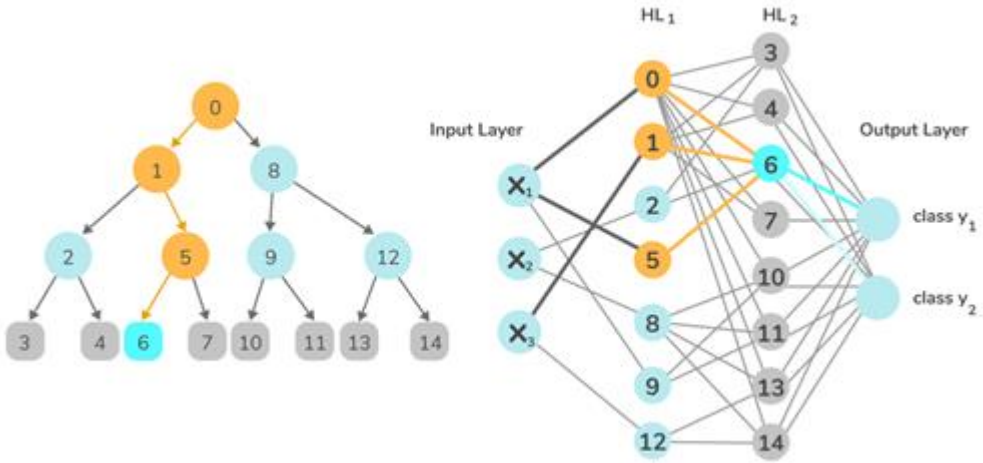

Soldaki şekil 2 katmanlı bir karar ağacını ve sağdaki şekil 2 katmanlı bir sinir ağını göstermektedir.

How does Recurrent Neural Network backpropagation vary from Artificial Neural Network backpropagation?

Tekrarlayan Sinir Ağı geri yayılımı, Yapay Sinir Ağı geri yayılımından nasıl farklıdır?

Tekrarlayan Sinir Ağlarında Geri Yayılım, aşağıdaki resimde gösterildiği gibi Tekrarlayan Sinir Ağlarındaki her düğümün ek bir döngüye sahip olması anlamında Yapay Sinir Ağlarından farklıdır:

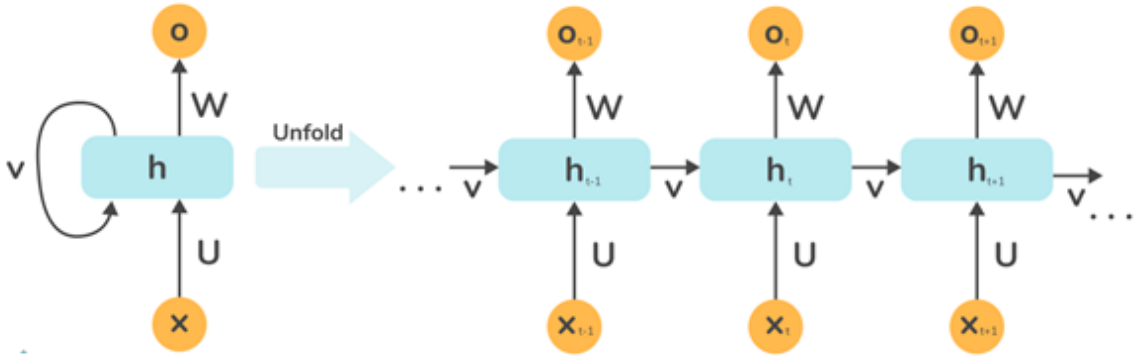

Bu döngü, özünde, ağa geçici bir bileşen ekler. Bu, genel bir yapay sinir ağı ile imkansız olan, verilerden sıralı bilgilerin yakalanmasına izin verir.

What exactly do you mean by exploding and vanishing gradients?
Patlayan ve kaybolan gradyanlarla tam olarak ne demek istiyorsunuz?

Minimum değere doğru artan adımlar atarak, gradyan iniş algoritması hatayı en aza indirmeyi amaçlar. Bir sinir ağındaki ağırlıklar ve yanlılıklar bu işlemler kullanılarak güncellenir.

Bununla birlikte, bazen adımlar aşırı derecede büyür ve ağırlıkların ve yanlılık terimlerinin güncellemelerinin artmasıyla sonuçlanır - ağırlıkların taştığı (veya NaN, yani Sayı Değil) noktaya kadar. Patlayan bir gradyan bunun sonucudur ve kararsız bir yöntemdir.

Öte yandan, adımlar aşırı derecede küçükse, ağırlıklarda ve sapma terimlerinde küçük, hatta ihmal edilebilir değişikliklerle sonuçlanır. Sonuç olarak, her seferinde neredeyse aynı ağırlıklara ve yanlıiklara sahip, hiçbir zaman en az hata işlevine ulaşmayan bir derin öğrenme modeli eğitebiliriz. Kaybolan gradyan buna denir.

What do you know about Dropout?
Bırakma hakkında ne biliyorsunuz?

Bırakma, fazla uydurmayı önlemeye yardımcı olan ve dolayısıyla genellenebilirliği artıran bir düzenleme yaklaşımıdır (yani model, yalnızca eğitim veri seti ile sınırlı olmak yerine, genel olarak girdilerin çoğu için doğru çıktıyı tahmin eder). Genel olarak, %20 ile iyi bir başlangıç noktası olmak üzere nöronların yüzde 20 ila yüzde 50'si gibi düşük bir bırakma değeri kullanmalıyız. Çok düşük bir olasılığın etkisi yoktur, oysa çok yüksek bir sayı ağın yetersiz öğrenmesine neden olur.

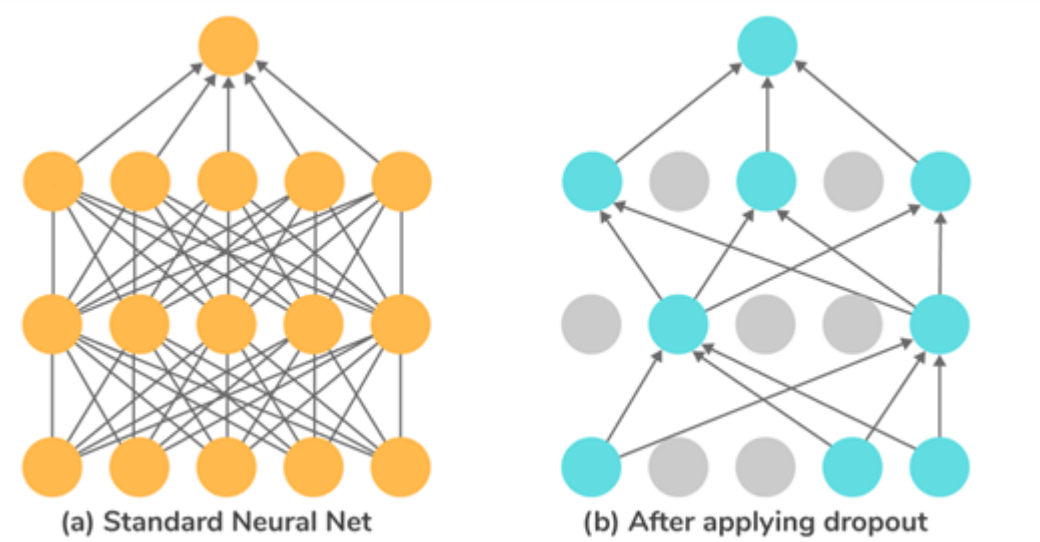

Daha büyük bir ağda bırakma yöntemini kullandığınızda, modelin bağımsız temsilleri öğrenmek için daha fazla fırsatı olduğundan daha iyi sonuçlar elde etme olasılığınız daha yüksektir.

Differentiate between Deep Learning and Machine Learning.
Derin Öğrenme ile Makine Öğrenimi arasında ayrım yapın.

Derin Öğrenme: Derin Öğrenme, tekrarlayan bir sinir ağının ve bir yapay sinir ağının bağlantılı olduğu bir Makine Öğrenimi alt sınıfıdır. Algoritmalar, makine öğrenimi algoritmalarıyla aynı şekilde oluşturulur, ancak daha birçok algoritma seviyesi vardır. Yapay sinir ağı, algoritmanın tüm ağlarının bir araya getirilmesini ifade eder. Çok daha basit bir ifadeyle derin öğrenme kavramı olan beyindeki tüm sinir ağlarını birbirine bağlayarak insan beynini taklit eder. Her türlü karmaşık problemin üstesinden gelmek için algoritmalar ve bir teknik kullanır.

Makine Öğrenimi: Makine öğrenimi, bir sistemin o seviyeye programlanmak zorunda kalmadan deneyimlerinden öğrenmesini ve büyümesini sağlayan bir Yapay Zeka (AI) alt kümesidir. Veriler, öğrenmek ve doğru sonuçlar elde etmek için Machine Learning tarafından kullanılır. Makine öğrenimi algoritmaları, daha fazla veri elde ederek öğrenme ve performanslarını iyileştirme yeteneğine sahiptir. Makine öğrenimi şu anda diğer uygulamaların yanı sıra sürücüsüz arabalarda, siber dolandırıcılık tespitinde, yüz tanımada ve Facebook arkadaş önerisinde kullanılmaktadır.

