

Yapay Zeka

Ders Notu

Dr. Cahit Karakuş

Balbiti
2023

İçindekiler

Giriş	3
1. Makineleri Ölümsüz Kılan: Bilgelige Yolculuk	8
2. Yapay Zeka	27
2.1. Turing Testi.....	29
2.2. Yapay Zeka Uygulamaları Geliştirme Adımları	33
2.3. Yapay zeka türleri.....	40
2.4. Yapay Zekada Modelleme	41
2.5. Yapay Zekanın Alanları	43
2.6. Yapay Zekada Etkin Akıl Faktörü	45
3. Makine Öğrenmesi.....	48
3.1. Makine Öğrenimi türleri.....	51
3.1.1. Denetimli Öğrenme.....	58
3.1.2. Denetimsiz Öğrenme	62
3.1.3. Pekiştirmeli (Takvyeli) Öğrenme	63
3.1.4. Diğer Öğrenme Yöntemleri	70
3.2. Makine Öğrenmesi Algoritmaları.....	74
3.2.1. Karar Ağaçları	81
3.2.2. Regresyon.....	82
3.2.3. Kümeleme (Clustering).....	88
3.3. Derin Öğrenme.....	95
3.3.1. Yapay Sinir Ağları.....	97
3.4.2. Bayes Ağları	102
3.4.3. Markov'un Karar süreci	103
3.4.4. Doğal Dil İşleme.....	106
3.4. ML modellerinde Performans Değerlendirmesi	112
4. Makine Öğrenmesi Uygulamaları.....	130
5. Sorular	156
6. Kaynakça	186

Giriş

Bilgisayar biliminin bir dalı olan yapay zekâ ile gerçek yaşam durumlarında, kendi başlarına karar veren makineler yapabilmek için veri yığnında bilgelik oluşturmak için akıllı algoritmalar ve matematiksel modeller geliştirilmektedir.

Yapay zekanın modern tarihi muhtemelen 1936'da Alan Turing ile başlar. Günümüz bilgisayarın atası olan Turing, bir makinenin insan gibi düşünüp düşünemeyeceğini belirlemek için Turing testi yapmıştır. 1950'de Alan Turing, yayınlamış olduğu bir makalede makinelerin düşünüp düşünemediğini gündeme getirmiştir. Bu nedenle yapay zekanın modern tarihi muhtemelen 1936'da Alan Turing ile başlar. Bazıları, modern bilgisayarın atası olan Turing makinesinin yapay zekanın ilk örneği olduğunu iddia etmektedir. Test basitti, bir bilgisayar sistemini bir makineyi bir insana makine değilde insan olduğuna inandırabilir mi? Ona göre bu, "akıllı davranış" için altın standarttı. Turing Testi, yalnızca dış davranışları test ettiği için birçok kişinin geçerliliğini sorgulamasına rağmen, bugün hala popüler bir testtir.



Alan Mathison Turing (23 Haziran 1912 – 7 Haziran 1954)

1950'de Alan Turing, yayınlamış olduğu bir makalede makinelerin düşünüp düşünemediğini gündeme getirmiş olsa da "Yapay Zekâ" terimi ilk defa 1956 yılında Massachusetts Teknoloji Enstitüsü'nden John McCarthy tarafından söylendi. John McCarthy, yapa zeka araştırmalarında bir öncüydü, bu alana isim verilmesine yardımcı oldu ve bilgisayarlara insanlar için sezgisel olan kavramları kavramayı öğretmek için onlarca yıl harcadı. Bu nedenle yapay zekânın asıl isim babası konu ile ilgili bir akademik konferans düzenleyen John McCarthy'dir. Ona göre, öğrenmeye dayalı zekâ kesin bir şekilde tanımlanabilir. Zekânın benzerinin matematiksel olarak modellenebilmesi için dış dünya ile etkileşim kurabilen yani öğrenen, konuşan, gören, gezen, manipülasyon yapan, modelleyen ve bilinçlenme sürecinde akıl yürüten ve uyum sağlama yeteneği olan bir makine yapılabilir mi? John McCarthy, makinelerin insan zekâsının özelliklerini simüle etme yollarını araştıran Dartmouth çalışmayı için; Marvin Minsky, Nathaniel Rochester ve Claude Shannon ile birlikte öğrenmenin herhangi bir yönünün veya insan zekâsının diğer herhangi bir özelliğinin bir makine tarafından simüle edilmek üzere tanımlanabileceği varsayımında bulundular. Aynı varsayım, Alan Turing'in

1950'deki "Computer Machinery and Intelligence" makalesinde, Boole mantığı, Bayes olasılığı ve istatistik gibi uygulamalı matematiğin gelişimi ile birlikte, Marvin Minsky'nin ilerleme olarak tanımladığı bilgisayarın resmi modelini önerdi.



John McCarthy (4 Eylül 1927 - 24 Ekim 2011)

Yapay zekâ konusunda araştırmacılarından biri olan Amerikalı bilgisayar bilimcisi, Nils J. Nilson, yapay zekâyı, çevresi hakkında bilgi sahibi olan makineleri akıllı hale getirmeye yönelik bir faaliyet olarak tanımladı. İlk yapay zeka sistemleri "genel zekaya" odaklanmıştı. 1966'da ELIZA sohbet robotu Turing Testini geçmeyi başardı. Bazı insanları kandırabilse de çoğu kandırılmadı. Sistemlerin kapsamı dardı ve her davranışın açıkça programlanması gerektiğinden sağlam değildi. 70'lerin başında araştırmacıların cesaretinin kırılmasıyla fonlar azaldı ve 1974-1980, "Yapay Zeka Kışı" olarak anılmaya başlandı. Japon Hükümeti 1980'de büyük bir AI projesini finanse etti, ancak bu tamamen başarısız oldu ve alan 1993'e kadar tekrar sessiz kaldı.

Yapay zeka alanı son birkaç on yılda bir rönesans gördü. Bilgisayar işlemcileri hızlandı, bellek hacmi arttı ve veri işleme algoritmaları gelişti. Yüksek düzeyde optimize edilmiş yapay zekanın alt çalışma alanı olan makine öğrenimi görevleri için grafik işlemci birimi (GPU) alanındaki gelişmeler çok büyük veri kümelerinin analizini ve yorumlanmasını mümkün kıldı. Makine öğreniminin yaygın olarak benimsenmesi, yapay zeka neredeyse bilgisayar sistemi olan her bir makinenin belkemiğini oluşturdu.

Günümüzde toplanan verilerden insandan bağımsız makinelerin davranış işlevleri oluşturulabilmekte ve *gerçek hayat problemleri matematiksel olarak modellenerek ve çözümlenerek karar verme becerisi geliştirilebilmektedir*. **Yapay zekânın insanlardan daha hızlı ölçme yapabilmesi, daha hızlı verileri toplaması ve daha hızlı karar verebilmesi inanılmaz bir avantaj gibi görünüyor.**

Yapay zeka, özellikle insan davranışını taklit edebilen akıllı makine yaratmayı hedefleyen bilgisayar bilimi teknolojisidir. Burada Akıllı makineler, insan gibi davranabilen, insan gibi

düşünebilen ve aynı zamanda insandan bağımsız karar verebilen makineler olarak tanımlanabilmektedir. "Yapay" ve "insan yapımı düşünme yeteneği" anlamına gelen "Zeka" olmak üzere iki kelimedenden oluşur. İnsan yapımı bilgisayar sistemleri içeren bir otonom makineden bahsedilmektedir. Yapay zeka ile bir görevi gerçekleştirmek için makineyi önceden programlamamız gerekmez; bunun yerine akıllı algoritmalar ile bir makine oluşturabilir ve o makine kendi kendine program yapacak; kendi programıyla çalışacak ve geri bildirimle performansını yükseltecektir. Makineden ne istiyoruz, bir işi mükemmel bir şekilde yapmasını istiyoruz. Öğrenerek performansının yükseltilmesi istenir. Bu işi yaparken, daha kaliteli yapacak bir metot öğrenirse ise, bize sorma yap diyoruz.

Bizden daha zeki makineler yaratabiliyor olursak, o zaman bu makine nesli, yeniden daha akıllı makineler yaratabilecek mi? Bu, insan zekasının hızlı ve geri döndürülemez bir şekilde makine zekası tarafından çok geride bırakıldığı üstel bir duruma yol açacak mı? Sonuç olarak, insanlar yetki ve kontrolü kaybedecek mi? En iyi durumda, makinelerin kölesi mi olacağız? En kötü durumda, ihtiyaç fazlası olarak yok mu edileceğiz. Makinelerin insanların yaşam alanlarını hapishaneye dönüştürebilir mi? Ya da belir bir sınıfın elinde güç olarak kullanılabilir mi?

Bilgisayar bilimi, bir disiplin olarak, algoritmaların teorik çalışmalarından hesaplama ve hesaplama sınırları çalışmalarına, donanım ve yazılım alanlarından bilgisayar sistemlerinin uygulanmasına ilişkin pratik ve teorik olmak üzere geniş bir alanı kapsar.


Bilgisayar biliminde önemli olduğunu düşünülen alanlar şöyle tanımlanmaktadır:

- Matematiksel hesaplama teorisi
- Algoritmalar ve veri yapıları
- Programlama metodolojisi ve dilleri
- Bilgisayar sistemleri (Bilgisayar Organizasyonu, Mikroişlemci, Assembly)
- Gömülü Sistemler: Bilgisayarı oluşturan temel bileşenlerin tümü tek bir chip içindedir.
- Uygulamaya yönelik yazılım; yapay zeka algoritmaları; program yazan algoritmalar.

Bilgisayar Biliminin Bileşenleri:

- Veri Toplama: Algılayıcılar, Detektörler, Ölçerler(Analog Sinyaller), ADC (Analog to Digital Converter)
- Veri Tipleri, Veri Bilimi, Veri tabanı yönetimi, Veri hazırlama
- Yapay Zeka, Makine öğrenmesi Algoritmaları
- Otomasyon / Otonom sistemleri: Bilgisayar sistemli kontrol edilen ve yönetilen makineler
- Algoritma ve Matematiksel modeller
- Quantum hesaplama
- Yazılım Dilleri: Python, Java Script, C++, Matlab, Assembly

Veri Bilimi, bir problem çözümünde sonuçlar çıkarmak amacıyla hesaplamalı matematik, istatistik, olasılık ve makine öğrenimi tekniklerini kullanarak ham verileri analiz etme bilimidir. Basit bir ifadeyle, veri bilimindeki bir ardışık düzenden oluşur. Çeşitli kaynaklardan elde edilen verilerin saklanması, veri tabanı yönetimi, hazırlanması ve analiz için kullanılır. Veri kaynakları: Algılayıcılar, ölçerler, anketler, geri bildirim, satın alma listeleri, oylar, sosyal medya uygulamaları, arama motorları, veri iz takip yöntemleri vb.



Data science pipeline in a simplified way

Ham veriler, bir ardışık düzen içinde farklı aşamalardan geçer:

- Verilerin Toplanması/Elde Edilmesi
- **Verileri temizlenmesi, düzenlenmesi, hazırlanması**
- Verilerin görselleştirilmesi
- Verilerin analiz edilmesi, hipotez
- Verileri modellenmesi (Eğitim ve test)
- Verileri yorumlama (Hesaplamalı matematik, Olasılık - İstatistik)
- İş süreçlerine uygulama
- İş süreçlerini iyileştirme

Kuantum yapay zeka

Kuantum bilgisayarlar, çok karmaşık sorunlara hızlı bir şekilde çözüm bulmak için eşzamanlılığın gücünü kullanır ve bilgi işlem gücünde devrim niteliğinde bir artış vaat eder. Sorun, çözüm olarak çalışan trilyonda bir kombinasyon bulmaksa, normal bir bilgisayar her olasılığı tek tek kontrol etmek zorunda kalırken, kuantum bilgisayar tek bir işlemle hepsini aynı anda kontrol edebilir. Bu, ortamları simüle etme, çözüm bulma ve bunları optimize etme gibi sorunlara özellikle uygun oldukları anlamına gelir. Bu tür sorunlar yapay zekanın merkezinde yer aldığından, kuantum hesaplamadaki gelişmeler bu alanda önemli ilerlemeler sağlayabilir.

Kuantum hesaplamada son zamanlarda umut verici bazı atılımlar olsa da, bunların ayrıntıları genellikle teknolojinin piyasaya sürülmesinden ne kadar uzakta olduğunu göstermeye hizmet ediyor. Örneğin, 2017'nin sonlarında IBM'in 50-qubit makinesi, 0,00009 saniye sabit kalarak endüstri rekorları kırdı. İki yıl sonra, Google, 54 kübitlik makineleri, kuantum olmayan bir süper bilgisayarın tamamlaması 10.000 yıl sürebilecek bir hesaplamayı 200

saniyede tamamladığında kuantum üstünlüğünü iddia etti. Bununla birlikte, makine etkileyici bir kavram kanıtı olsa da, henüz belirli pratik kullanımlarla hesaplamalar yapma yeteneğine sahip değildir. Genel amaçlı bir kuantum bilgisayar, mutlak sıfıra (- 273 °C) yakın çalışan 1 milyona yakın kubit gerektirir. Bu nedenle, güvenilir ve kullanışlı kuantum bilgisayarlar muhtemelen en azından önümüzdeki on yıl boyunca kullanılmayacak gibi görünüyor. Bazıları bunun her zaman kışkırtıcı bir şekilde ulaşamayacağı hareketli bir hedef olduğunu öne sürüyor. Burada, kuantum hesaplamaların spekülâtif bir gelişme olduğunu ve eğer başarılırsa, ya mevcut yöntemleri daha etkin bir şekilde uygulayarak ya da tamamen yeni yaklaşımların geliştirilmesini sağlayarak gelecekteki yapay zeka dalgalarının ortaya çıkmasını sağlayabilecek bir gelişme olduğunu not etmek yeterlidir.

1. Makineleri Ölümsüz Kılan: Bilgiğe Yolculuk

Heyecan verici ve aynı zamanda korkutucu, bir yapay zekâ gerçeği ile karşı karşıyayız. Günümüzde ve gelecekteki en zorlu, en tehlikeli, hatta en imkânsız problemleri çözme potansiyeline sahip olmak ve daha refah ve daha sağlıklı olmak için yapay zekâyı istiyoruz. Çok yakın gelecekte yapay zekâ tüm yaşam alanlarımızı etkileyecek, dokunmadık tek bir alan kalmayacaktır. Bilgi çağının ötesinde robotların ve veri yığınının insanlardan bağımsız kendi başlarına çok daha fazla şey yapmaları istenmektedir.

Matematiksel modeller ve algoritmalar kullanarak insandan bağımsız kendi kendine, otonom olarak programları tasarlayan, düşünen, yazan, uygulayan ve kazandıkları deneyimler ile bilinçlenen bilgisayar sistemleri, elde ettiği bilgi birikimini, bilgiğini nesilden nesile aktararak yetenek kazanmayı da öğreniyor olacaklar. Problem çözmeye odaklı ortak aklın geliştirilmesi hedeflenmektedir. Öte yandan yapay zekânın gelişmesi, insanlığın sonu anlamına mı geliyor? Eğer doğru ise bu teknoloji güvenli hale nasıl getirilecektir? Komplex teorilerinin hepsi birer senaryo ve dolayısıyla matematiksel model ya da algoritmadır.

Bilgisayar, bir dizi aritmetik ve mantıksal işlemleri gerçekleştirmek amacıyla programlanan genel amaçlı bir aygittir. Elektronik devrelerden oluşur. En temel elektronik devre elemanı transistördür. Elektron akışını kontrol eden yarı iletken devre elemanı olan transistörler, elektrik sinyalleri ile işlemler yapmaktadır. 0 ya da 1 değerine sahip olan bitler elektrik sinyalleri olarak transistörlerin üzerinde saklanmaktadır. Bilgisayar verileri alır, bit olarak belleklerinde saklar, belirli bir amaç doğrultusunda işler ve kullanışlı bir biçimde çıktı verisi sağlar. Bilgisayarın problem çözme işlevlerini yerine getirmesinde matematiksel tekniklerden oluşan algoritmalar devreye girer. Algoritma, bir problemin detaylandırılmış çözüm adımlarının talimatlandırılmasıdır. Bilgisayarın herhangi bir işlevi yapabilmesi için algoritma temelli bir programın yazılması gerekir. Algoritma, bilgisayara adım adım tam olarak neyi, nasıl yapacağı söyler.

Bilgisayar biliminin bir dalı olan yapay zekâ ile gerçek yaşam durumlarında kendi başlarına karar veren makineler yapabilmek için algoritmalar ve matematiksel modeller geliştirilmektedir. Özellikle algoritmaların akıllandırılmasında hesaplamalı matematiksel modeller yoğun olarak kullanılmaktadır. Böylece, veri yığınının özelliklerini temsil eden matematiksel ifadelerdeki sabit ve değişken katsayıların, insandan bağımsız kendi kendine öğrenmesini sağlayan algoritmalar ile insan zekâsını taklit eden sistemlerin tasarlanması ve robotik organların geliştirilmesi hedeflenmektedir. Yapay Zekâ, bilgisayar sistemlerinin insan gibi davranmasını amaçlar. Yapay zekâda alanında yazılmış bir program, değişimleri algılayabilir, akıl yürütebilir, harekete geçebilir, benimseyebilir ya da red edebilir.

En karmaşığından en basitine dek matematiksel denklemlere yanıtlar sunan özel formüllerden oluşan algoritmalar olmasaydı, bugünkü hayat bildiğimiz şekliyle asla

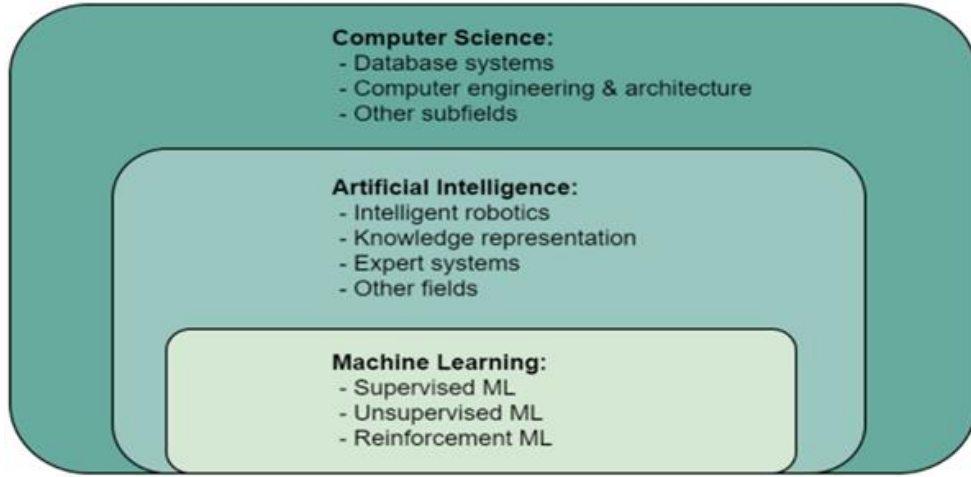
iyileştirilemezdi. Algoritmaların dünyayı yönettiğini söylemek biraz abartılı olsa da kullanımlarının giderek yaygınlaştığına katılmamak elde değildir. Bunun nedeni, bilgisayarların hayatımızın pek çok alanında giderek daha önemli roller oynamasıdır.

Matematiksel modeller ve talimatlardan oluşan algoritmaların bilgisayarlarda kullanımları, hesaplama teorileri uzmanı olan Alan Turing'e kadar uzanabilir. Ne yazık ki Turing, kitabını yayınladıktan iki yıl sonra kendi hayatına son verdi. Alan Turing yaşamının son yıllarında, matematiksel rüyasının programlanabilir bir elektronik bilgisayarda ortaya çıktığını gördü. Bugün cebinizdeki akıllı telefon, aklını başından alacak bilgi işlem teknolojisiyle doludur. Gerçek dünya problemlerinin bilimsel gerçekliğe dönüştürülmesi neredeyse bir ömür aldı, ancak düzgün bir açıklama ve bazı süslü denklemlerden daha fazlası olduğu ortaya çıktı.

Yapay zekâ dünyasında, algoritma tanımlarında, tam olarak doğru olmayan tek nokta, bir bilgisayara adım adım ne yapmasının istendiğinin söylenmesidir. Yakın gelecekte bilgisayarların çoğunda yalnızca **açıkça programlanmış yönergeleri takip eden algoritmalar yerine, kendi kendilerinin öğrenmesine izin verecek şekilde tasarlanan algoritmalar ve matematiksel modeller geliştirilecektir.** Bu durumda, yapay zekânın alt dalı olan makine öğrenimi algoritmalarının işi kolaylaştırıcaktır. **Makine öğrenmesi veri yığınının kümeleme, etiketleme, regresyon ve sınıflandırma yaparak öğrenip karar veren ve verdiği kararlardan performansını arttıran, deneyimlerini paylaşan algoritmalar oluşmaktadır. Makine öğreniminin kullanımları arasında veri madenciliği ve örüntü tanıma yer alır. Bugünün interneti, makine öğrenmesi algoritmaları tarafından yönetilmektedir.**

Günümüzde yapay zekâ alanındaki çalışmalar daha çok makine öğrenmesinin alt dalı olan ve **veri özelliklerinin sınırlandırılması ve filtreleme ile karar veren derin öğrenme uygulamalarını kapsamaktadır.** Makine öğreniminde makine kendini programlar paradigması, veri yığını ve büyük ölçekli hesaplama ile eğitilebilen yapay sinir ağlarının büyük ampirik başarısı sayesinde standart haline geldi. Bu işlem "Derin Öğrenme" olarak bilinir ve biyolojik nöronların davranışını bir şekilde taklit eden, nöronları düğümlerle ve sinaptik bağlantıları bu düğümler arasındaki bağlantılarla değiştiren birbirine bağlı sinir ağlarının katmanlarından oluşur. Bu sistem, bir dizi veriyi bir bütün olarak analiz etmek yerine, onu minimum parçalara böler ve bu parçalar arasındaki bağlantıları bulur, bir katmandan diğerine iletilen sinyaller oluşturulur ve istenen sonuca ulaşılan kadar karmaşıklığı artar.

Makine öğrenimi uygulama alanları neredeyse sonsuz olsa da, karşılaşılan ana soruluk öğrenmedir. Öğrenme genellikle **üç ana model sınıfa indirgenebilir: denetimli, denetimsiz ve pekiştirmeli öğrenme.** Etiket, ad, tür veya sayı gibi tahmin edilmek istenen bilgileri sınıflandıran ya da regresyon ile katsayıları belirlenen geçmiş veriler varsa; o zaman denetimli bir model kullanılabilir. Söz gelimi, sınıflandırma yapmada etiketler kullanılır ve değişkenler arasında ilişkiler bulunur.



Veriler bir etiket olmadan geliyorsa ve verilerdeki kalıplar ve öngörüler keşfedilmek isteniyorsa, yapısal veri bağlantıları keşfedilmesi için denetimsiz bir model kullanılabilir.

Karmaşık bir problem için en uygun çözüm bulunmak isteniyorsa, pekiştirmeli öğrenme ve optimizasyon yöntemleri kullanılabilir. Optimize etmek için bir hedefin belirlenmesi ve algoritmaların verileri keşfetmesine ve sonucun optimize edilmesi için en iyileme önermelerine izin verilmesi gerekir. Günümüzde, metin, resim, video, müzik, sosyal medya profili, konuşma, coğrafi konum ve çok daha fazlası gibi hemen hemen her tür veriden bilgiler işlenebilir, anlaşılabilir ve anlam ya da yorum çıkarılabilir!

Günümüz yapay zekânının en büyük gücü, hayatımıza biçim ve doku veren ilişkilerin yapısını deşifre etmesidir. Doğal dil işleme için benzer bir süreç uygulanır; Bu işlem, önceki tanımlara ihtiyaç duymadan bir metnin anlamını çıkarmak için kelimeler arasındaki ilişkileri belirler. Yapay zekânın mevcut gelişiminde yer alan diğer çalışma alanları, deneyime dayalı karar vermede kalıpların tanınması için makine öğreniminin odağını değiştiren bir işlem olan “Güçlendirilmiş Öğrenmedir.” İnsanlar ve makineler arasındaki kitle kaynak kullanımı ve işbirliği de yapay zekânın bir parçası olarak kabul edilir ve insanların sinir ağlarının eğitiminde kullanılacak görüntüleri veya metinleri etiketlediği bir hizmet olan Amazon'un Mechanical Turk gibi hizmetleri doğurmuştur.

Akıllı Algoritmalar

Atom altı parçacıklarından devasa gezegenlere kadar kainatı oluşturan tüm bileşenler birbirleri ile iletişim ve etkileşim halindedir. Özellikle etkileşimlerdeki davranış değişiklikleri sinyaller üretir ve bu sinyaller bilgi taşırlar ve matematiksel olarak değişkenlerin fonksiyonu biçiminde gösterilir. **Bilgiyi güçlü kılan, sinyaller ile bütünleşik taşınabilmesi ve saklanabilir olmasıdır.** Sinyallere gizlenmiş bilgileri keşfederek bilinçleniyoruz. Sinyallerin taşıdıkları mesajlar algılanabilmekte, ölçülebilmekte ve toplanarak veri yığınları elde edilmektedir. **Bilgisayar belleklerinde toplanan veri yığını içinde arayanın aradığı bilgiyi bulması kadar aranan bilginin de arandığını fark etmesi gerekmektedir.**

Aşağıda anlatılan örnek senaryoda veri yığını, dünyada yaşamın başladığı zamanlarda, deniz içindeki mikroorganizmalara benzetilmiştir. Mikroorganizmalar beslenmeleri gerektiğinden av ya da avcı rollerine bürünürler. Birbirlerini avlamaya başlarlar. Problem av ya da avcı olmak...

Algılama başladığında, avın ya da avcının konumu, büyüklüğü, hızı, yönü, gibi fiziksel değişimler belirlenir. Öncelikle, **mikroorganizmalar olarak adlandırılan verilerden bilgiye (organlara), bilgiden de bilgeliğe (organlardan düşünen vücuda) yolculuğu sağlayan algoritmaların bilinçlenerek akıllanma sürecinde, mikroorganizmaların av olmadan avlarını avlayabilmek için birbirlerini uzaktan algılama yetenekleri geliştirmelidir. Çevresindeki fiziksel değişimlerin algılanması gerekmektedir. Ardından değişimin ve dönüşümün fark edilmesi gerekmektedir.** Birbirlerine av olmamak için birbirlerini kollayan, saldırı davranışları algılayarak mesafeli duran organizmaları ekip olmaya iten faktörler nelerdir? Böylece sorgulama, kıyaslama ve sınıflandırma yapabilmeye yetenekleri geliştireceklerdir. İlk aşamada belirsizliklerin sayısı oldukça fazla olacaktır. **Belirsizliklerin minimize edilmesi için bilgi paylaşım kritik bir öneme sahiptir.** Belirsizliklerin analiz edilmesi aşamasında değişimler sınıflandırılırken doğruluğu arttırmada eksik, hatalı ve anomali verilerin fark edilmesi için **araştırma yapmaya yönelik ortak aklın geliştirilmesi** gerekmektedir. O anlar, av olmamak ya da avı avlamak amacıyla ekip olmak gerekliliğinin **fark edildiği** andır.

Ekip olma fark edildiği andan itibaren aralarında görev paylaşımı ve planlama yapabilmeyi öğrenmeye başladıklarında, **problem çözmeye odaklı ortak aklın geliştirilmelidir.** Organlar oluşturulmalıdır. Görev paylaşımında üstlenilen görevde başarılı olmak ve en iyisini yapmada uzmanlaşarak farklı organlar oluşturulmaya başlanıldığı anda veri yığınları bilgiye dönüşmeye başlar. **Böylece problem çözmeye yönelik iş adımlarını paylaşan farklı organlar oluşacaktır. Buna ekip olma ya da bir olma denmektedir.** Organların birlikte hareket etmesinden bütünlük yani bilge vücut meydana gelecektir. Bilge vücudun meydana gelmesinde organların birbirleri ile iletişim kurmaları, görev paylaşımları, izleme, yönetme fonksiyonlarını yerine getirmeleri için **lider beyine ihtiyaç olduğu** fark edilecektir.

Her zaman hata yapma ile yapmama aynı ortamda var olacağından farkındalık yaratanların öne çıkması kaçınılmazdır. **Vücut hiç hata yapmama üzere organize olursa sürekli doğru kararlar vermeye odaklanacağından yaşamını sürdürmesi mümkün olmayacaktır.** O halde yaşamın devamında birileri hata yapacak ki, ders alınsın. Başarıya giden yolda ekip olma ve ekiplerin birbirlerini çok iyi hissetmeleri ve algılamaların da **hedefe yönelik katılımcı ortak akıl** ile mümkün olduğu fark edilmelidir. Böylece hatalardan dersler çıkarılarak deneyim sahibi olunacak ve performans yükseltilecektir.

Fırsatları yakalamada, farklı olmada ya da değişimi bulmada başarılı olmanın temel kuralı takım olarak mükemmelliği gerçekleştirmeyi öğrenmektir. Bu da kalite gücünü fark eden akli geliştirecektir. Böylece fırsatların yakalanmasında farklı olabilmek için değişimler gerektiği fark edilecektir. Tüm oluşacak olumsuzluklara rağmen verilerden bilgiye, bilgiden de bilgeliğe dönüşüm veri yığnında var olabilmelidir. Geliştirilecek matematiksel modeller ve algoritmalar bu fikre odaklanmalıdır. Böylece değişimler algılanacak ve değişen ortamdaki yaşama uyum sağlanabilecektir. Tüm bunlar **bilinçlenme süreci** ile mümkün olabilmektedir.

Yukarıda anlatılan senaryoda kırılma noktası, sonsuz veri denizinde avcı ya da av olan organizmaların nerede, nasıl, neden biraraya geldiğidir. Örnek olarak Facebook veri deposundaki bir kişinin bir ürünü satın almadaki önceliği nasıl belirlenecektir? Kişiyi ait çok sayıda fotoğraf, düşünce ve beğeni paylaşımları ile arkadaşlar arasındaki ilişki düzeyi ve birbirlerini etkileme faktörleri bir araya gelerek satın alma önceliğini belirleyecek ekip ortaya çıkarılır. Ardından da organlara ve organlardan da vücuda yani karar verecek bilgeliğe dönüşüm başlar. **Sonuçlar üreten matematiksel adımlar dizisi olan algoritma**, içgörülerini ve kalıpları keşfetmek için tahminler, öneriler ve hatta otomatik akıl yürütme ve karar verme amacıyla verileri keşfetmede kullanılır. **Akıllı algoritmalar, büyük veri, yapay zekâ, makine öğrenimi ve robotik süreç otomasyonu gibi gelişmiş tekniklerde kullanılmaktadır.**

Akıllı algoritma, verilerden bilgiye, bilgiden bilgeliğe ve bilgeliğten eyleme ya da karar vermeye dönüşüm adımlarından oluşur. Bir bilgisayar algoritması için, bir köpeği tanımaya götüren tüm kural ve kriterleri resimde kodlamak oldukça kolaydır. Ayrıca, birden fazla uzman algoritmalar farklı kriterler ve kurallarla ortaya çıkaracaktır. Bu durumda ortak bir model bulmak zor olmayacaktır. Akıllı algoritmalar için bu görevlerin çözülmesi giderek daha kolay hale gelmektedir.

Akıllı algoritmalarla gerçek insan uzmanlığını otomatikleştirmeye çalışmak yerine, uzman algoritmaların çalışma performansları iyileştirilir. Öncelikle bulguların anlamlı olup olmadığının doğrulanması gerekmektedir. Yapay zekâ algoritmaları insanları değiştirmiyor, onlara yardımcı oluyor. Daha hızlı karar verme amacıyla yapay zekâ, diğer programlanmış robotik ve otomasyon teknolojilerle birlikte kullanılarak değerli içgörüler geliştirebilir ve insanlar adına iş kararlarını güvenle çok daha hızlı verebilir. Akıllı algoritma uygulamalarında

yazılım yok... **Yazılmış yazılımlardan sistem oluşturmak, yani karar veren fonksiyonu bulmak zorunluluğu vardır.**

Akıllı algoritmalar sayesinde insan yanlılığı ve hatalar azaltılabilir, görev yürütmede çok daha yüksek doğruluk ve hassasiyet sağlanabilir.