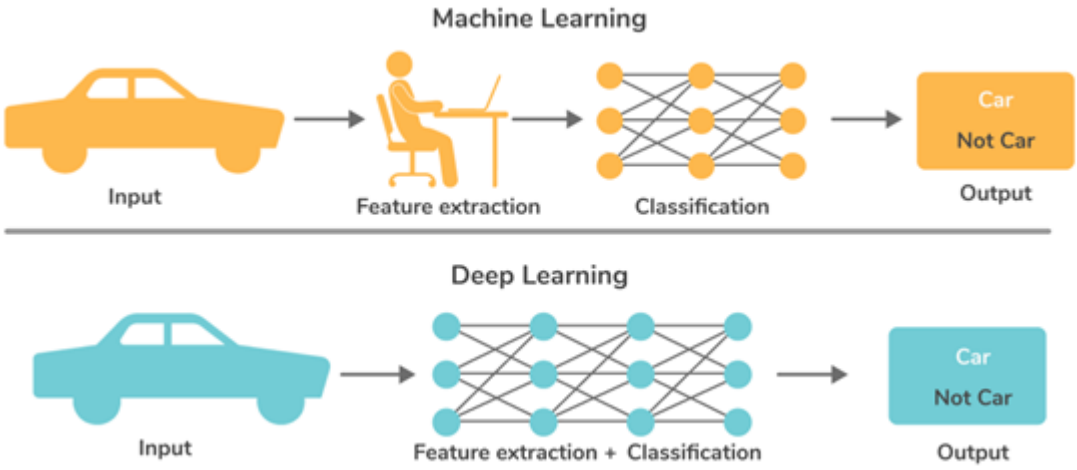

The following table illustrates the difference between them:

Derin Öğrenme:

- Derin Öğrenme, Makine Öğreniminin bir alt sınıfıdır.
- Derin Öğrenme, verileri temsil etmek için çok farklı bir veri temsili (YSA) olan sinir ağlarını kullanır.
- Bunda çıktı, sayısal değerlerden metin veya ses gibi serbest biçimli öğelere kadar değişir.
- Verileri işleme katmanlarından geçirerek veri özelliklerini ve ilişkilerini değerlendirmek için bir sinir ağı kullanır.
- Genellikle milyonlarca veri noktasıyla ilgilenir.
- Makine Öğrenimi, Derin Öğrenmeye dönüşmüştür. Esasen, makine öğreniminin derinliğini ifade eder.

Makine öğrenme:

- Makine Öğrenimi, Derin Öğrenmenin bir süper sınıfıdır.
- Makine Öğrenimi, yapılandırılmış verileri kullandığından, verileri Derin Öğrenme'den farklı bir şekilde temsil eder.
- Bunda, çıktı sayısal değerlerden oluşur
- Girdileri model işlevlerine dönüştürmek ve gelecekteki eylemleri tahmin etmek için çeşitli otomatik teknikler kullanır.
- Genellikle binlerce veri noktasıyla ilgilenir.
- Yapay Zeka, Makine Öğrenimi'ne dönüştü.

Explain the different types of activation functions.

36. Farklı aktivasyon fonksiyon tiplerini açıklayın.

Aşağıda, farklı etkinleştirme işlevi türleri verilmiştir:

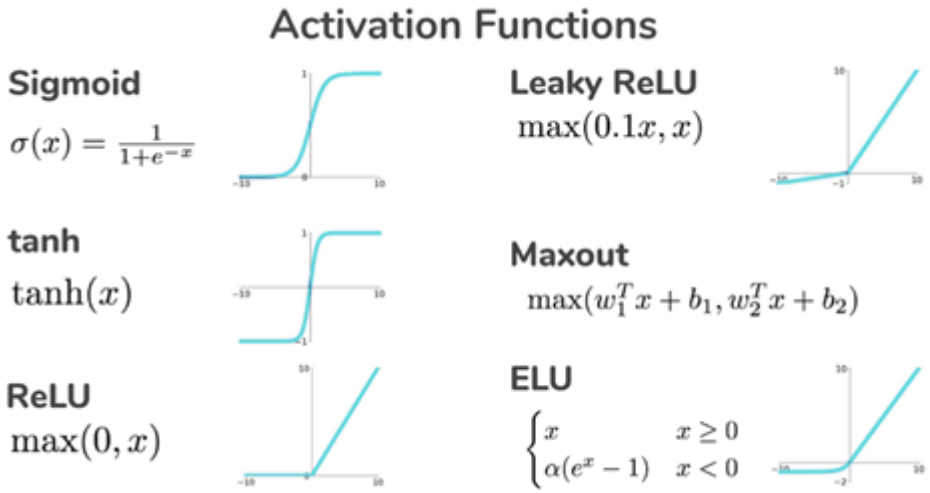

Sigmoid işlevi: Sigmoid işlevi, çoğunlukla ileri beslemeli sinir ağlarında kullanılan bir YSA'da doğrusal olmayan bir etkinleştirme işlevidir. Her yerde pozitif türevleri olan ve gerçek girdi değerleri için tanımlanmış belirli bir düzgünlük derecesine sahip türevlenebilir bir gerçek fonksiyondur. Sigmoid işlevi, derin öğrenme modellerinin çıktı katmanında bulunur ve olasılığa dayalı çıktıları tahmin etmek için kullanılır.

Hiperbolik Tanjant İşlevi (Tanh): Tanh işlevi, -1 ila 1 aralığına sahip daha yumuşak ve sıfır merkezli bir işlevdir. Çok katmanlı sinir ağları için daha yüksek eğitim performansı sağladığından, tanh işlevi sigmoid işlevinden çok daha yaygın olarak kullanılır. Tanh fonksiyonunun birincil avantajı, geri yayılıma yardımcı olan sıfır merkezli bir çıktı vermesidir.

Softmax işlevi: softmax işlevi, bir gerçek sayı vektöründen olasılık dağılımı oluşturmak için sinir ağlarında kullanılan başka bir etkinleştirme işlevi türüdür. Bu işlev, olasılıkların toplamı 1'e eşit olacak şekilde 0 ile 1 arasında bir sayı döndürür. Bu işlev en yaygın olarak çok sınıflı modellerde kullanılır ve hedef sınıf en yüksek olasılığa sahip olacak şekilde her sınıf için olasılıkları döndürür. DL mimarisinin hemen hemen tüm çıktı katmanlarında bulunabilir.

Softsign işlevi: Bu, en yaygın olarak regresyon hesaplama sorunları ve derin öğrenmeye dayalı metin okuma uygulamalarında kullanılır.

Düzeltilmiş Doğrusal Birim İşlevi: Doğrultulmuş doğrusal birim (ReLU) işlevi, üstün performans ve olağanüstü sonuçlar vermeyi vaat eden hızlı öğrenen bir yapay zekadır (AI). Derin öğrenmede, ReLU işlevi, performans ve genelleme açısından sigmoid ve tanh işlevleri gibi diğer AF'lerden daha iyi performans gösterir. İşlev, doğrusal modellerin özelliklerini

koruyan ve gradyan iniş yaklaşımlarını optimize etmeyi kolaylaştıran kabaca doğrusal bir işlevdir. Her giriş öğesinde, ReLU işlevi, sıfırdan küçük tüm değerleri sıfıra ayarlayarak bir eşik işlemi gerçekleştirir.

Üstel Doğrusal Birim İşlevi: Üstel doğrusal birimler (ELU'lar) işlevi, sinir ağı eğitimini hızlandırmak için kullanılabilen bir AF türüdür (tıpkı ReLU işlevi gibi). ELU fonksiyonunun en büyük avantajı, pozitif değerler için özdeşlik kullanarak ve modelin öğrenme özelliklerini artırarak kaybolan gradyan problemini çözebilmesidir.

Convolutional Neural Networks (CNNs):

Konvolüsyonel Sinir Ağları çoğunlukla bilgisayar görsellerde kullanılır. MLP'lerdeki tam bağlantılı katmanların aksine, bir veya daha fazla evrişim katmanı, CNN modellerinde evrişim işlemleri gerçekleştirerek girdiden basit özellikler çıkarır. Her katman, önceki katmanın çıktılarının uzamsal olarak yakın alt kümelerinin çeşitli koordinatlarındaki ağırlıklı toplamların doğrusal olmayan işlevlerinden oluşur ve ağırlıkların yeniden kullanılmasına izin verir.

AI sistemi, gerçek dünyadan bir dizi görüntü veya video verildiğinde resim sınıflandırma, yüz tanımlama ve görüntü anlamsal bölümleme gibi belirli bir görevi yerine getirmek için bu girdilerin özelliklerini otomatik olarak çıkarmayı öğrenir.

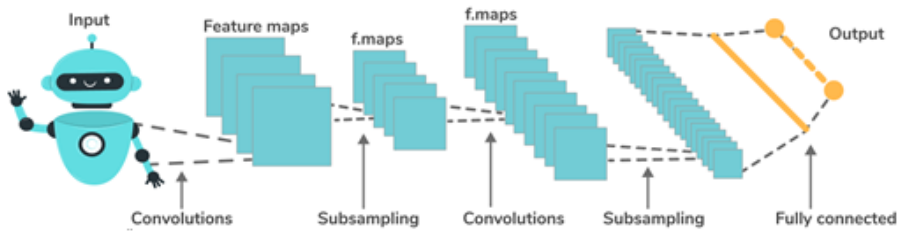

ConvNets olarak da bilinen CNN'ler, çoklu katmanlardan oluşur ve esas olarak görüntü işleme ve nesne algılama için kullanılır. Yann LeCun, ilk CNN'i 1988'de LeNet olarak adlandırıldığında geliştirdi. Posta kodları ve rakamlar gibi karakterleri tanımak için kullanıldı. CNN'ler, uydu görüntülerini tanımlamak, tıbbi görüntüleri işlemek, zaman serilerini tahmin etmek ve anormallikleri tespit etmek için yaygın olarak kullanılmaktadır.

CNN'ler Nasıl Çalışır?

CNN'ler, verilerden özellikleri işleyen ve çıkaran birden çok katmana sahiptir:
Evrişim Katmanı: CNN, evrişim işlemini gerçekleştirmek için birkaç filtreye sahip bir evrişim katmanına sahiptir.

Rektifiye Lineer Birim (ReLU): CNN'ler, öğeler üzerinde işlemleri gerçekleştirmek için bir ReLU katmanına sahiptir. Çıktı, düzeltilmiş bir özellik haritasıdır.
Havuzlama Katmanı: Düzeltilmiş özellik haritası daha sonra bir havuz katmanına beslenir. Havuzlama, özellik haritasının boyutlarını azaltan bir alt örnekleme işlemidir. Havuzlama katmanı daha sonra havuzlanmış özellik haritasından elde edilen iki boyutlu dizileri düzleştirerek tek, uzun, sürekli, doğrusal bir vektöre dönüştürür.
Tam Bağlantılı Katman: Havuzlama katmanından gelen düzleştirilmiş matris, görüntüleri sınıflandıran ve tanımlayan bir girdi olarak beslendiğinde, tam bağlantılı bir katman oluşur.

Aşağıda CNN aracılığıyla işlenen bir görüntü örneği bulunmaktadır.

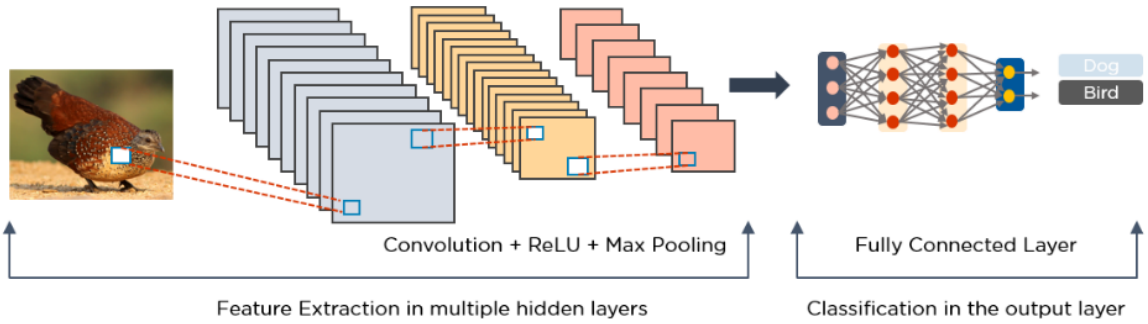

In a Convolutional Neural Network (CNN), how can you fix the constant validation accuracy?
Bir Evrişimli Sinir Ağında (CNN), sabit doğrulama doğruluğunu nasıl düzeltebilirsiniz?

Herhangi bir sinir ağını eğitirken, sürekli doğrulama doğruluğu yaygın bir sorundur, çünkü ağ yalnızca örneği hatırlayarak aşırı uyum sorununa neden olur. Bir modele aşırı uydurma, sinir ağı modelinin eğitim örneğinde takdire şayan bir performans gösterdiğini, ancak modelin performansının doğrulama setinde bozulduğunu gösterir. CNN'nin sürekli doğrulama doğruluğunu iyileştirmenin bazı yolları aşağıda verilmiştir:
• Veri setini üç bölüme ayırmak her zaman iyi bir fikirdir: eğitim, doğrulama ve test etme.
• Sınırlı verilerle çalışırken, bu zorluk, sinir ağının parametreleriyle deneyler yapılarak aşılabilir.
• Eğitim veri setinin boyutunu artırarak.
• Toplu normalleştirme kullanarak.
• Düzenlileştirme uygulayarak
• Ağın karmaşıklığını azaltarak

Long Short Term Memory Networks (LSTMs):

LSTMs are a type of Recurrent Neural Network (RNN) that can learn and memorize long-term dependencies. Recalling past information for long periods is the default behavior.

LSTMs retain information over time. They are useful in time-series prediction because they remember previous inputs. LSTMs have a chain-like structure where four interacting layers communicate in a unique way. Besides time-series predictions, LSTMs are typically used for speech recognition, music composition, and pharmaceutical development.

How Do LSTMs Work?

- First, they forget irrelevant parts of the previous state
- Next, they selectively update the cell-state values
- Finally, the output of certain parts of the cell state

Below is a diagram of how LSTMs operate:

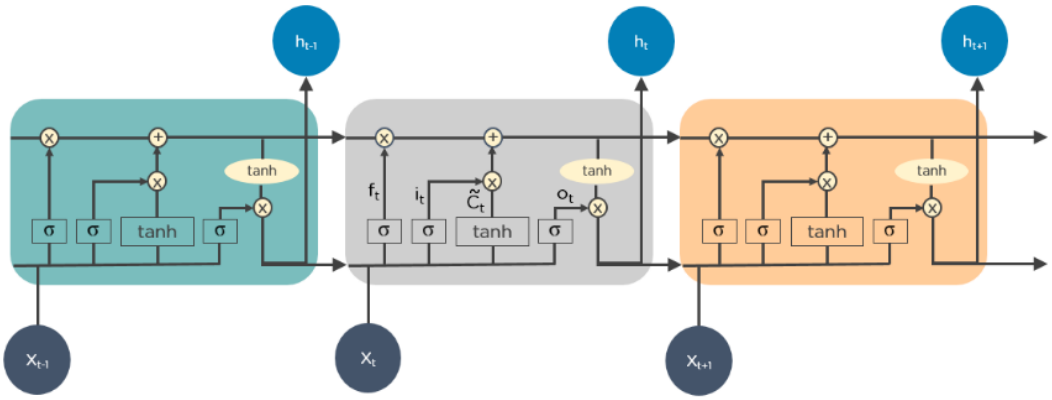

Recurrent Neural Networks (RNNs):

Recurrent Neural Network (RNN):
Tekrarlayan Sinir Ağları:

Sıralı giriş verisi zaman serisi problemini çözmek için Tekrarlayan Sinir Ağları oluşturuldu. RNN'nin girişi, mevcut giriş ve önceki örneklerden oluşur. Sonuç olarak, düğüm bağlantıları yönlendirilmiş bir grafik oluşturur. Ayrıca, bir RNN'deki her nöronun, önceki örneklerin hesaplamalarından elde edilen bilgileri depolayan bir dahili belleği vardır. RNN modelleri, değişken giriş uzunluğuna sahip verileri işlemedeki üstünlüklerinden dolayı, doğal dil işlemede (NLP) yaygın olarak kullanılır. Bu durumda AI'nın amacı, doğal dil modelleme, kelime yerleştirme ve makine çevirisi gibi insan tarafından konuşulan doğal dilleri anlayabilen bir sistem oluşturmaktır.

Bir RNN'deki her ardışık katman, ağırlıklı çıktı toplamlarının ve önceki durumun doğrusal olmayan fonksiyonlarından oluşur. Sonuç olarak, RNN'nin temel birimi "hücre" olarak adlandırılır ve her hücre katmanlardan ve tekrarlayan sinir ağı modellerinin sıralı olarak işlenmesine izin veren bir dizi hücreden oluşur.

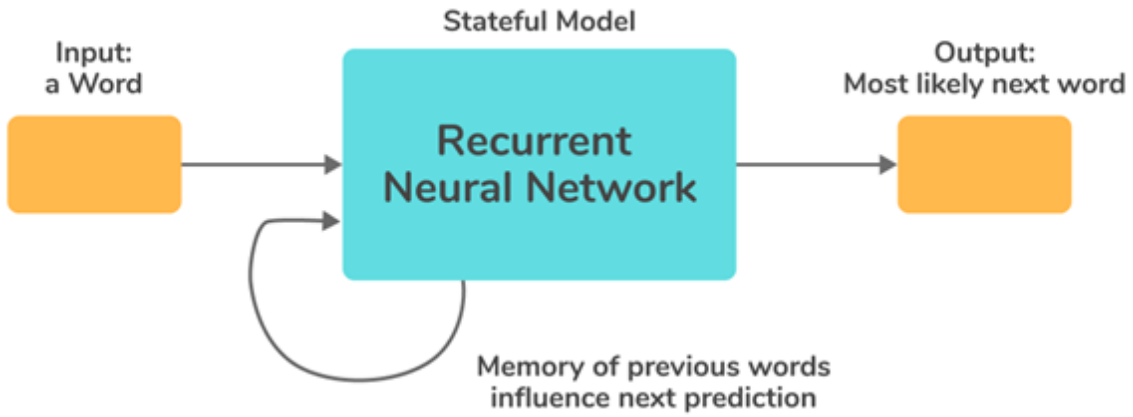

Modular Neural Network:
Bu ağ, tek bir ağ olmaktan ziyade çok sayıda küçük sinir ağlarından oluşur. Alt ağlar, ortak bir hedefe ulaşmak için bağımsız olarak çalışan daha büyük bir sinir ağı oluşturmak için birleşir. Bu ağlar, büyük-küçük bir sorunu daha küçük parçalara bölmek ve sonra onu çözmek için son derece kullanışlıdır.