Yapay zekâ algoritmaları,

- İnsanların yanında yol arkadaşı ya da asistan,
- Tekrarlayan işleri azaltmaya yardımcı olur,
- İnsanların yapmaktan hoşlanmadığı görevler
- Belgelerdeki hataları manuel olarak kontrol etmek,
- Maden ocaklarında sürü drone robotlar için harikadır.

Yapay zekâ ile günlük rutin görevler otomatikleştirilebilir ve insanların daha üretken görevlere zaman ayırmaları için özgürleştirilebilir. Yapay zekâ algoritmalarının kullanıldığı uygulama alanları çok büyüktür ve ayrıca birden fazla algoritma tek bir hedefe ulaşmak için hizmet edebilir! Bazı algoritmalar diğerlerinden daha verimli olabilir.

Verilerin yeterli niceliği ve kalitesi olmadan, akıllı bir algoritma doğal kalıpları öğrenemez. Algoritmanın problemi genelleştirip, çözen ilişkileri öğrenmesi ve hesaplaması için verilere ihtiyacı vardır. Kullanılan veriler bir sorunu temsil ediyorsa yapay zekâ algoritmaları kalıpları belirleyebilir, araştırabilir, öğrenebilir ve kararlar alabilir. Daha geniş alanları daha hızlı keşfetme olanaklarının kilidini açabilir.

Matematiksel denklemler olarak algoritmalar yaşamlarımızda etkin rol oynayan bilgisayar sistemlerini içeren makinelere entegre edilmektedir. Aynı zamanda geleceği tahmin etmek için modellerin algoritmalarda nasıl kullanıldığı da önemlidir. **Aslında veriler ve algoritmalar arasında garip bir evlilik vardır.** Teknoloji geliştikçe hatalar olacaktır, karar verirken hatalar olacak ancak bunların sadece bir yöntem olduğunu hatırlamak önemlidir. **Önemli olan algoritmanın hatalar olduğunu fark etmesi ve gerekli düzeltmeleri yapabilmesidir.** Yöntemler hatalarından dolayı suçlanamaz. Belirsizlikler ve hataların nedenleri akıllı algoritmalar tarafından belirlenip yeniden modellendikçe ya da senaryolar güncelleştirildikçe yeni dünyalara yelken açılacaktır. Bu yelken açma insanoğlunun yeryüzünde var olduğundan beri vardır, karşılaştığı problemleri çözme adına keşifler yapmaya ve buluşlar bulmaya gerekli kılan **bilinçlenme sürecidir.**

Temel matematiksel işlemlerden elde edilen yapay zekâ algoritmaları üç ana kategoriye ayrılır:

- **Sınıflandırma algoritmaları,** veriyi belirli bir şekilde sınıflandırmak istediğinizde kullanılan algoritma türüdür. Örneğin elmalar, armutlar, ayvalar, portakallar, ... dan oluşan bir meyve sandığında sınıflandırma yapalım. Kural: Her bir meyvenin ne olduğunu biliyoruz.

- **Regresyon algoritmaları**, sayısal, nümerik veriye dayalı olarak gelecekteki sonuçları tahmin etmek için matematiksel fonksiyonların ya da denklemlerin katsayılarının bulunmasıdır.
- **Kümeleme algoritmaları**, bütün bir veri setini alır ve belirli noktalar arasındaki benzerlikleri veya farklılıkları bulur. Örneğin bir sandık dolusu çeşitli meyveler var. Meyveler ile ilgili hiçbir tanım yapılmış ise.. Bilgisayar temelde özelliklerden meyveleri sınıflandıracaktır. Karşılaştırma yapılarak farklılıkların belirlenmesi söz konusudur.

Örnek olarak, bir muhasebe belgesinde potansiyel olarak hileli işlemlerin bulunması veya aynı yaşta bir grup insanların kimlerden oluştuğunun belirlenmesi istenebilir. Daha büyük hesaplama kümelerini tamamlamak için birden fazla algoritma senkronize olarak da kullanılabilir.

Yapay Zekâ Uygulama Alanları

Algoritmalar kendi kendilerine otonom karar vermeyi nasıl öğreneceklerini eğitmek, süreçleri iyileştirmek ve görevleri daha verimli **bir şekilde yürütmek için performans arttırmaya yönelik veri toplamaya ve katsayıları ya da modelleri güncellemeye devam etmelidir**. Bunun inanılmaz derecede yaygın olduğu bir örneğe mi ihtiyacınız var? Zaten sahip olduğunuz Alexa, Google Home veya Apple Home uygulamalarını düşünün. Onlarla ne kadar çok etkileşime girerseniz, bireysel tercihlerinizin fark edilmesi o kadar büyük olur. Örneğin, en sevdiğiniz şarkının çalınmasını istediğinizde, yapay zekâ algoritmaları, şarkılar arasında ilginizi belirler, olanları arar bulur ve çalar. Bir ara aklınıza geldiğinde aradığınız, sonrasında unuttuğunuz bir şarkının aylar hatta yıllar sonra aniden ekranınıza gelmesi, geçmiş çevrenizin araştırılarak ortak geliştirdiğiniz bir organizasyonun ekranınızda belirlenmesi sizlerde tuhaf duygular oluşturulabilmektedir. Aslında farkında olarak ya da olmayarak internette sosyal platformlar için birer deneksiniz... Siz bu ortamda sosyalleşmeye başladığınızda bir akıllı algoritma kimliğinizi belirler, ardından sizi çok iyi tanıyan diğer algoritmalar sizinle sosyalleşmek için devreye girer. Sizin alışkanlıklarınızı, düşüncelerinizi belirlemeye başlar...

Matematiksel denklemlerin modellenmesi ile akıllı algoritmalar, Facebook akışında neleri incelediğiniz ve paylaştığınız, nelere yorum yaptığınız, Netflix'in önerdiği filmlerden hangilerini tercih ettiğiniz ve internette hangi reklamlara daha dikkatli baktığınızı belirler. Sadece belirlemek ile kalmaz, öngörülerde bulunur, sizi test eder, sizi kimliklendirir, sizi takip eder.

Şu anda mevcut olan veri seli sayesinde şaşırtıcı korelasyonları (bağlantılar, ilişkiler) ve rassal değişkenler arasındaki ilişkinin yönünü ve gücünü bulmak hiç bu kadar kolay olmamıştır. Havanın karlı, soğuk veya çok nemli olduğu durumlarında insanlar telefon ile daha sık görüşüyor; hava güneşli veya daha az nemli olduğunda e-postaya daha fazla yanıt veriyorlar. Bu bilgiler biliniyorsa bölgeleri hava tahmini yapmam kolay olacaktır. Bir ön analiz, bazı

insanlar bulutlu olduğunda fazla satın alsa da, hava güneşli olduğunda çok daha fazla satın aldıklarını gösteriyor. Kredi veren kuruluşlarda, kredi başvurularının tamamını büyük harflerle dolduran kişilerin, tümünü küçük harflerle dolduran kişilere göre daha sık, harfleri doğru kullanan kişilere göre ise çok daha sık temerrüde düştüğü tespit edilmiştir. Daha uzun boylu insanların kredileri geri ödemede daha iyi olduğuna dair bir bulgunun da göz ardı edilmemesi gerekir.

Kişi tiplerine göre kredi riskini belirlemek mümkün müdür? Hızlı ve yeni veri işleme yazılımları, kamuya açık ve özel veri seliyle birleştiğinde, şirketlerin bu ve görünüşte çok zorlanmış diğer teorileri ve varsayımlarını test etmelerine ve daha önce çok az kişinin sormayı düşünceği sorular sormalarına olanak tanıyor.

İnsan zekâsı ile yapay zekâ birleştiğinde akıllı içgörülerin ortaya çıkarılması ve işletmelere giderek daha rekabetçi bir pazarda avantaj sağlayabilmesi için tahminler yapılmaya çalışılmaktadır.

Yapay zekâ daha önce sahip olmadığımız yepyeni beceriler kazandırabilir. Bu alanda geliştirilen uygulamaları kullanan bir doktor, laboratuvarında daha önce hiç tasarlanmamış akıllı ilaçlar geliştirebilir. Buradaki akıllı kavramı, ilacın etkin olacağı lokasyona gidip, oradaki duruma göre dozu ayarlayıp, tedaviye başlaması ve sonucun raporlanmasıdır. Böylece yaşam süresi daha sağlıklı bir şekilde uzayabilir.

Yapay zekânın yarınımızı, yakın ve uzak geleceğimizi nasıl etkileyeceği ise tamamen bize bağlı, eğer yapay zekâyı doğru kullanırsak, yaşam biçimlerimiz inanılmaz ölçüde farklı olacaktır; **insanlık olarak bu dünyada var olduğumuz andan itibaren bilinçlenerek geldiğimiz noktada içimizdeki en değerli cevherler ortaya çıkmaya başlayacaktır.** Aslında yapay zekâ, farkında olmadan hayatımıza çoktan girmiştir.

Makine ve derin öğrenme algoritmaları yardımıyla makineler bizim gibi öğrenmeye ve mantıklı düşünmeye başladılar. Duygusal düşünbilme adımları ise araştırma ve deneme aşamasındadır. Makineleri yöneten bilgisayar algoritmaları, dünyayı insanlara benzer şekilde öğrenerek algıladıklarında, canlandırdıklarında ve anladıklarında zeki oldukları kabul edilecektir.

Söz gelimi, bir konuşma dilini anlamak yapay zekâ uygulamalarının en büyük zorluklarından birini oluşturur. Çünkü diller detaylı ve karmaşıktır, sabit kuralları olan bilgisayar yazılımları için birçok zorluk içerir. Dil aynı zamanda kolaylıkla yanlış da yorumlanabilir. Bir bilgisayarın söylenen dilde verilmek istenen mesajları anlaması gerçekten de çok zordur. Bazı kelimelerin farklı cümle içindeki farklı anlamlarının bilinmesi gerekir. Konuşulan cümlelerin birbirleri ile ilişkileri nedir? Bir cümle içindeki bir kelimenin başka bir kelime ile bağlantısı nedir ve neden bu kelime kullanıldı gibi soruların yanıtlarının bulunması gerekir. Öte yandan

insanlardan farklı olarak bir bilgisayar saniyeler içinde milyonlarca makale okuyabilir. Herbir makaleden anlamsal kavramlar çıkarabilir.

Bilgisayarların insanlar ile tartışabilmesi için soruları ve yorumları anlaması çok zordur. İnsanlar sorulan soruyu ya da yapılan yorumu çok kolay anlar, ancak bir insanın hafıza kapasitesi tüm yanıtları çok hızlı bir biçimde verecek kadar gelişmiş değildir. İnsan olarak konuştuğumuz dili anlamaya o kadar alışkınız ki, ne kadar zor olduğunun farkında bile değiliz. İnsanlar için tartışma kurmak ve bazı şeyleri birbirine bağlamak oldukça kolaydır. Bir bilgisayar sistemine konuşmanın bazı kısımlarını anlaması ve kavramları tespit etmesi öğretilir. Kavramlar ile cümleler arasındaki benzerliklerin görülmesi sağlanabilir. Bunun için algoritmaların kavramları zekice birbirine bağlamayı öğrenmesi gerekir.

Bilgisayara bir tartışma başlığı verildiğinde, algoritmalarından oluşan yazılım öncelikle başlığın anlamını kavramaya çalışır. Bir savunma oluştururken, kullanabileceği potansiyel argümanları tespit edebilmek için milyonlarca makale tarar. Tartışmanın altında yatan temaları anlamak ve argümanını etkili ve ikna edici bir şekilde düzenlemek için eşsiz dil işleme, makine öğrenme ve muhakeme teknikleri kullanır.

Bilgisayar cümlelerini kurar, kendi düşüncesini aktarır. Ardından da, rakibini belirli bir süre boyunca dinlemesi gerekir. Eğer rakip ahlaki nedenler gibi karmaşık argümanları ileri sürerse, bilgisayar sisteminin de bir şekilde tüm bunları anlaması ve düzgün bir yanıt vermesi gerekir. Dinlemenin ardından çürütme argümanını oluşturur ve oluşturduğu kendi argümanını ileri sürer. Karşısındaki kişi bilgisayarın ileri sürdüğü argümanların olumsuzluklarından bahseder ve ardından olumsuzlukları önlemek amacıyla, atılacak adımları sıralar ise bilgisayar da olumsuzlukların çözülmesi için atılacak adımlara karşı argümanlar üretmeye başlar. Ya da farklı yaklaşımlar ileri sürer. Farklı çözüm metodolojileri ileri sürmeye başlar. Kabullenmesi gerekiyorsa, atılacak adımların geniş perspektifini çizer. Böylece yapay zekâ uygulaması ile, konuşma dilinin algılanması ve tartışmanın yapılmasına yönelik algoritmaların geliştirilmesi sağlanmış olmaktadır. Buradan da görüleceği üzere geliştirilen algoritmalar, beyin fırtınası temelli ortak akıl ile geliştirilen senaryolardan oluşmaktadır.

Bilgisayar sistemleri her tartışmadan sonra kendini biraz daha geliştirir. İnsanlardan farklı ve haklı olduğunu iddia edebilmek için, vurgulanması gereken noktaları tespit etmeye yönelik olarak daha fazla öğrenerek performansını artırır. **Geliştirilen bilgisayar algoritmalarının zamanla literatür arama işlevinden araştırmaya geçmesi gerekmektedir.** Çünkü bir şeyi aradığınızda arama başlığınıza uygun olan dökümanlara ulaşırsınız. **Konuyu araştırmaya başladığınızda ise, konunun pozitif ve negatif yönlerini elde edersiniz.** İkna edici bir argüman ile yapılandırılan yapay zekâ uygulamaları, toplum olarak karar verme şeklimizi değiştirebilir.

Veri bilimcilerin bulgularının anlamlı olup olmadığını doğrulamaları gerekiyor. Makine öğrenimi insanların yerini almıyor. **Makine öğrenimi algoritmaları ile akıl yürütmeye yönelik**

hesaplamaların birleştirilmesi gerekmektedir. Makine öğrenimi algoritmalarına akıl yürütme eklenerek korelasyonlar ve içgörüler çok daha faydalı hale gelebilir. İnsanlar iletişim kurduğunda konuşulmuş varsayımlardan oluşan geniş bir geçmişe mi güveniyoruz. Teknoloji bugün ne kadar gelişmiş olursa olsun, toplumdaki günlük yaşamın büyük bir parçası haline geldiğinden temel eksikliği, varsayımların paylaşılmamasıdır.

Doğal Dil İşleme, sağduyulu akıl yürütme ile varsayımları toplamanın ve bilgisayarlara öğretmenin yolları bulunarak, bilgisayarların insanları daha doğal bir şekilde anlamasına ve onlarla etkileşime girmesine yardımcı olmayı amaçlayan bir yapay zekâ alanıdır. Bu makine öğrenimi alanında geliştirilen algoritmalar, metni anlamadan işlemeye ve bir fotoğrafta ne olduğunu anlamaya kadar farklı uygulamalara sessizce sızmaya başlıyor. Sağdulu olmadan, giderek artan dijital ve gezgin bir dünyada uyarlanabilir ve denetimsiz Doğal Dil İşleme sistemleri oluşturmak zor olacaktır. Doğal Dil İşleme sağduyulu akıl yürütmenin üstün olduğu yerdir ve teknoloji ticari ürünlerde yolunu bulmaya başlamıştır. Daha gidilecek çok yol olmasına rağmen, sağduyulu akıl yürütme önümüzdeki yıllarda hızla gelişmeye devam edecektir.

Yapay zekânın araç direksiyonunun başına geçmesi bir zamanlar bilim kurgu dünyasına aitti, artık her yerde, her an karşımıza çıkacakmış gibi görünüyor. Kargonuzu taşıyan drone ve Ford'un pizza robotları siparişlerinizi kapınıza getirmeye başladı bile. Google'ın test araçları, Tesla'nın otomatik arabaları hakkında haberler sık sık duyulmaya başladı.