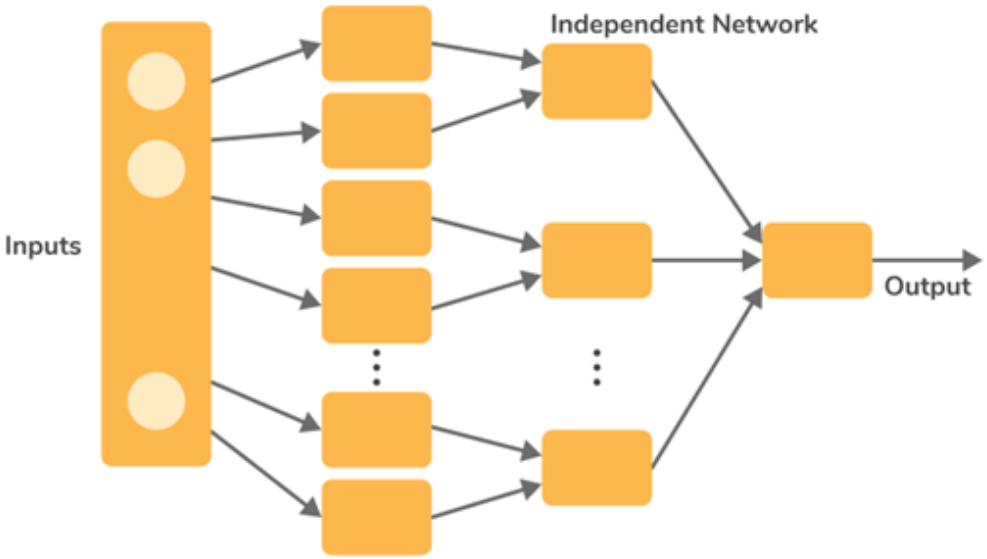

Sequence to Sequence Model:

Sıradan Sıraya Model:

Çoğu durumda, bu ağ iki RNN ağından oluşur. Ağ, kodlama ve kod çözmeye dayalıdır; bu, girdiyi işleyen bir kodlayıcıya ve çıktıyı işleyen bir kod çözücüye sahip olduğu anlamına gelir. Bu ağ türü, giren metnin uzunluğu, çıkan metnin uzunluğundan farklı olduğunda, genellikle metin işleme için kullanılır.

Deep Belief Networks (DBNs):

DBN'ler, birden çok stokastik, gizli değişken katmanından oluşan üretken modellerdir. Gizli değişkenler ikili değerlere sahiptir ve genellikle gizli birimler olarak adlandırılır.

DBN'ler, katmanlar arasında bağlantıları olan bir Boltzmann Makinesi yığınıdır ve her bir RBM katmanı, hem önceki hem de sonraki katmanlarla iletişim kurar. Derin İnanç (Kanı) Ağları (DBN'ler) görüntü tanıma, video tanıma ve hareket yakalama verileri için kullanılır.

DBN'ler Nasıl Çalışır?

- Açgözlü öğrenme algoritmaları DBN'leri eğitir. Açgözlü algoritma, her aşamada yerel olarak en uygun seçimi yapma problem çözme buluşsal yöntemini izleyen herhangi bir algoritmadır. Açgözlü öğrenme algoritması, yukarıdan aşağıya, üretken ağırlıkları öğrenmek için katman katman bir yaklaşım kullanır.
- DBN'ler, Gibbs örnekleme adımlarını en üstteki iki gizli katmanda çalıştırır. Bu aşama, en üstteki iki gizli katman tarafından tanımlanan RBM'den bir örnek alır.
- DBN'ler, modelin geri kalanı boyunca tek bir atasal örnekleme geçişini kullanarak görünür birimlerden bir örnek alır.
- DBN'ler, her katmandaki gizli değişkenlerin değerlerinin aşağıdan yukarıya tek bir geçişle çıkarılabileceğini öğrenir.

Below is an example of DBN architecture:

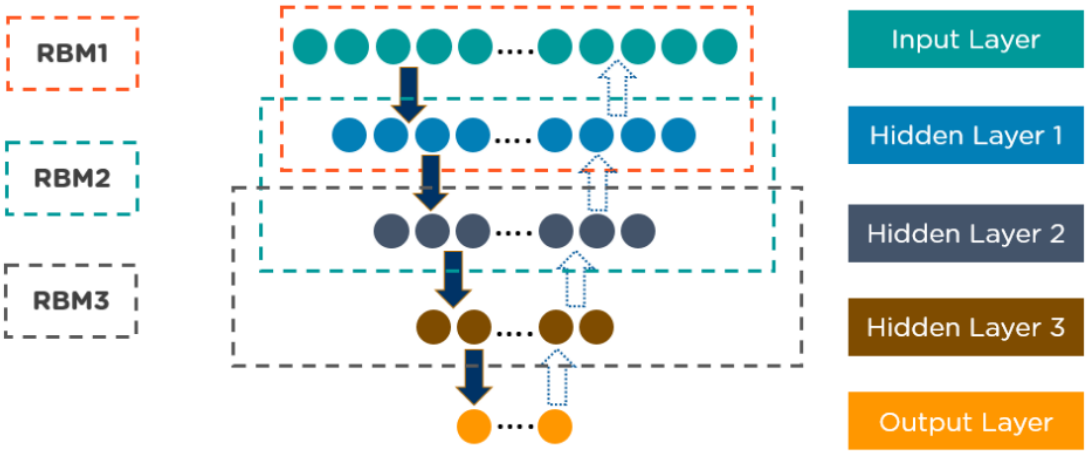

Autoencoders:

What are autoencoders? Explain the different layers of autoencoders.

Otomatik kodlayıcılar nelerdir? Otomatik kodlayıcıların farklı katmanlarını açıklayın.

Otomatik kodlayıcı, çıktı katmanının giriş katmanıyla aynı boyuta sahip olması koşuluyla bir tür sinir ağıdır. Başka bir deyişle, çıktı katmanındaki çıktı birimlerinin sayısı, girdi katmanındaki girdi birimlerinin sayısına eşittir. Otomatik kodlayıcı, girdiden çıktıya verileri denetimsiz bir şekilde çoğalttığı için çoğaltıcı sinir ağı olarak da bilinir.

Girişi ağ üzerinden göndererek, otomatik kodlayıcılar girişin her bir boyutunu yeniden oluşturur. Bir girdiyi çoğaltmak için bir sinir ağı kullanmak basit görünebilir, ancak çoğaltma işlemi sırasında girdinin boyutu küçülür, bu da daha küçük bir temsille sonuçlanır. Giriş ve çıkış katmanlarına kıyasla, sinir ağının orta katmanları daha az birime sahiptir. Sonuç olarak, girdinin azaltılmış temsili orta katmanlarda depolanır. Girdinin bu azaltılmış temsili, çıktıyı yeniden oluşturmak için kullanılır.

Otomatik kodlayıcıların mimarisindeki farklı katmanlar şunlardır:

Kodlayıcı: Kodlayıcı, giriş görüntüsünü bir gizli uzay temsiline sıkıştıran ve onu daha düşük bir boyutta sıkıştırılmış bir temsil olarak kodlayan, tamamen bağlı, ileri beslemeli bir sinir ağıdır. Orijinal görüntünün deforme olmuş temsili sıkıştırılmış görüntüdür.

Kod: Kod çözücüye sağlanan girişin azaltılmış gösterimi ağın bu bölümünde saklanır.

Kod çözücü: Kodlayıcı gibi, kod çözücü de kodlayıcıyla aynı yapıya sahip ileri beslemeli bir ağdır. Bu ağ, koddan gelen girdiyi orijinal boyutlarına yeniden monte etmekten sorumludur.

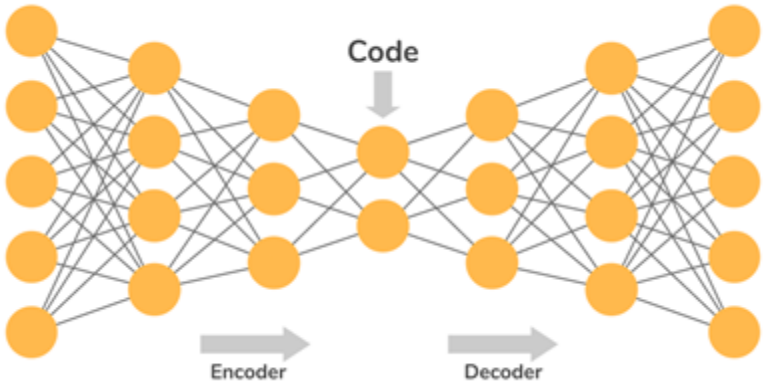

Yukarıdaki resimde gördüğümüz gibi, girdi kodlayıcıda sıkıştırılır, ardından Kodda saklanır ve ardından orijinal girdi kod çözücü tarafından koddan açılır. Otomatik kodlayıcının temel amacı, girdiyle aynı olan bir çıktı sağlamaktır.

Mention the applications of autoencoders.