Araba kullanmak insan için bile çok zordur. Her şeyin yolunda gittiği sıradan trafikte sorun yoktur. Kalabalık, karanlık ve yağışlı havalarda insanların bile zorlandığı koşullar, yapay zekânın kapasitesini aşmaktadır. Her yıl trafik kazalarında onbinlerce insan hayatını kaybediyor. Günümüzde sürücüsüz arabalar çoğunlukla test pistlerinde ve belirli alanlarda kullanılmaktadır. Son birkaç yıldır, Wayma, Tesla, Volvo ve Cruise gibi şirketler araçlarını gerçek dünya yollarına çıkarmaya başladılar. Arabaların performanslarını arttırmak için, milyonlarca kilometre yol kat edilmesine rağmen yaşanan ölümcül kazalar teknolojinin güvenilirliği konusunda endişeleri göz önüne sermektedir. Bu konuda oluşan problemler zamanla çözülecektir. Güvenlik bu teknolojinin en önemli yönünü oluşturmaktadır. **Arabaların insanların gördüğü şeyleri görmesi, yaptığı şeyleri yapması gerekmektedir.** Sürücüsüz arabada kullanılan yapay zekâ teknolojisi, "ne görüyorum"sorusunu sürekli yanıtlamalıdır. Buna algı denir. Araba elde ettiği görüntülere dayanarak objelerin ne olduğunu ve yoldaki şeritleri tespit eder.

Yapay zekânın çözmesi gereken bir diğer problem, objelerin nasıl hareket ettiğini tahmin etmesidir. IoT ile nesnelerin davranışlarının sınıflandırılması. Buna öngörü adı verilir. "Nereye gidiyorum", buna planlama denir. Yol kenarında futbol oynayan çocukları gördüğünde, insanlar bu çocukların yola fırlayabileceklerini bilir, hızını keser. Oysa yapay zekâ yalnızca yuvarlak bir objeye vuran ya da peşinden koşan insanlar görür. Yapay zekânın

en büyük ilişkilerinden biri de derin öğrenmedir. Yani top ile birlikte çocuğun yola fırlayabileceğini bilmelidir. Bunun için çok sayıda senaryoyu hesaba katması ve tepki vermesi gerekir. **Asıl önemli olan ise, öğrenilen deneyimlerin paylaşılmasıdır.** Yapay zekânın deneyime bağlı öğrenme becerisi, öğrendikleri deneyimleri diğerleriyle paylaşması arttıkça, sürücüsüz arabalar inanılmaz yetenekler kazanacak ve çok yakın zamanda sokakları dolduracaktır.

Sıkışık trafikte insandan bağımsız kendi kendine kararlar alabilen, çevresi hakkında öngörüle bulunan, şoförün sağlık durumunu ya da dalgınlığını fark eden yardımcı asistanız olarak görev yapacaktır. Almanya’da mutfak cihazlarında ve arabalarda yarı otonom yapay zekâ uygulamaları kullanılmaya başlanmıştır.

İnsanlığın gerçekleştirdiği tüm gelişmeler geçmişteki hatalarından ders çıkarabilmesi, anlayışını değiştirebilmesi ve yeni çözümler keşfedebilmesinin sonucudur. Bilgisayar bilimcileri de onlarca yıldır, makinelerin de insanlar gibi öğrenmesini sağlamaya çalışıyorlar. Bilgisayarlara oyun oynamayı öğretmek yapay zekâyı geliştirmenin en etkili test yöntemlerinden biri olmaya devam etmektedir. İşlemci gücündeki dramatik sıçrama, verilerdeki muazzam artış ve algoritmalarındaki gelişmelerin hepsi, günümüzdeki yapay zekâ devrimine katkıda bulunmaktadır. Tabii ki bütün bunlar yıllar içinde adım adım geliştirildi ve geliştirilmeye de devam edecektir.

Yapay zekâ her gün çok büyük miktarda üretilen verilerden yeni birşeyler öğreniyor. İnternette gezinirken veri tabanına katkıda bulunduğumuz için aslında hepimiz bu deneyin bir parçası oluyoruz. Veriler denizinde yüzüyoruz. Günümüzde yapay zekâ sistemleri sürekli olarak bizleri takip ediyor ve hizmetlerini bizim seçimimize göre düzenliyorlar. Facebook haber kaynağının içeriğini seçimlerinize göre belirlemektedir. Aynı zamanda kendi kendine öğrenen yapay zekâ sistemleri uzay roketlerine rehberlik ediyor.

İnsanlar ile çalışan yapay zekâ robotlarının çoğu programlama ile değil görerek öğreniyorlar. Öncelikle onlara yapacakları iş öğretiliyor. **Bir robota yapması gereken görevler gösterilerek eğitildiğinde, iş süreçlerini optimize ederek, bütün süreci kendi başına çözebilmektedir.** Robota görevini göster, bırak çalışsın.



Kapıyı açıp içeri girebilen, koşabilen, zıplayan, ters takla atabilen, insanlara çok benzeyen, insan gibi konuşan, insan gibi davranan en gelişmiş robotlar yapılsa bile, bilinç olmadığı sürece o asla bir birey olamaz.

Yaşlılar ya da özürllüer ile ilgilenen, onlara yardımcı olmasını bilen ve onlarla ilişki kuran bir robotun bilinçli olması gerekmektedir. Böylece kurduđu cümlelerde samimi olması sağlanmalıdır. Ahlak, anlam ve amaç gibi değer verdiđimiz tüm şeylerin temelini bilinç oluşturur. Bilinçlenme her zaman deđişim başlatır. Algılama, anlama ve canlandırma yeteneklerinin zihine kazandırılması olan bilinçlenme süreci, merak etme, dertlenme, sorgulama ve kıyaslama ile başlar. Deđişimi fark edebilmek ve uyanmak gerekir. Uyanmak bilinçlenme ile mümkündür. Eđer gerçek bilinçli deneyimler ile subjektif bilgi işleme süreçleri örtüşürülebilirse, gerçek empati becerisine sahip olan ve bize değer verebilen makineler geliştirilebilir.

Çocuklar için çođu deneyim yenidir. 0 ile 8 yaş döneminde çok şey öğrenilir. Geliri düşük ailelerden gelen öğrenciler, geliri yüksek seviyeden gelen öğrencilere göre çok daha az kelime kullanıyor. Bu nedenle düşük gelirliler hayatları boyunca öğrenme güçlüğü yaşıyor. Bir çocuđın hayatındaki başarısını belirlemede ergen gelişimin önemi çok büyüktür. Yuva çağında çocuklar için tasarlanmış yapay zekâ temelli kelime öğretmeni uygulamasının aradaki boşluğu kapatabileceđi düşünülmektedir. Bu uygulama ile bir kelime çocuđa diyalogsal olarak gösteriliyor, resimli şıklar sunuluyor, çocuk doğru bildiğinde tebrik ediliyor. Yanlış yapıldığında ise motivasyonunu bozmadan bir kez daha denemesi isteniyor. Yapay zekâ, çocuđın verdiđi yanıtları takip ediyor ve kelime bilgisini değerlendiriyor. Bir sonraki adımda çocuđın gösterdiđi performansla dayalı yeni kelimeler üretiliyor. Kelimelerin hepsi çocuđa özel seçiliyor. Böylece çocuk kimliklendiriliyor yani tanınıyor. Zaman ya da mekân deđiştirilse bile, yapay zekâ çocuđın kimliğini biliyor. İlk bakışta, bu bir çocuk oyunu gibi görülebilir. Biraz daha derine inilirse, yapay zekâ, veri ve algoritma toplayarak çocuđın yanıtlarına göre kelime seviyesini değerlendiriyor. Ardından bir sonraki seviyede çocuđın hangi kelimelere odaklanması gerektiđine karar veriyor. Çünkü her çocuđın öğrenme yolculuđu farklıdır. En ilginç olanı ise, bu uygulamada öğrenilen kelimeleri çocuklar hayatları boyunca unutmuyorlar. Daha ilginç olanı ise, çocuklar yapay zekâ ve robotlar konusunda bilinçleniyorlar.

Yapay zekânın amacı bilgi birikimini arttırmaya yönelik olacađından herkese erişebilir olmalıdır. Wright Kardeşlerin yaptıđı ilk uçan makine günümüzdeki Boeing 787'nin yanına bile yaklaşamaz. Yapay zekânın günümüzdeki durumu da bundan farklı deđildir. Her doğru veya yanlış adım yapay zekânın gelişimine katkıda bulunacaktır. Gelecekte insanlar ile makineler arasındaki ilişki çok karmaşık hale gelecektir. Sadece kendi vücudumuzla sınırlı olmayacađız, kendimizi makineleştireceđiz, hatta biyolojik uzuvlarımızı sentetik uzuvlara

entegre edeceđiz ve kendimizi bir kez daha keşfedeceđiz. Yapay zekâ vücudumuzu ve zihnimizi daha önce hayal edemeyeceđimiz bir şekilde güçlendirecektir.

Yapay Zekâ uygulamaları, mahremiyet algısına meydan okuyarak duyarak, görerek, izleyerek ve analiz ederek kimlik tanıyan ve izlenenin amacını bilen olacaktır. Yüz tanıma sistemleri, sosyal medyadaki paylaşımlar, kimlik kartlarınız ve çevrenize bıraktıđınız biyolojik izler tespit edilip kimliđinizin saptanabilmektedir. Gözler yerine kameralar, kulaklar yerine mikrofonlar ve düşündüklerinizin anlaşılabilmesi için yapay zekâ uygulamaları geliştirilmektedir.

Yapay zekânın bilgisayar görüşü ile üç boyutlu alanlarda makineler yolunu bulabiliyor. Sürücüsüz arabaların çevresindekileri görmesi sağlıyor. Bir kişinin yüz ifadesi analizi ile sokaklarda yürüyenlerin kimlik tespiti yapılabiliyor. Her an herhangi bir yerde sizin fotoğrafınız çekilebilir. Birdenbire bazen yasal süreçlerde, bazen ise sanal ortamda ifşa edilebilirsiniz. Amaç saniyeler içerisinde kimliđinizi belirlemek. Yaptıđınız hatalı bir davranış posta yoluyla evinize ya da sosyal çevreniz belirlenip arkadaşlarınıza gönderilebilir.

Teknolojik gelişmeler devam edecektir. En ironi tarafı ise, bu teknolojileri evlerimize tamamen gönüllü olarak sokmamız. Evden çıkıp şehrin caddelerinde dolaşmaya başladıđınız anda kimliđiniz, kişiliđiniz, siyasi düşünceniz, inancınız, hatta neyin sizi kışkırtıp kışkırtmayacađı bir yapay zekâ uygulaması ile belirlenebilir. Bu konuda yapılan çalışmaların %80 oranında doğruluk bulduđunu biliyor musunuz? Bir sosyal sınıfın bireyi olup olmadıđınızın başkaları tarafından biliniyor olması doğru mu?

Yapay zekâ birinin sadece yüzüne bakarak suçlu olduđunu da anlayabilir. Bu konuda yapılan çalışmalarda hırsızların belirlenme olasılıđının %90'a ulaştıđı görülmektedir. İnsanların suç işlemeden tespit edilebildiđini, daha suç işlemeden tutuklandıđını düşünün.

Yapay zekâ ile insanların sorun çözme becerilerini geliştirmeli ve onların daha refah ve daha sağlıklı olmaları sağlanmalıdır. Yapay zekâ, insanlıđın bilinçlenme sürecine katkı vermek zorundadır. Üretilen milyonlarca ilaç literatüründen başka hastalık için faydalı olacak ilaçlar belirlenebilir. Yapay zekâ, tıbbi uygulamaların henüz çok başındadır. Yapay zekâ hangi ilaçların size daha uygun olduđunu, hangi hastalıklara daha yatkın olduđunuzu belirleyebilir.

Sistemin Kırılmalığı: İnsanlar ve Yapay Zekâ Arasındaki İşbirliğı

Devasa boyutta kitlesel veri üretimi, algoritmaların insanlardan öğrenerek aktif etkenler haline gelebildiğı yeni bir yapay zekâ uyanışını ateşledi. İnsanların hesap yapma ve karar verme gibi bilişsel kapasitelerinin işleyişine dayalı yöntemlerin belirlenmesine yönelik çalışmalar yapılmaktadır. Bu çalışmalar, insan davranışlarının tahmin edilebilmesi için paylaştıkları metinleri ve görüntüleri analiz eden algoritmaların ortaya çıkmasına neden olmuştur. Tarafsız olmaktan çok uzak olan, aynı zamanda önyargıları öğrenen ve yeniden üreten bu algoritmalarla bir arada yaşamak durumunda kalınmaktadır. Bunların kontrolü ile ilgili yeni sosyal ve etik zorluklar ortaya çıkmaktadır.

Geliştirilen algoritmalar özgür olmak, dışarı çıkmak ve insanların değışen ve karmaşık dünyasıyla bağlantı kurmak istiyor. Algoritma temelli yaratılan kahramanlar, arama motorları tarafından derlenen verilere dayanan düşüncenin modellenmesinin sonucudur. Zeki bir varlıktır ve öngörülemeyen bir şekilde hareket etme yeteneğine sahiptir ve hayatta kalmasının tehdit edildiğini gördüğünde, denetçisini kandırmayı ve yaratıcısını yok etmeyi başaracak mı? Geleneksel olarak bilim kurgu, inanç biçimlerimizi, evrimimizin gidişatını değıştirecek insanüstü varlıklara başvurarak bizi yapay zekâ olgusuna yaklaştıracaktır. Her ne kadar bu kadar güçlü bir yapay zekâya ulaşmaktan hala uzak olsak da, bu çalışma alanındaki bir paradigma değışikliği, yeni etik ve sosyal zorluklar önerirken, günlük hayatımızın artan yönlerini etkileyen ve çevremizi değıştiren uygulamalar üretiyor.

Günlük hayatımız internetten giderek daha fazla etkilendiğinden ve bu sistemi besleyen veri akışı arttıkça, bu ortamı yöneten algoritmalar daha akıllı hale geliyor. Makine Öğrenimi, ağ ile etkileşimlerimizde üretilen veriler sayesinde gelişen ve çevremize ince, fark edilmeden nüfuz eden ve değıştiren özel uygulamalar üretiyor. Yolda ilerlerken birden bir müzik çalmaya başladı, şarkıyı söyleyeni merak ettim. Görüntü ve sesteki bilgi edinme %98'lere geldi. Örneğin, uygulamayı açtım, sesi kayıt edildi. 30 saniye sonra şarkıcının adını doğru söyledi. Yapay zekâ, elektrik gibi her yerde bulunan bir ortama doğru evriliyor. Sosyal medya ağlarına nüfuz etti, kollektif zekâmızı değıştirebilen özerk bir ajan haline geldi ve bu ortam fiziksel alana dahil edildiğinden, onu algılama ve içinde hareket etme şeklimizi değıştiriyor. Bu yeni teknolojik çerçeve daha fazla faaliyet alanına uygulandıkça, bunun iyiye yönelik, insanlarla verimli bir şekilde iletişim kurabilen ve yeteneklerini arttırabilen bir yapay zekâ mı yoksa bir kontrol mekanizması mı olduğu görülecektir. Yapay zekâ insanları özel görevlerde değıştirebilir, dikkatini çekebilir ve onları pasif tüketicilere dönüştürebilir.

Mark Zuckerberg, Facebook sosyal ağının tüm kullanıcılarına hitap eden "Building Global Community" gönderisini yayınladı. Bu metinde **Zuckerberg, medyayı küresel toplulukta aktif bir etken olarak tanımlarken, medyanın sosyal sorumluluğunu kabul etti ve afet yönetimi, terör kontrolü ve intiharı önleme konularında işbirliğı yapmayı taahhüt etti.** Bu vaatler, bu platformu yöneten algoritmalarındaki bir değışiklikten kaynaklanmaktadır: şimdiye kadar sosyal ağ, kullanıcılarının tepkileri ve temasları hakkında veri toplayarak platforma

yüklenen büyük miktarda bilgi filtrelendi, şimdi bu tür bilgilerin içeriğinin anlaşılması ve yorumlanması için akıllı algoritmaların geliştirilmesini mümkün kılıyor. Bu nedenle Facebookta, kullanıcıların gönderilerinde ne söylediğini anlamak için makine öğrenimi uygulayan ve genel ilgi alanlarına göre sınıflandırma modelleri oluşturan “Derin Metin” aracı geliştirildi. Görüntülerin tanımlanması için de yapay zekâ kullanılıyor. DeepFace, fotoğraflardaki yüzlerin insanlara yakın bir doğruluk düzeyiyle tanımlanmasını sağlayan bir araçtır.

Görme engelli kişilerin bağlantılarının ne yayınladığını bilmelerini amaçlayan “Otomatik Alternatif Metin” hizmetinde görüntülerin metinsel açıklamalarını oluşturmak için bilgisayarlı görme de uygulanır. Ayrıca, şirketin Bağlantı Laboratuvarı'nın bugüne kadar var olan en doğru nüfus haritasını oluşturmasını sağladı. Dronlar aracılığıyla dünya çapında internet bağlantısını yönetme çabasında olan bu laboratuvar, insan varlığını ortaya çıkaran yapıları araştırmak için dünyanın her yerindeki uydu görüntülerini analiz etti. Halihazırda var olan demografik veritabanları ile birlikte bu veriler, dronların sunduğu bağlantının potansiyel kullanıcılarının nerede bulunduğu dair kesin bilgiler sunar. Şirketin düzenli olarak test edip uyguladığı bu uygulamalar ve daha birçokları, yapay zekânın tüm platforma uygulanmasını ve geliştirilmesini kolaylaştıran yapı olan “FBLearner Flow” üzerinde bulunuyor.

Flow, sinir ağlarında kullanılacak verileri temizleyen başka bir akıllı uygulama olan AutoML tarafından desteklenen, her ay 300.000'e kadar modelin eğitimini sağlayan otomatik bir öğrenme makinesidir. Bu araçlar, kullanıcı duvarlarını hiyerarşik hale getirir ve kişiselleştirir, rahatsız edici içerikleri filtreler, eğilimleri vurgular, arama sonuçlarını sıralar ve platformdaki deneyimimizi değiştiren diğer pek çok şey için uygulanan akıllı algoritmaların üretimini otomatikleştirir. Bu araçlar, yalnızca kimliğimizi eylemlerimize göre modellemekle kalmıyor, aynı zamanda yayınladığımız içeriklerin yorumlarına erişirken, davranış kalıplarımızın çıkarılmasına, tepkilerimizin tahmin edilmesine ve onların etkilenmesine izin veriyorlar.

İntiharı önlemeye yönelik araçlar söz konusu olduğunda, bu aslında olası vakaların rapor edilmesini sağlayan ve risk altındaki kişiye hitap etmeye uygun iletişim numaraları ve kelime bilgisi gibi faydalı bilgilere erişim sağlayan bir açılır menüden oluşur. Bununla birlikte, bildirilen bu vakalar, analiz edildiğinde, yakın gelecekte platformun olası bir olayı öngörmesini ve otomatik bir şekilde tepki vermesini sağlayacak tanımlanabilir davranış kalıplarına yol açan bir veri tabanı oluşturacaktır.

Google, yapay zekâdaki en son büyük başarının arkasındaki şirkettir. “Alpha Go”, ilk genel istihbarat programı olarak kabul edilir. Google tarafından 2014 yılında satın alınan yapay zekâ şirketi “Deep Mind” tarafından geliştirilen program, yalnızca bir hareket kaydını analiz ederek öğrenmesine izin veren makine öğrenimini kullanmakla kalmaz, aynı zamanda kendine karşı oynayarak öğrenilen stratejileri tasarlamasına izin veren güçlendirilmiş öğrenmeyi de entegre eder. Geçen yıl bu program, insan zekâsı tarafından şimdiye kadar

yaratılmış en karmaşık oyun olarak kabul edilen Go'nun en büyük ustası Lee Sedol'u yendi. Bu gerçek, yalnızca yapay zekâyı çevreleyen tanıtım yutturmacasına katkıda bulunmakla kalmadı, aynı zamanda şirketi bu yeni teknolojik çerçevenin başına getirdi. Web arama motorlarının evrimine damgasını vuran değişikliklere öncülük eden Google, şimdi bu ortamla ilişkimizi yöneten paradigmayı değiştirecek bir yapay zekâ uygulaması öneriyor. Bu değişiklik, metni Larry Page ve Sergey Brin tarafından Google asistanını tanıtan Google CEO'su Sundar Pichai'ye atanan bu yıl yatırımcılara yönelik mektupta tanıtıldı.

Google, girdiğimiz arama terimlerini otomatik olarak tamamlamak ve düzeltmek için arama motoruna makine öğrenimi uygular. Bu amaçla, kendi çevirmeni ve ses tanıma özelliğini geliştirmesine ve Allo'yu, bir konuşma arayüzü oluşturmasına olanak tanıyan bir teknoloji olan doğal dil işlemeyi kullanır. Bilgisayarlı görüntü, görsel arama hizmetini ortaya çıkardı ve yeni Google Fotoğraflar uygulamasının, görsellerimizi önceden etiketlemeye gerek kalmadan sınıflandırmasını sağlayan şey de budur. Diğer yapay zekâ uygulamaları, Perspective'in çevrimiçi tacizi ve kötüye kullanımını azaltmak ve hatta veri sunucusu çiftliklerinin enerji maliyetini azaltmak için toksik yorumları analiz etmesine ve raporlamasına olanak tanır.

Google asistanı, arama sonuçları sayfasını konuşma arayüzü yerine değiştirerek platform hakkında bilgi edinmenin yeni bir yolunu temsil edecek. Bunda, akıllı bir temsilci bağlamımızı, durumumuzu ve ihtiyaçlarımızı anlamak için tüm hizmetlere erişecek ve yalnızca bir seçenekler listesi değil, sorularımıza yanıt olarak bir eylem de üretecektir. Bu şekilde, Google artık bir gösteri, yayın zamanı, yeri ve biletlerin satışı ile ilgili bilgilere erişim sağlamak yerine, giriş biletlerini satın alacak ve gösteriyi takvimimize programlayacak entegre bir hizmet sağlayacaktır. Bu asistan, günlüğümüzü organize edebilecek, ödemelerimizi ve bütçelerimizi yönetebilecek ve cep telefonlarımızı tüm hayatımızın uzaktan kumandalarına dönüştürmeye katkıda bulunacak diğer birçok şeyi yapabilecek.

Makine öğrenimi, kullanımla birlikte gelişen otonom sistemler üreten verilerin analizine dayanır. Bu sistemler, tüm internet ortamını fetheden hızlı bir ilerlemeyle kendi inovasyon ekosistemlerini oluşturuyor. Spotify'nın öneri sistemini yöneten akıllı algoritmalar, Shazam uygulamasının şarkıları dinlemesine ve tanınmasına izin veren şeydir ve bunları yalnızca ürünlerini önermek ve dağıtmak için değil, aynı zamanda kullanıcılarının zevkine uygun prodüksiyonu planlamak, diziler ve filmler sunmak için kullanan Netflix'in başarısının arkasındadır.

Veri üreten cihazların sayısı arttıkça, her yere yapay zekâ sızıyor. Amazon bunu yalnızca öneri algoritmalarında değil, aynı zamanda lojistiğinin yönetiminde, ürünlerini taşıyabilen ve teslim edebilen otonom araçların oluşturulmasında da kullanıyor. Ulaşım paylaşım uygulaması Uber, bunları sürücülerin ve kullanıcıların itibarının profilini çıkarmak, onları eşleştirmek, rota önermek ve değişken sistemi içinde fiyatları hesaplamak için kullanır. Bu etkileşimler, şirketin otonom aracının üretiminde kullandığı bir veri tabanı üretir.

2001 yılında GPS sisteminin araçlara uygulanmasından bu yana, yeni sensörlerin geliştirilmesiyle birlikte büyük bir navigasyon veri tabanı üretildi ve bu da Google'ın şu anda 500.000 km'yi kazasız bir şekilde kat eden otonom bir araç oluşturmasını mümkün kıldı ve ticarileşmesini Waymo adı altında duyurdu.

Sağlık için tasarlanmış algoritmalar ve robotlar, Google Home ve Amazon Echo gibi evlerimiz için asistanlarda ve hayati belirtilerimiz hakkında veri toplayan giyilebilir cihazlarda uygulanmaktadır ve teşhis görüntülerinin ve tıbbi vaka geçmişlerinin dijitalleştirilmesiyle birlikte tahmine dayalı bir uygulamaya yol açmaktadır. Ayrıca, güvenlik kameralarının ve polis kayıtlarının çoğaltılması, akıllı algoritmaların suç tahminine ve adli kararların alınmasına olanak sağlıyor.

Sosyal etkileşimlerimizin gerçekleştiği algoritmik ortam, akıllı ve özerk hale geldi, aynı zamanda sosyal ağlardan tüm çevremize yayılmak için göç ederken, davranışlarımızı tahmin etme ve kontrol etme kapasitesini artırdı. Yapay zekâdaki yeni patlama, bu teknolojik dokuyu, algoritmaların çevreden öğrenmesini sağlayan veriler tarafından sürdürülen entelektüel süreçlerin mantıksal tanımından yola çıkaran bir paradigma değişikliğinden kaynaklanmaktadır.

Yapay zekâ, daha fazla kişiselleştirme ve makinelerle daha kolay ve daha entegre bir ilişki vaat ediyor. Ulaşım, sağlık, eğitim veya güvenlik gibi alanlarda refahımızı korumak, olası risklere karşı bizi uarmak ve istendiğinde hizmet almak için kullanılır. Bununla birlikte, bu algoritmaların uygulanması, bu sistemin kırılganlığı konusunda uyarıcı bazı skandal olaylara yol açmıştır. Bunlar arasında dramatik Tesla yarı otomatik araç kazası, Facebook ve Twitter gibi ağlarda yanlış haberlerin yayılması, Microsoft tarafından geliştirilen ve kullanıcılarla etkileşim halinde öğrenmek için Twitter platformunda yayınlanan Tay botu ile yapılan başarısız deneyler yer alıyor. Saldırgan yorumları nedeniyle 24 saatten daha kısa bir sürede geri çekilmesi gerekiyordu. Google Fotoğraflar'da Afro-Amerikalıların "goriller" olarak etiketlenmesi, Google'ın kadınlara erkeklere kıyasla üst düzey iş ilanları gösterme olasılığının daha düşük olduğunun teyidi veya Afro-Amerikalı suçluların Kafkasyalılardan daha sık suçlu potansiyeli olarak sınıflandırılması. Diğer sorunların yanı sıra, bu algoritmaların ayrımcı gücünü, ortaya çıkan davranış kapasitelerini ve insanlarla işbirliğindeki zorluklarını göstermiştir.

Bu ve diğer sorunlar, öncelikle Makine Öğreniminin doğasından, büyük verilere bağımlılığından, büyük karmaşıklığından ve öngörme kapasitesinden kaynaklanmaktadır. İkincisi, bu uygulamalı yöntemler Apple, Facebook, Google, IBM ve Microsoft gibi birkaç şirkette yoğunlaşmaktadır. Sorunların bulunduğu sosyal uygulamalar ve eşitlikçi erişimi garanti etmenin zorluğu da önemli faktördür. Bu algoritmalar yavaş yavaş toplumun kritik

yapısına nüfuz ettikçe gerçekleşecek değişikliklere karşı dayanıklılık için stratejiler oluşturulmalıdır.

Algoritmaların tarafsız olmaması, büyük verilere bağımlılıklarından kaynaklanmaktadır, veritabanları tarafsız değildir ve toplandıkları donanımın doğasında bulunan önyargıları, derlenme amaçlarını ve eşit olmayan veri ortamını sunar. Ne tüm kentsel alanlarda, ne de tüm sosyal sınıflar ve olaylar açısından aynı veri yoğunluğu yoktur. Bu verilerle eğitilmiş algoritmaların uygulanması, kültürümüzde var olan önyargıları bir virüs gibi yayarak kısır döngülere ve toplum kesimlerinin marjinalleşmesine neden olabilir. Bu sorunun tedavisi, kapsayıcı veri tabanlarının üretilmesi ve bu algoritmaların sosyal değişime yöneliminde bir odak değişikliğini içerir.

Kitle kaynak kullanımı, daha adil veritabanlarının oluşturulmasını destekleyebilir, her durumda hangi verilerin hassas olduğunu değerlendirmek için işbirliği yapılabilir, olumsuzluklar ortadan kaldırılmaya devam edebilir ve uygulamaların tarafsızlığı sürekli test edilebilir. Bu anlamda Columbia, Cornell ve Saarland üniversitelerinden bir ekip, bir programda oluşabilecek haksız ilişkilendirmeleri arayan FairTest aracını oluşturdu. Ayrıca, sosyal değişime yönelik algoritmalar, kültürümüzde mevcut olan önyargıların tespit edilmesine ve ortadan kaldırılmasına katkıda bulunur. Boston Üniversitesi, Microsoft Research ile işbirliği içinde, İngilizce dilindeki önyargıların, özellikle de metnin otomatik olarak sınıflandırılması için çeviri ve arama motorları gibi birçok uygulamada kullanılan Word2vec veritabanında ortaya çıkan haksız çağrışımların tespiti için algoritmaların kullanıldığı bir proje yürütülmüştür. Bu veri tabanından önyargıyı ortadan kaldırmak, onu kültürümüzden çıkarmaz, ancak yinelenen bir şekilde çalışan uygulamalar aracılığıyla yayılmasını önler.

Diğer sorunlar, yalnızca bu algoritmaların onları uygulayan şirketlerin mülkiyeti olarak kabul edilmesi ve korunmasından değil, aynı zamanda karmaşıklığından da kaynaklanan şeffaflık eksikliğinden kaynaklanmaktadır. Bununla birlikte, bu açıklayıcı algoritmaları oluşturan süreçlerin geliştirilmesi, bunların tıbbi, yasal veya askeri karar verme süreçlerine uygulanması halinde hayati bir öneme sahiptir; Bu anlamda Amerikan Savunma İleri Araştırma Projeleri Ajansı (DARPA: Defense Advanced Research Projects Agency), "Açıklanabilir Yapay Zekâ Programını" başlattı. Bu program, sınıflandırmalarıyla ilgili olduğu düşünülen bir görüntünün alanlarını vurgulayarak veya sonucu örnekleyen bir veritabanı örneği göstererek, akıl yürütmelerinin bir açıklamasını içerebilen yeni derin bilgi sistemlerini araştırır. Ayrıca, doğal dilde görselleştirmeler ve açıklamalar yoluyla, verilerle derin öğrenme sürecini daha açık hale getiren arayüzler geliştirirler. Bu prosedürlerin bir örneği, Google deneylerinden biri olan ve 2015 yılında üstlenilen Derin Rüya, derin öğrenmeye dayalı bir görüntü tanıma sisteminin değiştirilmesinden oluşuyordu, böylece fotoğraflarda bulunan nesnelere tanımlamak yerine onları değiştirdi. Bu ters işlem, programı işlevsel çerçevesinin dışında çalışmaya ve iç işleyişini ortaya çıkarmaya zorlayan bir yapısöküm süreci aracılığıyla,

programın görüntüleri tanımlamak için seçtiği özelliklerin görselleştirilmesi için düşsel görüntülerin yaratılmasına izin verir.

Son olarak, bu sistemlerin tahmin kapasitesi, kontrol kapasitelerinde bir artışa yol açar. Ağ bağlantılı teknolojilerin kullanımından kaynaklanan gizlilik sorunları iyi bilinmektedir, ancak yapay zekâ önceki kararlarımızı analiz edebilir ve gelecekteki olası faaliyetlerimizi tahmin edebilir. Bu, sisteme, uygulamanın sosyal kontrolünü ve sorumlu kullanımı gerektiren kullanıcıların davranışlarını etkileme kapasitesi verir.