Otomatik kodlayıcıların uygulamalarından bahsedin.
Otomatik kodlayıcıların uygulamaları şunlardır: -

Görüntü Gürültüsünü Giderme: Görüntüleri gürültüden arındırma, otomatik kodlayıcıların çok başarılı olduğu bir beceridir. Gürültülü bir görüntü, bozulmuş veya içinde az miktarda parazit (yani, görüntülerde rastgele parlaklık veya renk bilgisi değişimi) bulunan görüntüdür. Görüntü denoising, görüntünün içeriği hakkında doğru bilgi elde etmek için kullanılır.

Boyutsallık Azaltma: Giriş, kod adı verilen orta katmanda depolanan otomatik kodlayıcılar tarafından azaltılmış bir temsile dönüştürülür. Bu, girdiden gelen bilgilerin sıkıştırıldığı yerdir ve artık her düğüm, bu katman modelden çıkarılarak bir değişken olarak ele alınabilir. Sonuç olarak, kod çözücüyü kaldırarak, çıktı olarak kodlama katmanı ile boyut azaltma için bir otomatik kodlayıcının kullanılabileceği sonucuna varabiliriz.

Özellik Çıkarma: Otomatik Kodlayıcıların kodlama bölümü, yeniden yapılandırma hatasını azaltarak giriş verilerinde bulunan önemli gizli özelliklerin öğrenilmesine yardımcı olur. Kodlama sırasında, orijinal özellik kombinasyonlarından oluşan yeni bir koleksiyon oluşturulur.

Görüntü Renklendirme: Siyah beyaz bir görüntüyü renkli bir görüntüye dönüştürmek, otomatik kodlayıcıların uygulamalarından biridir. Renkli bir görüntüyü gri tonlamaya da dönüştürebiliriz.

Veri Sıkıştırma: Veri sıkıştırma için otomatik kodlayıcılar kullanılabilir. Yine de, aşağıdaki nedenlerden dolayı nadiren veri sıkıştırma için kullanılırlar: Kayıplı sıkıştırma: Otomatik kodlayıcının çıkışı girişle aynı değildir, ancak yakın fakat bozulmuş bir temsildir. Kayıpsız sıkıştırma için en iyi seçenek değildirler. Veriye özel: Otomatik kodlayıcılar, yalnızca eğitildikleri verilerle aynı olan verileri sıkıştırabilir. Sağlanan eğitim verileriyle ilgili özellikleri öğrenmeleri bakımından jpeg veya gzip gibi geleneksel veri sıkıştırma algoritmalarından farklıdırlar. Sonuç olarak, elle yazılmış rakamlarla eğitilmiş bir otomatik kodlayıcı tarafından sıkıştırılacak bir manzara fotoğrafını tahmin edemeyiz.

Otomatik kodlayıcılar, giriş ve çıkışın aynı olduğu belirli bir ileri beslemeli sinir ağı türüdür. Geoffrey Hinton, 1980'lerde denetimsiz öğrenme sorunlarını çözmek için otomatik kodlayıcılar tasarladı. Verileri girdi katmanından çıktı katmanına kopyalayan eğitimli sinir ağlarıdır. Otomatik kodlayıcılar, farmasötik keşif, popülerlik tahmini ve görüntü işleme gibi amaçlar için kullanılır.

Otomatik Kodlayıcılar Nasıl Çalışır?

Bir otomatik kodlayıcı üç ana bileşenden oluşur: kodlayıcı, kod ve kod çözücü.

- Otomatik kodlayıcılar, bir girdi alacak ve onu farklı bir temsile dönüştürecek şekilde yapılandırılmıştır. Daha sonra orijinal girdiyi mümkün olduğu kadar doğru bir şekilde yeniden oluşturmaya çalışırlar.
- Bir rakamın görüntüsü net olarak görülmediğinde, otomatik kodlayıcı sinir ağına beslenir.
- Otomatik kodlayıcılar önce görüntüyü kodlar, ardından girdinin boyutunu daha küçük bir temsile küçültür.
- Son olarak, otomatik kodlayıcı, yeniden oluşturulmuş görüntüyü oluşturmak için görüntünün kodunu çözer.

Aşağıdaki resim, otomatik kodlayıcıların nasıl çalıştığını gösterir:

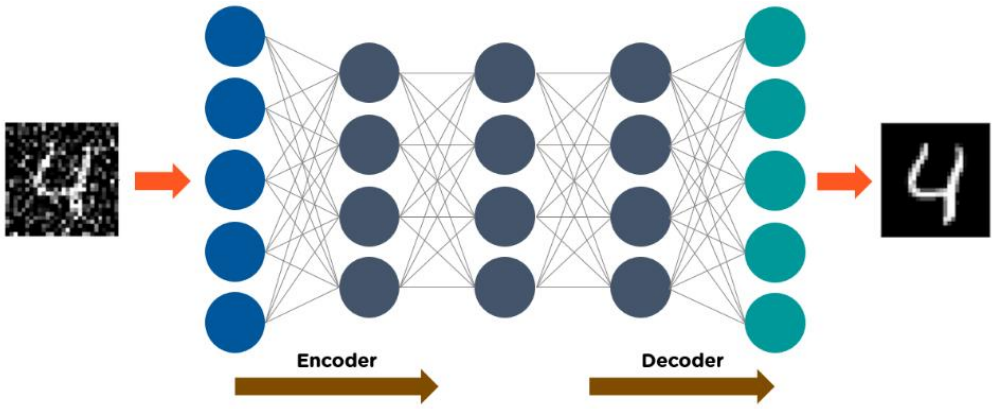

9. Genetik Algoritmalar

Genetik algoritma (GA), belirli bir soruna iyi çözümler bulma umuduyla yeni genotipler üretmek için mutasyon ve çaprazlama gibi yöntemleri kullanarak doğal seleksiyon sürecini taklit eden bir arama algoritması ve sezgisel tekniktir. Makine öğrenmesinde, 1980'ler ve 1990'larda genetik algoritmalar kullanılmıştır. Tersine, genetik ve evrimsel algoritmaların performansını arttırmak için makine öğrenme teknikleri kullanılmıştır.

Genetik Algoritma yaklaşımının ortaya çıkışı 1970 'lerin başında olmuştur . 1975 'te John Holland'ın makine öğrenmesi üzerine yaptığı çalışmalarda canlılardaki evrimden ve değişimden etkilenerek, bu genetik evrim sürecini bilgisayar ortamına aktarması ve böylece bir tek mekanik yapının öğrenme yeteneğini geliştirmek yerine, çok sayıdaki böyle yapıların tamamını " çoğalma, değişim gibigenetik süreçler sonunda üstün yeni bireylerin elde edilebileceğini gösteren çalışmasından çıkan sonuçların yayınlanmasından sonra geliştirdiği yöntemin adı "Genetik Algoritmalar" olarak tanınmıştır.

Genetik Algoritmalar, süreçleri model olarak kullanan problem çözme teknikleridir. Öğrenen Makina Algoritmaları ise tecrübe ile ortaya çıkan yeni duruma ya da belirsizliğe ilişkin parameterlerin otomatik olarak belirlendiği matematiksel modellerdir.

Genetik Algoritmalar mümkün olan çözümlerin bir popülasyonu üzerinde işlem yapan olasılıklı (stochastic) arama algoritmalarıdır. Geleneksel programlama teknikleriyle çözülmesi güç olan, özellikle sınıflandırma ve çok boyutlu optimizasyon problemleri, bunların yardımıyla daha kolay ve hızlı olarak çözüme ulaştırılmaktadır. Genetik algoritmalar doğada geçerli olan en iyinin yaşaması kuralına dayanarak sürekli iyileşen çözümler üretir. Bunun için "iyi"nin ne olduğunu belirleyen bir uygunluk fonksiyonu ve yeni çözümler üretmek için yeniden kopyalama, değiştirme gibi operatörleri kullanır. Görevler için programın ölçülen performansı tecrübe ile artıyor ise bu program tecrübe ile öğreniyor denilebilir. Genetik algoritmalar robot kontrolü için kural kümelerinin öğrenilmesi ve yapay sinir ağları için topoloji ve öğrenme parametrelerinin optimize edilmesi için kullanılmaktadır.

Göçmen kuşlar, her yıl çıktıkları yolculukta adreslerini hiç şaşırmadan, hiçbir duraklarını atlamadan, yüzyıllardır sürekli hareket halindeler; üstelik pusulasız ve haritasız... Dünyadaki on binlerce kuş türünün sadece sekiz bin kadarı her yıl binlerce kilometre kat ederek nesillerini sürdürmeye çalışır. Kimileri sürüler halinde, kimileri küçük gruplar halinde ömürlerinin sonuna kadar kendilerini bu uzun yolculuğa adarlar. Bu kuşların tek bir ortak amaçları vardır: Üremek ve beslenmek. Göçmen kuşların uzun uçuşlarına iç güdüsel olarak hazırlandıklarını da söyleyebiliriz. Öyle ki, genlerinde uzak diyarlara göç etme nitelikleri bulunan hayvanat bahçelerinde, ya da kafeste beslenen kuşlar göç vakti geldiklerinde kıpır kıpır oldukları gözlenir.