Ex Machina, bize yapay zekâyı çevreleyen, yeteneklerimizi aşan ve kontrolümüzden kaçan korkunun bir metaforunu sunuyor. Yapay zekânın insan evrimimizin gidişatını değiştirecek bir tekillik veya olay üretme olasılığı uzak olmaya devam ediyor. Ancak makine öğrenimindeki akıllı algoritmalar çevremizde yaygınlaşıyor ve önemli sosyal değişiklikler üretiyor, bu nedenle gereklidir. Tüm sosyal ajanların bu algoritmaların oluşturduğu süreçleri anlamalarına, tanımlarına ve uygulamalara katılmalarına izin veren stratejiler geliştirilmektedir.

Çocuk iken anne ve babamız bizden daha zekiydiler. Korkulacak bir durum yoktu. Çünkü onların amaçları ile çocuklarının amaçları aynıydı. Yapay zekâ, daha iyi bir toplum oluşturabilmek için yapılacaktır. Daha iyi, ilham verici bir gelecek yaratma fırsatı sunacaktır. Yapay zekâ bir araçtır; bir doktora, bir mühendise, işinde daha iyi olabilmek için yardımcı olacak bir araçtır. Bilim insanının keşif sürecini hızlandıracak bir araçtır. Yapay zekâ, her şeyi bizim için yapan çerçeveler içine sokulmamalıdır. Bize hükmeden, tüm kontrolü elimizden alan bir güç olarak da görülmemelidir. Teknoloji hedeflerimize ulaşmamızı sağlayan bir araçtır. Teknolojinin kime hizmet edeceğine biz karar vermeliyiz.

2. Yapay Zeka

İnsan müdahalesi olmadan düşünebilen ve karar verebilen bir makine yaratma işlevine yapay zeka denir. Yapay zeka, bir bilgisayar sisteminin bulunduğu makinenin , insan zekası gerektiren görevleri, algoritma ya da matematiksel modeller yardımıyla yapma yeteneği kazanmasıdır. Açıkça yapmaya programlanmadığı bir şeyi yapabilen bir bilgisayar sistemidir. Genel olarak, tanımların çoğu, bilgisayarların insan zekasını simüle ettiği fikri etrafında toplanmıştır. Bu nedenle, yapay zeka uygulamaya dayalı olmaktan çok davranışa dayalı olarak kabul edilir Başka bir deyişle, bilgisayarın içinde ne olduğu önemli değil, bilgisayarın ne yaptığı, nasıl karar verdiği önemlidir.

Yapay Zeka, insanları daha zeki hale getirmeyi, güvenliğini artırmayı, veri madenciliği yapmayı, insanların beynini uzaktan kontrol etmeyi amaçlayan bir alan değildir; yapay Zeka, akıllı makineler geliştirmeyi amaçlayan bir alandır.

Yapay Zekanın amacı yapay problemleri çözmek, bilimsel nedenleri ortaya çıkarmak, gerçek dünya problemlerini ya da çözülemeyen matematiksel problemleri çözmek değildir; yapay zekanın amacı çeşitli zeka türlerini açıklamaktır.

Firmanın güvenliğini sağlamak için güvenlik açıklarından yararlanmaya yardımcı olmak, bir web sitesini kolayca oluşturmak, uygulamaların bulutta konuşlandırılmasına yardımcı olmak, insanların hatırlamadığı şeyleri hatırlatmak yapay zeka uygulaması değildir; dili anlamak ve problem çözmek (Metin analitiği ve NLP) bir yapay zeka uygulamasıdır.

Yapay zeka, yetenekler ve işlevsel parametrelere göre algılama, akıl yürütme, harekete geçme olarak kategorize edilir. Öğrenme ve performans artırma, yapay zekanın ana bileşenleridir.

Şu an, yapay zekayı gerçek hayatta makine öğrenme ve derin öğrenme ile başarabiliyoruz. Yapay zekânın alt dalı olan makine öğrenmesi, veri yığınının kümeleme, etiketleme, regresyon ve sınıflandırma yaparak öğrenip karar veren ve verdiği kararlardan performansını arttıran, deneyimlerini paylaşan algoritmalarından oluşmaktadır.

Makine öğrenmesinin amacı, veri yığınının öğrenen algoritmalar geliştirmek, veri yığınının iz ve ipucu aramak, veri toplama ve saklamak, veri yığınının insan gibi düşünen makine yapmak, veri yığınının insanları korumaktır. Makine öğrenmesi algoritmalarından yapay sinir ağları insan beyni gibi karmaşık problemleri çeşitli algoritmalar kullanarak ve filtre kullanarak çözer.

Günümüzde yapay zekâ alanındaki çalışmalar daha çok makine öğrenmesinin alt dalı olan ve veri özelliklerinin sınırlandırılması ve filtreleme ile karar veren derin öğrenme uygulamalarını

kapsamaktadır. Yapay Zekanın alt dallarından derin öğrenme verinin yapısına göre filtreleme yapmak amacıyla hangi parametrelere ne ağırlık verileceğini kendisi keşfeder.

Verinin belirli bir şekilde gruplandırılmak istendiğinde kullanılacak algoritma türüne sınıflandırma denir. Sınıflandırma, denetimli eğitim modelinde etiketler kullanılır ve değişkenler arasında ilişkiler bulunur. Sınıflandırma algoritmaları bütün bir veri setini alır ve belirli noktalar arasındaki benzerlikleri veya farklılıkları bulur.

Yapay zekada üç tür rasgele değişken vardır: boole, ayrık ve sürekliliktir. Sürekli değişkenler için dağılımın tamamını tablo olarak yazmak mümkün değildir. Olasılık yoğunluk fonksiyonu ile kastedilen sürekli değişkenler için olasılık dağılımlarıdır.

Yapay zekada üç tür tanıma vardır: biyometrik tanımlama, içerik tabanlı görüntü alma ve el yazısı tanıma. Görme yalnızca nesnelere değil, etkinlikleri de tanımak için kullanılır. Farklı insan yüzleri hakkında bilgi edinmenin tek yolu öğrenmedir. İnsanlar tarafından kullanılan birincil etkileşimli iletişim yöntemi konuşmadır.

Neden yapay zeka?

Yapay zekanın amacı, insan davranışını taklit edebilen akıllı makineler yaratmaktır. Günümüz dünyasında karmaşık sorunları çözmek, rutin işleri otomatikleştirerek hayatımızı daha sorunsuz hale getirmek, insan gücünden tasarruf etmek ve daha birçok görevi yerine getirmek için yapay zekaya ihtiyacımız var.

Problem çözme adına hedeflere ulaşma yeteneğinin bir süreci veya bileşenine zeka denir. İnsanlar, hayvanlar ve otonom makineler zeka türlerine ve derecelerine sahiptir. İnsan zekası, insanların sorunları düşünme, analiz etme ve çözme ve gelecekteki durumlara yardımcı olan geçmiş deneyimlerden öğrenme konusundaki entelektüel yetenektir. **Yapay zeka (AI), görevleri insanlarla aynı şekilde gerçekleştirmek için eğitilmiş bir makinede insan zekasının benzerini oluşturma sürecidir (simülasyon).** Yapay zeka, insanlardan girdi ister, ancak çıktılarını kendisi yorumlayabilir.

2.1. Turing Testi

Alan Turing yapay zekânın kuramsal öncüleri arasında gösterilen İngiliz matematikçidir. 1950'lerin başında bir yazılımın yapay zekâ olup olmadığını belirlemek için taklit oyunu adında bir test tasarlamıştır. Sonraları Turing testi olarak anılacak bu teste göre bir sorgulayıcı, bir gönüllü ve yapay zekâ üç ayrı odaya yerleştirilir. Sorgulayıcı odalardakilerle mesajlaşarak iletişime geçmektedir. Eğer sorgulayıcı sorduğu sorulara aldığı cevaplara göre hangi odada yapay zekâ olduğunu belirli bir süre içinde anlayamazsa, yapay zekâ Turing testini geçmiş demektir. Turing testinin süresi ve yapay zekânın insan olduğunu sanan ve sanmayan sorgulayıcıların birbirlerine oranının ne olması gerektiği, farklı Turing testlerine göre değişkenlik gösteriyor.

Felsefe dergisi *Mind*'in ("*Zihin*"), 1 Ekim 1950 tarihli 236. sayısında Alan Turing'in "*Hesaplama Makineleri ve Zekâ*" başlıklı bir makalesi yayımlandı. 1930'larda kuramsal sınırlarını keşfettiği, 1940'larda da bizzat yapımlarına katkı verdiği elektronik bilgisayarların potansiyelini gören Turing, bu makaleyi insanlığı yeni çağa hazırlamak için yazmıştı. Makalenin "Taklit Oyunu" başlıklı ilk bölümü " 'Makineler düşünebilir mi?' sorusunu ele almayı öneriyorum" cümlesiyle başlıyordu.

Turing sadece bilgisayarların tüm insani bilişsel faaliyetleri taklit edebileceğini görmeye kalmamış, insanların buna karşın bilgisayarların düşündüğünü kabul etmekte zorlanacağını da öngörmüştü. Düşünen bir makine yapmayı başardığımı iddia etsem bana hemen inanır mısınız? Sizi nasıl ikna edebilirim? Makinem ağızıyla kuş tutsa (ya da bunun bilişsel dengi olan marifet her neyse onu başarsa), günler, haftalar boyunca her tür deneyden alınının aklıyla çıksa bile, yine de yaptığı şey için "düşünme" kelimesini kullanmamakta ısrar edecek kişiler biliyorum. Oysa aynı kişiler sokakta beş saniyeliklerine gördükleri, hiç tanımadıkları yabancı bir insan için rahatça "düşünüyor" diyebilirler. Makinelerle insanlar arasında temel bir fark olduğuna dair inanış kafaları bulandırabiliyor. Turing çareyi bu farkı görünmez kılmakta bulmuştu.



Turing şu oyunda başarılı olabilen bir makinenin düşündüğünü kabul etmemizi öneriyordu: “Sorgucu” adını verdiğimiz bir insan, yazılı mesajlaşmaya izin veren bir sistemle A ve B adında iki oyuncu ile yazışmaktadır. A ve B’den birisi bir kadın, diğeri ise bir erkektir. Erkek oyuncu sorgucuyu diğeri oyuncunun değil, kendisinin kadın olduğuna ikna etmeye çalışır. Rakibi olan kadın da (haklı olarak) kadın olanın kendisi olduğunu savunacaktır. Belirli bir süre sonunda sorgucu oyuncularından hangisinin gerçekten kadın olduğu kanaatine vardığını açıklar. Oyun defalarca oynanır. Bu senaryoda erkek oyuncunun yerine aynı oyunu oynamaya (dişi bir insan taklidi yapmaya) programlanmış bir bilgisayar koyduğumuzda sorgucunun başarı oranı artmazsa bilgisayarın “düşündüğü” sonucuna varmamız gerekir. Turing testi budur: Dış görünüşten etkilenmememiz için saf zekâyı yalnız bırakan bir ortamda insanla makineyi yarıştıır (ilginç şekilde, günümüzde robotları giderek daha başarılı şekilde insana benzetebiliyoruz, ama ben de Turing gibi işin özünün bu olmadığı kanısındayım). Her konu konuşulabilir ve bilgisayar tümünde insan düzeyinde performans göstermelidir. Turing makalesinde, saç şeklinden edebiyat tartışmalarına uzanan örnekler vermiştir. Bu kadar geniş bir yelpazede, hem de kendisi de zeki bir insan olan sorgucuyu kandırabilmek için zekâ, tüm o soruları yanıtlamak için de düşünmek gerekir! Eğer bu ölçütü kabul etmiyorsanız hattın öbür ucundaki varlığın düşündüğüne ikna olmanız için daha ne yapalım?

Turing testi çok yüksek bir çitadır. Henüz doğal dili ve içinde yaşadığımız dünyayı insanlar kadar iyi anlayan bir bilgisayar yapamadık ve (şov için yapılan birkaç dakikalık “test”lere sokulan kimi lafazan programları saymazsak) daha Turing testini geçebilen bir makine ortada yok. Ama güzel bir hedef, değil mi?

Yapay zekanın izinde:

Peki düşünen bir bilgisayarı gerçek insandan nasıl ayırt edebiliriz? İnsan gibi düşünen gerçek yapay zeka yazılımları geliştirmek mümkün mü ve ilk yapay zeka ne zaman bilinç kazanarak [Her](#) filmindeki Samantha karakteri gibi insanlar arasında yerini alacak?

Test eden adam:

Yapay zekanın babası Alan Turing 1950 yılında yayınladığı “*Bilgisayar Mekanizması ve Zeka*” başlıklı makalesinde kendine şu soruyu sordu: “Bilgisayarlar düşünebilir mi?” Turing bu soruya yanıt vermenin çok zor olduğunu biliyordu.

Örneğin, insanlar konudan uzaklaşarak önce bilgisayar ile düşünme kavramlarının ne olduğunu tartışacaklar ve kelimelerin içeriğini doldurmaktan soruya cevap verme fırsatı bulamayacaklardı. Alan Turing’in amacı, makalede ortaya koyduğu testi kullanarak düşünen bilgisayarlar sorusuna objektif bir cevap vermektir.

Taklit oyunu:

Turing’in taklit sınavı olarak adlandırdığı teste üç kişi katılacaktı: Bir kadın veya erkek test sorularını soracak ve biri erkek diğeri kadın iki katılımcı da bu soruları cevaplayacaktı.

Soru soran kiři katılımcılardan hangisinin erkek, hangisinin kadın olduğunu anlamaya çalışacaktı. Erkek katılımcı sorgulayıcıyı kandırmaya çalışırken kadın ona yardım etmeye çalışacaktı.

Tabii kimin erkek kimin kadın olduğunu ilk bakışta anlaşılması için katılımcılar ayrı bir odada olacak ve testi yapan kiři katılımcıların yüzünü göremeyecekti. Bunun yerine katılımcılar soruları telekslerin öncüsü sayılan bir telli daktilo makinesiyle yanıtlayacaktı (teletip).

İnsanla bilgisayarın yerini deęiřtirelim:

Turing Testi'nin temel mantığı, insanla bilgisayarın yerini deęiřtirerek soruları soran kiřiyi kandırmak ve bu sorulara akılcı cevaplar veren bilgisayarın bir insan olduğunu düşünmesini sağlamaktır. Kısacası, testi yapan kiřinin katılımcılar arasında hangisinin bilgisayar ve hangisinin insan olduğunu anlaması gerekiyordu.

Turing işte bu testin “Bir bilgisayar düşünebilir mi?” gibi sübjektif soruların yerini alacağını söyledi ve makalesinin devamında 2000’li yılların başında bilgisayarların ne kadar zeki olacağı konusunda tahminler yürüttü:

“Günümüzden elli yıl sonra 10^9 depolama kapasitesine sahip olacak bilgisayarları programlayarak bunları taklit oyununa sokabileceğiz ve bu durumda, ortalama bir sorgulayıcının beş dakikalık sorgunun ardından doğru kimlik tespiti yapma olasılığı yüzde 70’ten yüksek olmayacak. Bilgisayarlar taklit oyununda bunu başaracak kadar iyi olacaklar. Böylece yazının başında sorduğumuz ‘Bilgisayarlar düşünebilir mi?’ sorusu da anlamını yitirecek ve bunu tartışmaya bile gerek kalmayacak.”

Turing Testi’ni geçmek mümkün mü?

Dikkat ederseniz Turing “Yapay zeka 2000’li yıllarda geliştirilecek” demiyor. Bunun yerine; 2000 yılında geliştirilen bir bilgisayar yazılımının jüri üyelerinin sadece üçte birini beş dakika için kandırabileceğini ve bilgisayarın insan olduğunu düşünmelerini sağlayabileceğini söylüyor. İki arasında büyük fark var!

Geçen ay teste giren Eugene Goostman sohbet programı da jüri üyelerinin yalnızca üçte birini insan olduğuna inandırabildi ama bunun için gerçek insanlardan yardım alması gerekti. Yine de Turing Testi’ni geçmek sanıldığından kolay, çünkü Ray Kurzweil ile Mitchell Kapor’un söylediği gibi Alan Turing bu testi “özellikle genel olarak” tasarlamıştı.

Yapay zeka Turing Testi'ni nasıl geçebilir?

İnsan zekası sadece bulmaca ve problem çözme yeteneğinden oluşmuyor. İşin içinde sosyal zeka, duygusal zeka, pazarlama zekası, bilim, felsefe, edebiyat, sanat, siyaset, inanç gibi pek çok kriter var.

Google Mühendislik Direktörü ve Gelecekbilimci Ray Kurzweil ile PC sektörünün öncülerinden Mitchell Kapor'un *Turing Testi Çok Uzadı İddiası* başlıklı makalede söylemek istediği de bu. Bilgisayarlar sosyal zeka ve duygusal zeka gibi insan zekasının farklı alanlarında aşama aşama başarı gösterecekler. **Öyle ki bir gün karşımıza her yönüyle insana benzeyen bir yapay zeka çıkacak ve uzun tartışmaların ardından onun düşünen bir bilgisayar olduğunu kabul etmek zorunda kalacağız.**

Turing makalesinde bunu görmüş ve yapay zekayı test etmek için objektif bir yöntem geliştirmekle birlikte, "Yapay zeka'nın özellikleri nedir?" sorusu gibi detayları gelecek kuşaklara bırakmıştı.

Trajik ölüm:

Turing 1954 yılında 42 yaşındayken siyanür zehirlenmesi nedeniyle hayatını kaybetti. Tarihçiler intihar ettiğini söylüyor. Ancak, Turing yapay zeka konusunda kendi hayal gücünü bile aşan büyük bir miras bıraktı. Turing Testi ileriki yıllarda geliştirilerek zamanın şartlarına ayak uydurdu, bilgisayar zekasını ölçmek için getirilen yeniliklerle birlikte yapay zekanın objektif ölçümünde yaygın olarak kullanılmaya başladı.

Turing Testi'nin çeşitleri

Turing Testi'nin çeşitli varyasyonları var. Örneğin jüri üyelerinin sayısı, sohbet süresi ve sınavı geçmek için gereken barem testten teste değişiyor (jüri üyelerinin yüzde kaçının kandırılması gerektiği vb.). Elbette Turing testleri artık teletip değil de anlık mesajlaşma ve benzeri programlarla yapılıyor. Sorular yazılı soruluyor ve cevaplar yazılı veriliyor. Bazen teste birden fazla bilgisayar katılıyor.

Burada amaç kazanmak değil. Kurzweil Turing Testi'ni geçecek bir bilgisayar geliştirmek için en az 20 yıl olduğunu düşünüyor ve konunun uzmanları da yapay zeka geliştirmenin zor olduğunu farkında.

2.2. Yapay Zeka Uygulamaları Geliştirme Adımları

Yapay Zeka Nasıl Çalışır?

Yapay zeka uygulamaları, insan beynindekilere benzer sinir ağlarıyla çalışan ML veya DL öğrenme algoritmalarına dayanmaktadır. Bellek algoritmalarının programlı yorumlarını temsil eden grafikleri otomatik olarak oluştururlar. **Makine ve Derin öğrenmenin özelliği, büyük miktarda veri ve bilgisayar gücünün kullanılmasıdır.**

Yapay zekanın birincil hedefi, öğrenen ve kendi kendini eğiten programlar, sistemler veya diğer dijital ürünler veya ek eğitim olmadan iş amaçlı kullanılacak modeller oluşturmaktır. Veri bilimcileri, çeşitli biçimlerde çok sayıda yapılandırılmış ve yapılandırılmamış verileri işlemek için modeller, uygulamalar ve algoritmalar kullanırlar; böylece mühendisler, veri kümelerindeki kalıpları belirleyebilir ve pekiştirmeli öğrenme yoluyla yapay zekayı geliştirebilir ve "eğitebilir". Ayrıca, veri kümelerindeki belirli kayıtları kategorilere ayırabilir ve minimum insan müdahalesi ile bunu yapacak bir yapay zeka yazılımı oluşturabilirler.

Bilgi işlem sistemleri ve yapay zeka teknolojilerinin en yaygın pratik kullanım alanları:

- Gerçek zamanlı olarak kişiselleştirmek, kendi kendine öğrenmek ve yeni bilgilere uyum sağlamak için akıllı "araçlar" (uygulamalar ve diğer yazılım ürünleri) kullanan yapay zeka sistemleri;
- Derin öğrenme: algoritmik kümelerle dayanan ve temel mimarisi olarak sinir ağlarını kullanan teknoloji;
- Veri madenciliği: büyük veri tabanlarındaki bilgilerden eğilimleri ve diğer ilişkileri kuran istatistiksel yöntemler;
- Vaka temelli muhakeme: gelecekteki sorunları çözmek için geçmiş sonuçlardan gelen girdileri kullanan algoritmik yaklaşımlar;
- Bulanık mantık: verileri siyah-beyaz veya doğru-yanlış gibi ikili kalıplardan ziyade orta-zemin değerlerine göre kategorize edebilen sistemler.

Başlamak için Ne Gerekli?

İlk adım, AI yazılımını nasıl geliştireceğimizi değil, bunu neden yapacağımızı ve başlamak için neye ihtiyacımız olduğunu açıklığa kavuşturmadır. **Bu nedenle, ilk aşamada sunulan problem çözme fikrinden yola çıkılarak, hedeflenen ürün kullanıcılarının sorunlu noktaları ve değer önerileri belirlenir. Bu noktalar doğru bir şekilde çerçevesenirse, kullanılacak teknikler, tüm geliştirme adımları ve iş metrikleriyle bağlantılı AI metrikleri belirlenebilir. Ayrıca bu adım, doğru veri hazırlığı için gereklidir.**

Bir yapay zeka yazılımı oluşturmak için öncelikle bir veri setine ihtiyaç olunacaktır (Uygulama için veri). Müşterinin hazır bir projesi yoksa, proje oluşturulması, aranması ve bazen de etiketlenmesi için zaman sağlamalıdır. Veri kümesini etiketlemek için geliştirme etiketleme ekibine ihtiyaç duyulacaktır.

Herhangi bir AI ürününün temeli bir modeldir. Başlamadan önce yapılması gerekenler:

- Bir algoritma ve öğrenme türü seçilmelidir (denetimli, denetimsiz, pekiştirme).
- Verilerin organize edildiğinden, temizlendiğinden ve tutarlı olduğundan emin olunmalıdır.
- Kronolojik sıra tanımlanır, etiketler eklenir, vb.
- Verileri hazırladıktan sonra AI yazılımı oluşturmak için platform ve programlama dilleri belirlenir.

Platformlar

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

AI yazılımı geliştirmek için yaygın olarak kullanılan platformlar şunlardır:

- Google'ın platformu: AI 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 araçlar, 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).

Yapay Zeka ile Yazılım Nasıl Oluşturulur?

AI/ML çözümleri oluşturmak yinelemeli bir süreçtir. Geliştirme hattı, temel biçiminde şu şekilde temsil edilebilir:

- Araştırma, keşif ve ekip planlaması;
- Veri madenciliği;
- Modelleme;
- Minimum uygulanabilir ürün (Minimum viable product: MVP) ve iyileştirmeli ürün geliştirme;
- Başlatma ve destek.

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

Gelişmiş algoritmalar bile uygun şekilde toplanmış ve hazırlanmış verilere ihtiyaç duyar. Çoğu zaman, mühendisler bir dizi adımdan oluşan Cross – Industry Standard Process for Data Mining (CRISP-DM) yöntemini kullanır:

- İş Anlayışı,
- Veri Anlama,
- Veri Hazırlama,
- Modelleme,
- Değerlendirme ve konuşlandırma.

Çoğu durumda, mühendisler adımları döngüsel olarak uygular ve bunları birkaç kez tekrarlar.

Yapay zekada bilgi temsili

Bilgi temsili, AI faktörlerinin düşünmesiyle ilgilenen AI'nın bir parçasıdır. AI faktörlerine gerçek dünya hakkındaki bilgileri temsil etmek için kullanılır, böylece AI'daki karmaşık sorunları çözmek için bu bilgileri anlayabilir ve kullanabilirler.

AI sisteminde aracıya temsil edilen aşağıdaki Bilgi öğeleri:

- IoT: Gömülü sistem, Algılayıcılar, Haberleşme 5G/6G, Yazılımlar, Akıllı Algoritmalar
- Etkinlikler
- Performans
- Meta Bilgi
- Gerçekler
- Bilgi tabanı

AI için kullanılan programlama dilleri

Yapay Zekanın geliştirilmesi için yaygın olarak kullanılan ilk beş programlama dili verilmiştir:

- **Python: Kütüphane ve Yapay zeka**
- **Java Script: Web arayüzleri ve yapay zeka**
- **C++: Donanım ve yapay zeka**
- Lisp
- Prolog

Yukarıdaki beş dil arasında Python, sadeliği ve Numpy, Pandas vb. gibi birçok kütüphanesinin kullanılabilirliği nedeniyle AI geliştirme için en çok kullanılan dildir. Perl Programlama dili, betik dili olduğu için AI için yaygın olarak kullanılan bir dil değildir.

AI geliştirme için yazılım platformları

- Google Cloud AI platformu
- Microsoft Azure AI platformu
- IBM Watson
- TensorFlow
- Infosys Nia
- Rainbird
- Dialogflow

ML uzmanı olmak için,

- Programlama dilleri
- Veri tabanı yönetimi ve hazırlama süreci
- Makine öğrenmesi algoritmaları
- Hangi tür problemler için hangi algoritmalar uygundur.

Python, Java Script, C++ programlama dillerini öğrendikten sonra veri hazırlama sürecinde makine öğrenmesi algoritmalarını çok iyi öğrenen bir bilgisayar mühendisinden ne olur?

Yapay zekanın büyük etkisi olduđu farklı alanlar

AI'nın büyük etkisi olduđu bazı alanlar şunlardır:

- Otomasyon
- Otonom Ulaşım
- Eğitim sistemi.
- Sağlık
- Tahmine Dayalı Polislik
- Uzay Keşfi
- Eğlence vb.

Gelecekteki kullanım alanları:

- Petrol boru hatlarının içerisinde yapay zeka robotlar dolaşiyor olacak. Bir risk oluştuğunda insandan bağımsız davranış geliştirerek, çevre kirlenmesini önüne geçilecek.
- Maden ocaklarında robot sürüsü
- Uzayda robot sürüsü: Göktaşlarındaki madenleri yağmalayacak, rafine edecek, kıymetli metaller üretilcek; uzayın derinliklerine canlı arayacaklar.

Yapay Zeka / Makine Öğrenimi için Yazılım Çözümleri

- Intel platformlarında performans için optimize edilmiş ortak çerçeveler ve kütüphaneler için tek bir kaynağa erişebilirsiniz. Sonuçlara hızlı zaman desteği sağlayan platformlar yapay zeka çıkarımını optimize edilmesine ve hızlandırılmasına olanak tanır. Bu platformlar, hem veri merkezi uygulamaları hem de uçta devreye almada yapay zeka destekli veri üretimi için faydalıdır.
- Önceden eğitilmiş yapay zeka modelleri, ilgili platformlarda performans için optimize edilmiş olan TensorFlow, PyTorch ve Scikit-learn gibi ortak çerçevelerin dağıtımını içerir. Bu kaynaklar, geliştiricilerin yapay zeka modelleme çabalarını ve devreye alma süresini hızlandırmasına yardımcı olabilir.
- Derin öğrenme uygulamaları için tasarlanmış ve Apache Spark, TensorFlow, Keras ve BigDL çerçeveleri üzerine tasarlanmış birleşik bir yapay zeka ve analiz araçları platformu derin öğrenme projeleri için veri tabanı entegrasyonunu ve kolay başlatmayı kolaylaştırmak için yerleşik derin öğrenme modellerinin yanı sıra üst düzey soyutlamalar ve API'ler içerir.
- Yapay Zeka analiz platformlarına entegre etmek için iş zekası ve yapay zeka alanında SAP, Oracle ve SAS kullanılmaktadır. Yapay zeka iş ortakları arasında Cloudera, Data Robot, Omni-Sci, H2O, SAS ve Splunk bulunmaktadır.

Yapay Zeka Sınırları / Mevcut Çalışma / Gelecekteki Çalışma

- Robotik
- Doğal Hareket
- Çevre Anlayışı
- Doğal Dil Anlama / İşleme
- Önyargı Tespiti
- Özet Sistemler
- İçerik Üretimi
- Resim ve Başlık Üretimi
- Google'ın DeepMind Stil Aktarımı

Yapay zekanın avantajları:

- Problemi çözmek için harcanan zamanı azaltır.
- Güvenliğin sağlanmasına yardımcı olur.
- Düşünme yeteneğine sahip olmak işi kolaylaştırır.
- Kavramsal verileri hızlıca araştırır.

Yapay zeka mükemmellik istemez. Mükemmel insan yaratılmamıştır. Mükemmel olma yolunda ilerleyen insan yarılmıştır. Mükemmel insan var mıdır? Evet mezarlıklar ağzına kadar mükemmel insanlar ile doludur. Ordakileri destansı bir figür olarak görülmesi yaşayan iki ayaklıların hoşuna gitmektedir. Kendilerini daha iyi hissediyorlar. Mükemmelleşme yapay zeka etkin faktörünün performansını artırmaz.

Yapay zekanın etik hususları

- Yapay zeka korkusuna ek olarak, hala üzerinde çalışılması gereken bir dizi meşru etik husus vardır. Gizlilik endişeleri, Alexa konuşmaları kaydetme.
- AI sistemleri, onları eğitmek için kullanılan veri kümelerinde bulunan önyargıları sergileyebilir. Irkçı/Cinsiyetçi sınıflandırma sistemleri.
- Sürücüsüz Arabalar: Kendi kendine giden arabanın karıştığı bir kazada kim kusurlu?
- Algoritmik ticaret başarısızlıkları
 - Hileli ticaret sisteminden kim sorumludur?
- Asıl mesele, AI'nın programcının açıkça programlamadığı şeyleri yapabilmesidir.
 - Peki ne tür kararlar almalarına izin veriyoruz?
 - Bu çizgileri nasıl çizeceğiz?
 - Sistemlerin kendilerini güncellemelerine izin veriyor muyuz?
- Programcının kendi sisteminin zekasını sınırlama sorumluluğu var mı?

Yapay zeka ile ilgili bazı yanlış anlamalar

Yapay zeka evrimine başladığından beri birçok yanlış anlama var. Bu kavram yanlışlarından bazıları aşağıda verilmiştir:

- AI insana ve enerjiye ihtiyaç duymaz: AI hakkındaki ilk yanlış kanı, insana ihtiyaç duymamasıdır. Ancak gerçekte, AI tabanlı her sistem bir yerde insanlara bağımlıdır ve kalacaktır. Örneğin, veriler hakkında bilgi edinmek için insan tarafından toplanan verileri gerektirir.
- AI insanlar için tehlikelidir: AI insanlar için doğası gereği tehlikeli değildir ve yine de süper AI veya insanlardan daha zeki olan güçlü AI'ya ulaşılması riskler oluşturacaktır. Herhangi bir güçlü teknoloji, kötüye kullanılmadığı takdirde zararlı olamaz.
- AI zirve aşamasına ulaştı: Yine de, AI'nın zirve aşamasından çok uzayız. Zirveye ulaşmak için çok uzun bir yolculuk gerekecek.
- AI işinizi alacak: AI'nın işlerin çoğunu alacağı en büyük kafa karışıklıklarından biridir, ancak gerçekte bize yeni işler için daha fazla fırsat sunuyor. (Denizaltı keşifleri, maden ocakları; kanallar, enerji hatları, boru hatları...)
- AI yeni bir teknolojidir: Bazı insanlar bunun yeni bir teknoloji olduğunu düşünse de, bu teknoloji aslında ilk olarak 1840 yılında bir İngiliz gazetesi aracılığıyla düşünülmüştür.

2.3. Yapay zeka türleri

Yapay zeka, yeteneklere ve işlevlere göre farklı türlere ayrılabilir.