Göçmen kuşların her yıl binlerce kilometre süren yolculukları sırasında yönlerini kaybolmadan nasıl tayin edebildikleri üzerine yapılan araştırmalarda ortaya sadece mantıksal tahminler atılmış durumda. Örneğin, kuşların tanıdık kara parçalarını ezberledikleri, sürekli sahil şeridini takip ettikleri gibi var sayımlar bir yere kadar doğru ama uzun deniz yolculukları yapanlar bu varsayımları yerle bir ediyor. Diğer taraftan gece uçuşu yapanlar içinse yıldızların onlara yol gösterdiği düşünülüyor. Bir diğer var sayım ise göçmen kuşların, dünyanın manyetik alan çizgilerini takip ederek kaybolmadan yönlerini bulabildikleri şeklinde. Modern çağın nimetlerinden biri olan GPS sayesinde işaretlenen kimi göçmen kuşların izledikleri rotalar her yıl tıpa tıp aynı. Hatta inanılması güç ama, her yıl mola verdikleri yerler bile şaşmıyor.

Göçmen kuşların hayranlıkla izlenebilecek bir başka özellikleri de havada çizdikleri V şeklindeki düzen olsa gerek. Öyle ya, ancak bu şekilde onları diğer sürülerden net bir şekilde ayırt edebiliyoruz. Bu uçuş düzeninin iki önemli avantajı var. İlki, en öndeki lider kuşu görebilmek. İkincisi ve tabi ki daha önemli olanı ise hemen öndeki kuşun yarattığı hava akımından yararlanarak daha az enerji harcayarak uçmak. Kuşların bu şekilde uçmaları sayesinde tahminen yüzde 20'lik bir enerji tasarrufu sağladıklarına inanılıyor. Eğer havada bu tür bir V oluşumu yakalarsanız, kuşların yerlerini sürekli değiştirdiğine de tanık olacaksınız. Özellikle de en önde uçarak en fazla yorulan lider kuşa eşlik edenlerin onun yerini nasıl almaya çalıştıklarını göreceksiniz.

Geleneksel programlama teknikleriyle çözülmesi güç olan, özellikle sınıflandırma ve çok boyutlu optimizasyon problemleri, bunların yardımıyla daha kolay ve hızlı olarak çözüme ulaştırılmaktadır. Genetik algoritmalar doğada geçerli olan en iyinin yaşaması kuralına dayanarak sürekli iyileşen çözümler üretir. Bunun için "iyi"nin ne olduğunu belirleyen bir uygunluk fonksiyonu ve yeni çözümler üretmek için yeniden kopyalama, değiştirme gibi operatörleri kullanır. Görevler için programın ölçülen performansı tecrübe ile artıyor ise bu program tecrübe ile öğreniyor denilebilir. Genetik algoritmalar robot kontrolü için kural kümelerinin öğrenilmesi ve yapay sinir ağları için topoloji ve öğrenme parametrelerinin optimize edilmesi için kullanılmaktadır.

Genetik algoritmalar, evrim teorisinin dayandığı temel prensiplerinden olan doğal seçilim ile en iyi bireylerin hayatta kalması ilkesini taklit eden bir tekniktir. Burada yapılan, en iyi çözümün pek çok çözüm seçeneği içinden arama yapılarak belirlenmesidir. Rassal arama teknikleri ile eldeki mevcut çözümlerden hareketle en iyi çözüme ulaşılmaya çalışılmaktadır. Basit bir genetik algoritmanın işlem adımları; problemin olası çözümlerinin dizilere (kromozomlar) kodlanarak çözüm yığınının oluşturulması, kromozomların çözüme yaklaşma başarısının uygunluk fonksiyonu ile değerlendirilmesi, genetik parametrelerin belirlenmesi, seçim stratejisi ve mekanizmaları, genetik operatörler ve durdurma kriteri olarak sıralanabilir.

Genetik algoritmalar, bilinen yöntemlerle çözülemeyen veya çözüm süresi problemin büyüklüğüne göre oldukça fazla olan problemlerde, kesin sonuca çok yakın sonuçlar verebilen bir yöntemdir. Bu özelliği ile, NP (Nonpolynomially-Polinomal olmayan) problemler yanında gezgin satıcı, karesel atama, yerleşim, atölye çizelgeleme, mekanik öğrenme, üretim planlama, elektronik, finansman ve hücresel üretim gibi konularda uygulanmaktadır.

GEN: Kendi başına anlamı olan ve genetik bilgi taşıyan en küçük genetik birimdir.

- Bir gen A, B gibi bir karakter olabileceği gibi 0 veya 1 ile ifade edilen bir bit veya bit dizisi olabilir. Örneğin bir cismin x koordinatındaki yerini gösteren bir gen 101 şeklinde ifade edilebilir

KROMOZOM: Bir ya da birden fazla genin bir araya gelmesiyle oluşurlar Probleme ait tüm bilgileri içerirler. Kromozomlar toplumdaki bireyler yada üyelere karşılık gelirler. Ele alınan problemde alternatif çözüm adayıdır.

Örneğin, kromozom bir problemde açı, boyut ve koordinat değişkenlerinden veya bir dikdörtgen prizmasının ölçülerinden (genişlik, derinlik) oluşabilir 001 101 111 1 5 7 değerleri kromozomu oluşturan genlerdir. Genetik algoritma işlemlerinde kromozomları kullandığı için kromozom tanımları çok iyi ifade edilmelidir.

POPÜLASYON: Kromozomlar veya bireyler topluluğudur. Popülasyon üzerinde durulan problem için alternatif çözümler kümesidir. Aynı anda bir popülasyonda ki birey sayısı sabit ve probleme göre kullanıcı tarafından belirlenir. Zayıf olan bireylerin yerini kuvvetli yeniler almaktadır.

Genetik Algoritmalar Nasıl Çalışır?

1. Adım: Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur. Çözüm grubuna biyolojideki benzerliği nedeniyle populasyon çözümlerin kodları da kromozom olarak adlandırılır. Bu adıma populasyonda bulunan birey sayısı belirleyerek başlanır. Bu sayı için bir standart yoktur. Genel olarak önerilen 100 - 300 aralığında bir büyüklüktür. Büyüklük seçiminde yapılan işlemlerin karmaşıklığı ve aramanın derinliği önemlidir. Populasyon bu işlemden sonra rasgele oluşturulur.
2. Adım: Her kromozomun ne kadar iyi olduğu bulunur Kromozomların ne kadar iyi olduğunu bulan fonksiyona uygunluk fonksiyonu denir Bu fonksiyon işletilerek kromozomların uygunluklarının bulunmasına ise hesaplama(evalution adı verilir Bu fonksiyon genetik algoritmanın beynini oluşturmaktadır GA da probleme özel çalışan tek kısım bu fonksiyondır. Çoğu zaman GA nın başarısı bu fonksiyonun verimli ve hassas olmasına bağlı olmaktadır

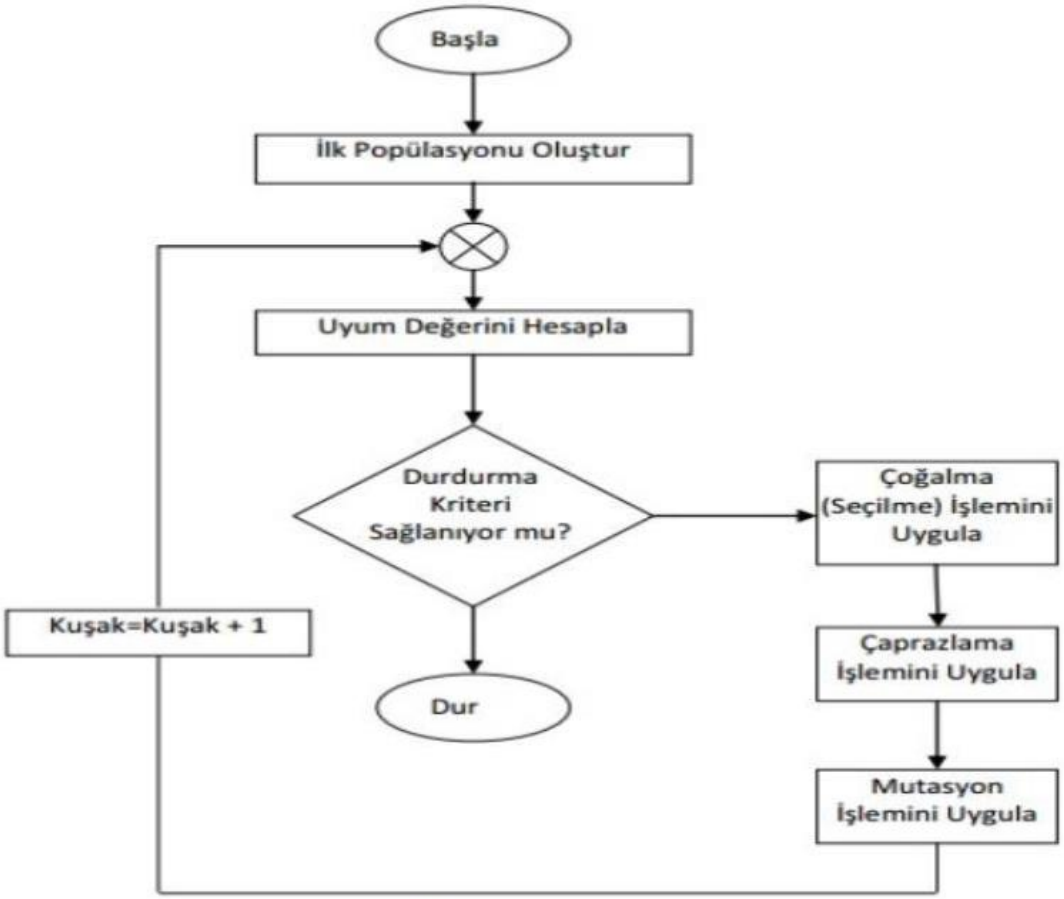

Genetik algoritmanın akış diyağramı.

Genetic Programming Background:

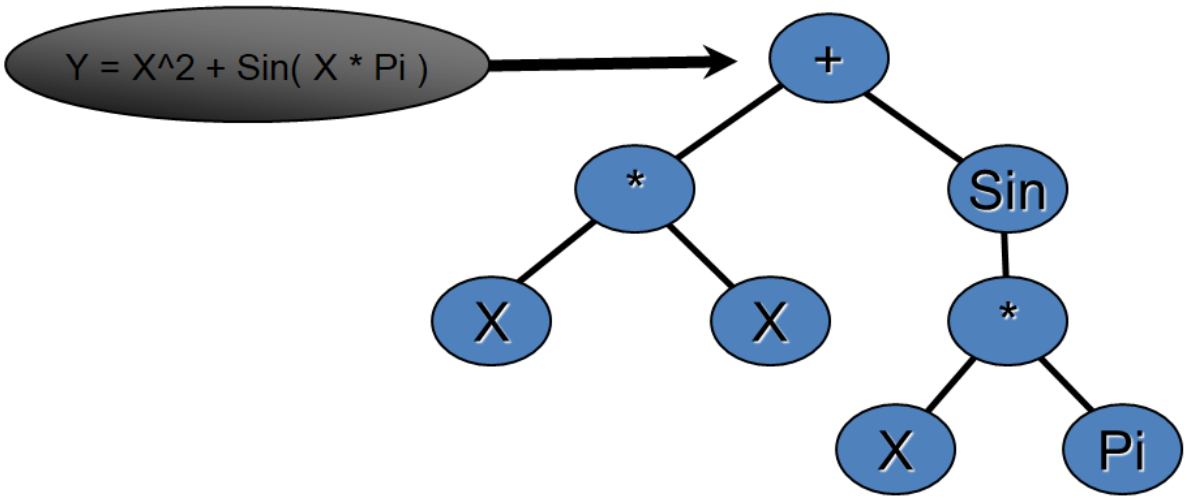

Crossover: bir üst programdaki bir makinedeki işlem sırasını başka bir ana makinedeki başka bir makinedeki işlem dizisiyle birleştirin.

Example 1.

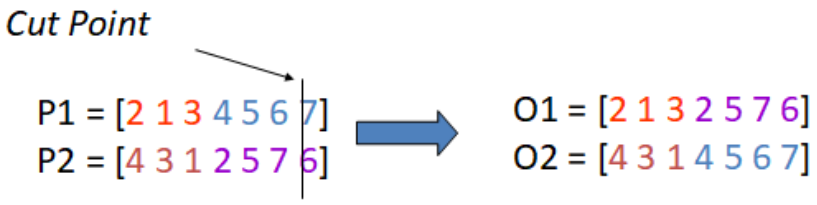

Example 2. Partially Mapped Crossover

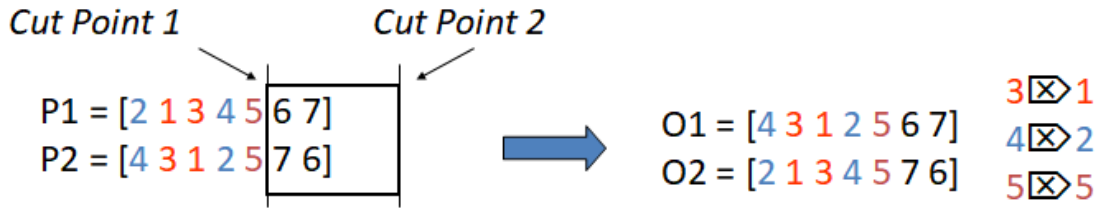

Örnek: P1'den alınan işlerin mutlak konumlarını ve P2'den alınanların göreceli konumlarını korur.

Örnek: Örnek 3'e benzer ancak 2 geçiş noktası vardır.

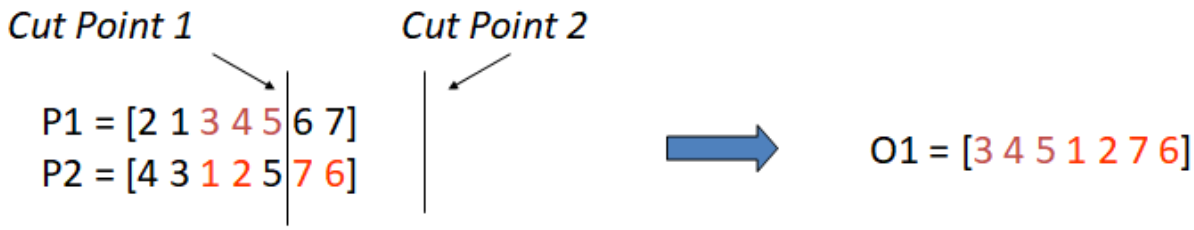

Örnek:
Aşağıdaki ifadeyi karşılayan GA'yı kullanarak a ve b'nin optimal değerlerini tahmin edelim.

$$2a^2 + b = 57$$

Herhangi bir optimizasyon problemi, bir amaç fonksiyonuyla başlar. Yukarıdaki denklem şu şekilde yazılabilir:

$$f(a,b)= 2a^2 + b - 57$$

Fonksiyonun değerinin 0 olduğu anlaşılmaktadır. Bu fonksiyon bizim amaç fonksiyonumuzdur ve amaç a ve b değerlerini tahmin etmektir, öyle ki objektif fonksiyonun değeri sıfıra indirilir.

Örnek:

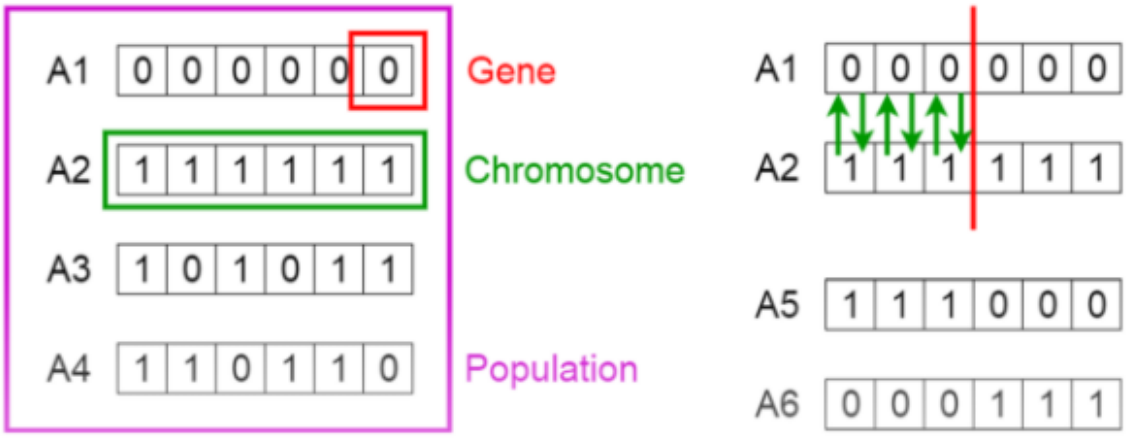

Örnek:

Adil bir jetonu 60 kez atıyoruz ve aşağıdaki ilk popülasyonu elde ediyoruz:

s_1 = 1111010101 $f(s_1) = 7$
s_2 = 0111000101 $f(s_2) = 5$
s_3 = 1110110101 $f(s_3) = 7$
s_4 = 0100010011 $f(s_4) = 4$
s_5 = 1110111101 $f(s_5) = 8$
s_6 = 0100110000 $f(s_6) = 3$

Seçimi yaptıktan sonra aşağıdaki popülasyonu elde ettiğimizi varsayalım

s_1` = 1111010101 (s_1)
s_2` = 1110110101 (s_3)
s_3` = 1110111101 (s_5)
s_4` = 0111000101 (s_2)
s_5` = 0100010011 (s_4)
s_6` = 1110111101 (s_5)

Sonra crossover için dizeleri eşleştiriyoruz. Her çift için crossover olasılığına (örneğin 0.6) göre crossover yapıp yapmamaya karar veririz. Sadece çiftler için (s1`, s2`) ve (s5`, s6`) crossover yapmaya karar verdiğimizi varsayalım. Her çift için rastgele bir geçiş noktası çıkarırız, örneğin birinci için 2 ve ikinci için 5.

Before crossover:
s_1` = 1111010101
s_2` = 1110110101

s_5` = 0100010011
s_6` = 1110111101

After crossover:
s_1`` = 1110110101
s_2`` = 1111010101

s_5`` = 0100011101
s_6`` = 1110110011

Son adım, rastgele mutasyon uygulamaktır: yeni popülasyona kopyalayacağımız her bit için küçük bir hata olasılığına izin veriyoruz (örneğin 0.1)
Mutasyonu uygulamadan önce:

s_1`` = 1110110101

s_2`` = 1111010101
s_3`` = 1110111101
s_4`` = 0111000101
s_5`` = 0100011101
s_6`` = 1110110011

After applying mutation:

s_1``` = 1110100101 $f(s_1```) = 6$
s_2``` = 1111110100 $f(s_2```) = 7$
s_3``` = 1110101111 $f(s_3```) = 8$
s_4``` = 0111000101 $f(s_4```) = 5$
s_5``` = 0100011101 $f(s_5```) = 5$
s_6``` = 1110110001 $f(s_6```) = 6$

Bir nesilde, toplam popülasyon uygunluğu 34'ten 37'ye değişti, böylece ~% 9 arttı. Bu noktada, bir durdurma kriteri karşılanana kadar aynı süreci yeniden yaşıyoruz.

Örnek:

A, B, C, D, E, F olmak üzere 6 durumum olsun. Her bir durumdan(genden) diğer bütün durumları (genlere) geçiş mümkün olsun. Tüm durumlar bir defa muhakak ziyaret edilecek. O halde 5!=120 tur mümkündür. Tur, herzaman A'dan başlayacak bütün durumlar dolaşılacak sonunda yeniden A'ya dönülecek. Durumlar arasında rasgele bir rota oluşturalım. ABDFECA.

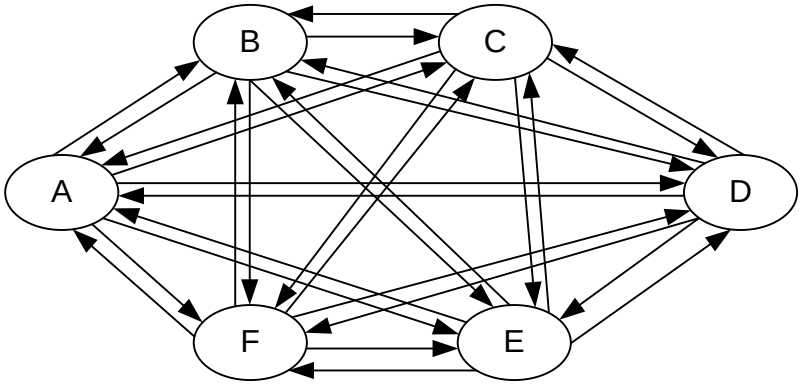

Bu problem Genetik Algoritma ile çözülürken,

- Uygunluk fonkisyonu seçilir. Uygunluk fonksiyonu mesafeler olacak, mesafeyi en aza indirilmesi gerekiyor.
- Popülasyon büyüklüğü, kaç çözümden oluşacak, mesela 10 seçilebilir.
- Ebeveyn seöimi, çözüm uzayındaki farklı durumları kullanarak yeni bir rota oluşturulacak. (Rulet tekerleği, sıralı yöntem)
- Çaprazlama, iki turdan yeni bir tur oluşturulurken çarpazlama iki noktalı mı yoksa tek noktalı mı?
- Mutasyon oranı, yeni tur oluşturulduktan sonra bir veya iki durumun (gen) rasgele değiştirilmesi
- Bitirme Şartı, iterasyon sayısının belirli bir sayıya ulaşması mı, uygunluk fonksiyonun belirli bir değerinin altında veya üstünde olması mı karar verilir.

Öncelikle durumlar (genler) arasında rasgele 2 çözüm turu oluşturalım. 6 durum arasında oluşturulacak tur sayısı=5!=120 farklı tur oluşturulabilir.

Tur-1: A B D F E C A
Tur-2: A C E D F B A

Bu iki tur kendi aralrında çaprazlamaya tabi tutulur. Çaprazlama oranı %50 olsun ve tek noktalı olarak yapılsın.

Tur-1: A B D F E C A
Tur-2: A C E D F B A

Yeni tur oluşturulurken birinci turdan ilk kısım ikinci turdan ise ikinci kısım alınır. İkinci kısımda olanlar birinci kısımda var ise alınmaz, yerine ikinci turundan başından itibaren olmayanlar alınr.
Tur-3: A B D ~~D~~ F ~~B~~ A = A B D F C E A olur.

Mutasyonu yaparken tek noktalı bir durumun (genin) değiştirilsin. Yeni oluşan Turda rasgele bir durum (gen) değiştirilsin. Sözgelimi B'yi değiştirelim ve E olsun. Yeni tur (kromozom),

Tur-4: A E D F C B A olur. E durumu iki adet olamayacağı için sağ tarafdaki E B ile değiştirilir. Böylece mutasyondan sonraki turda elde edilmiş olur.

Bu aşamadan sonra uygunluk fonksiyonu hesaplanır. Popülasyon içerisindeki diğer çözümlerden daha kısa mesafe ise diğer çözümlerden daha iyi çözüm olarak kabul edilir. Eğer değilse öldürülür.

Adımları sıralarsak,

- 10 tane başlangıç çözümünü oluşturulur.
- Herbir çözüm için uygunluk fonksiyonu değerini hesaplanır.
- Başlangıç çözümlerinden iki tane ebeveyn seçilir.
- Ebeveynler üzerinde çaprazlama yapılır.
- Mutasyona tabi tutulur.
- Yeni bireyin uygunluk fonksiyon değeri hesaplanır.
- Yeni birey öldürülecek mi yoksa popülasyona katılacak mı karar vermek için seleksiyon işlemi yapılır.
- Bitirme şartı sağlandı mı diye kontrol edilir, sağlandıysa en iyi çözüm al ve çık.

10.Python Yükleme

1- python.org
Download
All Releases
Python releases by version number
Python 3.9.13
Not: setup kurulumunda path seçme dahil iki kutucuğu da onaylayın.

2- https://www.anaconda.com/products/distribution
Dowload(uzun sürer)
Setup install edilirken, kutucukların seçimine dikkat edin, ortak path seçimi yapın
Anaconda Navigator kurulumu yapın

3- Editör
https://code.visualstudio.com/
Download for Windows

4- Çalıştırılırken
Anaconda Navigator, başlat menüsünden yazılırak enter yapılır
VS Code seçilir. Launch yapılır.

Pandas

Pandas, veri işlemesi ve analizi için Python programlama dilinde yazılmış olan bir yazılım kütüphanesidir. Bu kütüphane temel olarak zaman etiketli serileri ve sayısal tabloları işlemek için bir veri yapısı oluşturur ve bu şekilde çeşitli işlemler bu veri yapısı üzerinde gerçekleştirilebilir olur. Yazılım ücretsizdir ve bir çeşit lisansına sahiptir. Yazılım ismini bir ekonometri terimi olan veri panelinden almıştır. Bir veri paneli birçok zaman aralığı içinde farklı gözlemlerin işlenebildiği yapıyı tarif eder.

Kütüphane özellikleri

- İndeksli DataFrame (veri iskeleti) objeleri ile veri işlemesi yapabilmek.
- Hafızadaki veya farklı türlerde bulunan veriyi okuyabilmek ve yazabilmek için araçlar sağlamak.
- Veri sıralama ve bütünleşik kayıp veri senaryolarına karşı esnek imkanlar sunması.
- Veri setlerinin tekrar boyutlandırılması veya döndürülmesi.
- Etiket bazlı dilimleme, özel indeksleme ve büyük veri setlerini ayrıştırma özelliği.
- Veri iskeletine sütun ekleme veya var olan sütunu çıkarma.
- Veri gruplama özelliği ile ayırma-uygulama-birleştirme uygulamalarının yapılabilmesi.
- Veri setlerinin birleştirilmesi ve birbirine eklenmesi.

- Hiyerarşik eksenleri indeksleme özelliğiyle birlikte çok boyutlu veriden, daha az boyutlu veri elde edilebilmesi.
- Zaman serisi özelliği: Zaman aralığı oluşturma[4] ve sıklık çevrimleri yapma, hareketli aralık istatistik fonksiyonları, tarih öteleme ve geciktirme.
- Veri filtrelemesi yapabilmek.

Kütüphane performans konusunda yüksek derecede en iyilenmiştir. Bu yüzden kütüphanenin önemli parçaları CPython ve C üzerinde yazılmışlardır.

Dataframes (Veri İskeletleri):
Pandas temel olarak makine öğrenmesi uygulamalarında kullanılmaktadır. Bu uygulamalarda en öne çıkan özelliği de veri isketleridir. Pandas ayrıca birçok farklı formattan (csv, excel gibi) veri içe aktarması gerçekleştirebilir. Pandas çok farklı veri işleme yöntemlerini uygulayabilir; örneğin gruplama, ekleme, birleştirme, kaynaştırma, bir araya getirme. Ayrıca bu kütüphane veri temizleme için veri doldurma, değiştirme ve varsayma özelliklerine de sahiptir.

11.Kaynaklar

1. Machine Learning (ML) Algorithms For Beginners with Code Examples in Python. https://medium.com/towards-artificial-intelligence/machine-learning-algorithms-for-beginners-with-python-code-examples-ml-19c6afd60daa
2. https://www.w3schools.com/python/python_ml_getting_started.asp
3. https://www.tutorialspoint.com/machine_learning_with_python/knn_algorithm_finding_nearest_neighbors.htm
4. https://brilliant.org/wiki/feature-vector/
5. https://stanford.edu/~shervine/l/tr/teaching/cs-229/
6. https://stanford.edu/~shervine/l/tr/teaching/cs-221/
7. https://stanford.edu/~shervine/l/tr/teaching/cs-230/