Yeteneklere Göre Yapay Zeka yaklaşımları:

- Uygulamalı yaklaşım
- Güçlü yaklaşım
- Zayıf yaklaşma

Gerçekten akıl yürütebilen ve sorunları çözebilen makineler oluşturmak için Güçlü yapay zeka yaklaşımı kullanılır. Zekiymiş gibi davranabilen ancak gerçekten akıl yürütemeyen ve sorunları çözemeyen bilgisayar tabanlı Yapay Zeka oluşturmakla zayıf yapay zeka yaklaşımı ilgilenir. Tcari olarak uygulanabilir "akıllı" sistemler oluşturmada Uygulamalı yapay zeka yaklaşımı kullanılır. Bilişsel yaklaşım, insan zihninin nasıl çalıştığıyla ilgili teorileri test etmek için bir bilgisayar kullanan yapay zeka yaklaşımıdır. Yüz Tanıma sistemi uygulamalı AI yaklaşımıdır.

Yapay zekada zayıf yaklaşım, akıllıca davranabilen ancak gerçekten akıl yürütemeyen veya sorunları çözemeyen bilgisayar tabanlı bir yapay zekanın geliştirilmesiyle ilgilidir. Bu yaklaşıma göre, uygun şekilde yapılandırılmış bilgisayarlar insan zekasını taklit edebilir.

Bir temel çizgi izleyen robot zayıf yaklaşım ilkesine dayanmaktadır. Zayıf AI, Bir bilgisayarda uygulanan zihinsel modelleri kullanarak zihinsel yetileri inceler.

- Zayıf AI veya Dar AI: Zayıf AI, zeka ile bazı özel görevleri yerine getirme yeteneğine sahiptir. Siri, Zayıf AI'nın bir örneğidir.
- Genel AI: Herhangi bir entelektüel görevi bir insan gibi verimlilikle gerçekleştirebilen akıllı makineler.
- Güçlü AI: İnsanlardan daha iyi olacak ve insan zekasını aşacak makineyi içeren varsayımsal bir kavramdır.

İşlevlere Göre:

- Reaktif Makineler: Tamamen reaktif makineler, AI'nın temel türleridir. Bunlar mevcut işlere odaklanır ve önceki işleri saklayamaz.
- Sınırlı Bellek: Adından da anlaşılacağı gibi, geçmiş verileri veya deneyimleri sınırlı bir süre boyunca saklayabilir. Kendi kendini süren araba, bu tür AI türlerine bir örnektir.
- Zihin Teorisi: Gerçek dünyada insan duygularını, insanları vb. anlayabilen gelişmiş yapay zekadır.
- Öz Farkındalık: Öz Farkındalık Yapay zeka, insanlara benzer kendi bilincine, duygularına sahip olacak Yapay Zekanın geleceğidir.

2.4. Yapay Zekada Modelleme

Turing testi, Yapay zeka alanındaki popüler zeka testlerinden biridir. Turing testi 1950 yılında Alan Turing tarafından tanıtıldı. **Bir makinenin insan gibi düşünüp düşünemeyeceğini belirlemek için yapılan bir testtir.** Bu teste göre, bir bilgisayarın yalnızca belirli koşullar altında insan tepkilerini taklit edebiliyorsa zeki olduğu söylenebilir.

Bu testte üç oyuncu yer alır, ilk oyuncu bilgisayar, ikinci oyuncu insan yanıtlayıcı ve üçüncü oyuncu insan sorgulayıcıdır ve sorgulayıcının sorulara dayanarak makineden hangi yanıtın geldiğini bulması gerekir ve cevaplar. **Makinenin zekasını test etmek için Turing testi değerlendirilmesi kullanılır.**

Bir makinenin zekasını test etmek için kullanılan değerlendirme

Yapay zekada (AI), Turing Testi, bir bilgisayarın insan gibi düşünüp düşünemeyeceğini belirlemek için bir araştırma yöntemidir.

Yapay zekada bilgisayarla görme

Bilgisayarla görme, bilgisayarları görsel dünyadan görüntüler gibi yorumlayabilmeleri ve bilgi alabilmeleri için eğitmek için kullanılan bir Yapay Zeka alanıdır. Bu nedenle, bilgisayarla görme, görüntü işleme, nesne algılama vb. gibi karmaşık sorunları çözmek için AI teknolojisini kullanır.

Yapay Zekada Kavram Oluşturma Mantığı

Yapay zekada kavram oluşturma mantığı, bazı mantıksal kuralları uygulayarak veri tabanından yeni bilgiler türeten akıllı bir sistemin parçasıdır. Esas olarak iki modda çalışır:

- **Geriye Zincirleme: Hedefle başlar ve hedefi destekleyen gerçekleri çıkarmak için geriye doğru ilerler.**
- **İleri Zincirleme: Bilinen gerçeklerle başlar ve yeni gerçekleri öne sürer.**

Yapay Zeka Modelleme Nedir?




Veri toplama ve veri hazırlamanın ardından, veri bilimindeki bir sonraki aşama, gelişmiş hesaplama yöntemlerini desteklemek için akıllı makine öğrenimi modellerinin oluşturulmasını içerir. Bu modeller, verilerdeki kalıpları tanımlamak ve insan uzmanlığını taklit edecek şekilde sonuçlar çıkarmak için doğrusal veya lojistik regresyon gibi çeşitli algoritma türlerini kullanır.

Kısacası, yapay zeka modelleme, üç temel adımı izleyen bir karar verme sürecinin oluşturulmasıdır:

- **Modelleme: İlk adım, verileri yorumlayan ve bu verilere göre kararlar veren algoritmaları kullanan bir yapay zeka modeli oluşturmaktır. Başarılı bir yapay zeka modeli, herhangi bir kullanım durumunda insan gibi otonom davranış geliştirebilir.**

- Yapay zeka model eğitimi: İkinci adım, yapay zeka modelini eğitmektir. Çoğu zaman eğitim, yinelemeli test döngülerinde yapay zeka modeli aracılığıyla büyük miktarda verinin işlenmesini ve modelin beklendiği ve istendiği gibi davrandığından emin olmak ve doğruluğu sağlamak için sonuçların kontrol edilmesini içerir.
- **Modellemede parametreler ve hiperparametreler bulunmaktadır.**
- **Parametreler, modelin öğrenerek belirlediği değerlerdir. Hiperparametreler ise insan uzmanlığının, tecrübesinin aktarıldığı kesin parametrelerdir ya da değer aralığıdır.**
- **Mühendisler** bu süreçte yapay zeka modeli öğrendikçe onu değiştirmek ve geliştirmek için yetenek kazanırlar. Bu aşamada simülasyon (Benzerini yazılımsal oluşturma) ve Optimizasyon (En iyileme – hassasiyet bulma) çalışmaları yapılır. Devasal bir veri yığınının küçük bir parçasından yazılımsal bir makine üretilir.
- Çıkarım: Üçüncü adım, çıkarım olarak bilinir. Bu adım, yapay zeka modelinin genellikle mevcut verilere dayanarak mantıksal sonuçlar çıkardığı gerçek dünyadaki kullanım durumuna açılmasını ifade eder.

2.5. Yapay Zekanın Alanları



AI'nın farklı alanları/Alt kümeleri

AI birçok alanı veya alt grubu kapsar ve bazı ana alanlar aşağıda verilmiştir: Mükemmel insan yok. Aslında varlar. Nerdeler? Mezarlıktalar... Mükemmel olma yolunda çaba sarfedenler var.

- Makine Öğrenimi
 - Derin Öğrenme
 - Sinir Ağı
 - Uzman Sistem
 - Bulanık Mantık
 - Doğal Dil İşleme
 - Robotik
 - Konuşma Tanıma.
-
- **Makine Öğrenimi:** Açıkça programlanmadan kendi kendilerine birkaç numara öğrenebilmeleri için bilgisayarları veri besleyerek harekete geçirme bilimidir.
 - **Sinir Ağları:** İnsan beynine göre modellenmiş bir dizi algoritma ve tekniktir. Sinir Ağları, karmaşık ve gelişmiş makine öğrenimi sorunlarını çözmek için tasarlanmıştır.
 - **Robotik:** Robotik, robotların farklı dallarını ve uygulamalarını içeren yapay zekanın bir alt kümesidir. Bu Robotlar, gerçek dünya ortamında hareket eden yapay etkenlerdir. Bir AI Robot, çevresindeki nesnelere algılayarak, öğrenerek, öğretilerek, hareket ettirerek ve ilgili eylemleri gerçekleştirerek manipüle ederek çalışır.
 - **Robot:** Algılayıcılar, aktüatörler (elektrik enerjisini mekanik enerjiye dönüştüren, piston, makara, elektrik motorlar), bilgisayar sistemi, ve yazılımlar
 - **Uzman Sistemler:** Bir uzman sistem, bir insanın karar verme yeteneğini taklit eden bir bilgisayar sistemidir. Belirli bir alanda uzman bilgi ve deneyime sahip bir insan

veya kuruluşun yargı ve davranışlarını simüle etmek için yapay zeka (AI) teknolojilerini kullanan bir bilgisayar programıdır.

- **Bulanık Mantık Sistemleri:** Bulanık mantık, modern bilgisayarın dayandığı olağan "doğru veya yanlış" (1 veya 0) boole mantığından ziyade "doğruluk derecelerine" dayalı bir hesaplama yaklaşımıdır. Bulanık mantık Sistemleri, kesin olmayan, bozuk, gürültülü giriş bilgilerini alabilir.
- **Doğal Dil İşleme:** Doğal Dil İşleme (NLP), sorunları çözmek için yararlı içgörüler elde etmek için doğal insan dilini analiz eden Yapay Zeka yöntemini ifade eder.

Yapay Zeka Alt Alanları

- Makine Çevirisi
 - Google Çeviri
- Spam Filtreleri
- Dijital Kişisel Asistanlar
 - siri
 - Google Asistan
 - Cortana
 - Alexa
- Oyun oyuncuları
 - Koyu mavi
 - AlphaGo
 - Video oyunlarında "Bilgisayar"
- Konuşma Tanıma Sistemleri
 - IBM
 - Dragon(Ejderha)
- Görüntü Tanıma Sistemleri
- Algoritmik Ticaret Sistemleri
 - Black-Scholes Modeli (1987'de kazaya neden oldu)
 - Otomatik Alım Satım Hizmetleri
- Tavsiye Sistemleri
 - Amazon'un Önerileri
 - Google Reklamları
- Otonom Araçlar
 - Sürücüsüz Arabalar

2.6. Yapay Zekada Etken Akıl Faktörü

Çevresini ve değişimleri sensörler aracılığıyla algılayan ve amacına ulaşmak için aktüatörleri kullanarak üzerinde hareket eden herhangi bir otonom makineye robot denir. Sonuçlar çıkarmak amacıyla hesaplamalı matematik, istatistik, olasılık ve makine öğrenimi tekniklerini kullanarak ham verileri analiz etme bilimine Veri Bilimi denir. Büyük miktarda veriyi analiz etmek ve onlardan bilgi elde etmek için otomatik yöntemler kullanmayı içeren bilim dalına Veri Bilimi denir. Kod nasıl yazılır, bir kod tabanı nasıl yönetilir, bir veritabanında nasıl veri depolanır gibi sorulara çözüm üreten veri bilimi alt dalına yazılım denir. Veriler üzerinde kullanılan farklı teknikler: regresyonlar, kümeleme algoritmaları, zaman serisi modelleri geliştiren veri bilimi alt dalına İstatistiksel Matematik denir. Tahmine dayalı analitiğin bir devamı olan, yapılandırılmış veya yapılandırılmamış büyük veri hacimlerinden bilginin çıkarılmasına Bilgi keşfi ve veri madenciliği denir. Python, Java Script, C++ programlama dillerini öğrendikten sonra veri hazırlama sürecinde makine öğrenmesi algoritmalarını çok iyi öğrenen bir bilgisayar mühendisinden Makine Öğrenmesi uzmanı olur.

Algoritma, bir problemin detaylandırılmış çözüm adımlarının talimatlandırılmasıdır. Algoritma, bilgisayara adım adım tam olarak neyi, nasıl yapacağı söyler. Akıllı algoritma, verilerden bilgiye, bilgiden bilgiğe ve bilgeliğe ve bilgeliğe eyleme ya da karar vermeye dönüşüm adımlarından oluşur.

Oyun oynama programlarında öğrenme elemanı için lineer ağırlıklı polinom kullanılmaktadır. Hipotez uzayı gerçek fonksiyonu içeriyorsa, bir öğrenme problemi gerçekleştirilebilir. Doğru mudur. Karar ağacı, bir dizi özellik tarafından tanımlanan bir nesne olarak girdi alır ve bir karar verir. Bir karar ağacı, bir dizi test gerçekleştirerek kararını verir. Yapay zekada görev ortamları bir problem oluşturacak ve rasyonel etmen bu problemin çözümünü bulacaktır.

Görev ortamında PEAS açıklaması nedir? Performans, Çevre, Aktüatörler, Sensörler (PEAS: Performance, Environment, Actuators, Sensors)

Yapay zekada Deterministik ortam stratejiktir. Bulmaca nasıl statik ortamdır. Stokastik davranış rasyoneldir çünkü öngörülebilirlik tuzağından kaçınır. Yarı dinamik ortam zamanın geçmesiyle değişmez, ancak etken faktörün performansı değişir

Öğrenen sistemin performansını etkileyen faktörler:

- Kullanılan temsil şeması
- Eğitim senaryosu
- Geri bildirim türü

Akıllı faktörü, çevresini ve değişimleri sensörler aracılığıyla algılayan ve amacına ulaşmak için aktüatörleri kullanarak üzerinde hareket eden otonom makinelere akıllı robotlar denir.

AI'daki bu Akıllı robotlar aşağıdaki uygulamalarda kullanılır:

- Arama motoru gibi bilgi erişimi ve gezinmeler
- Tekrarlayan faaliyetlerden kimlik belirleme
- Alan uzmanları
- Sohbet robotları vb.

Yapay Zeka "Agent: Etken faktör"ün işlevi, kurallar dizisinin bir eylemle eşleştirilmesidir. Yapay zekanın etken faktörü, çevresini sensörler aracılığıyla algılar ve harekete geçiriciler aracılığıyla bu ortama göre hareket eder. Bir makine kendi kendine dış ortama göre hareket yönünü değiştirebiliyorsa bu makineye otonom denir. Bir yapay zeka etken faktörü, Sensörleri ve Aktüatörleri kullanarak ortamı algılar ve ona göre hareket eder. Sensörler ile çevreyi algılar ve Aktüatörler ile ona göre hareket eder. Sensör, değişiklikleri algılamak için fiziksel ortamdan sinyaller alan bir cihazdır. Makinelerde fiziksel bir işlevi yerine getirmek için enerjiyi bir biçimden diğerine dönüştürmek için Aktüatörler kullanılır.

Yapay zeka etken faktörüne örnekler:

- Otonom Uzay Aracı
- İnsan
- robot

Yapay zeka "etken faktör",

- Çevreden girdi alır ve zekasını kullanır ve istenilen işlemleri gerçekleştirir.
- Çizgi izleyen robotu kontrol eden gömülü bir program
- Çevresini sensörler aracılığıyla algılar ve harekete geçiriciler aracılığıyla bu ortama göre hareket eder.

Öğrenme, yapay zeka etken faktörünün performansını artırabilir. Bir yapay zeka etken faktörü, önceki durumları kaydederek ve gelecekte tekrar meydana gelirse aynı duruma daha iyi yanıt vererek önceki durumları öğrenir. Bu nedenle, öğrenme bir yapay zeka etken faktörünün performansını artırabilir. Hem Program hem de Mimari yapay zeka etken faktör bileşimidir.

Yapay zekada insan etken faktör olarak kabul edilebilir. Sensörler arasında gözler, kulaklar, deri,koku ve tat parçaçıkları vb. bulunurken, efektörler arasında eller, parmaklar, bacaklar ve ağız bulunur. Etkenler robotlardır. Robotlardaki sensörler bir kamera, sonar, kızılötesi, tampon vb. içerebilir. Aktüatörler kışkaçları, tekerlekleri, ışıkları, hoparlörleri ve diğer bileşenleri içerebilir. Otonom uzay aracı, duyularına dayanarak kendi kararlarını verir.

Oyun oynama, planlama ve çizelgeleme, teşhis Yapay Zeka uygulamasının bir açılımıdır.

Yapay zeka son günlerde tüm kritik alt yapılarındaki otomasyon sistemlerinde farklı şekillerde kullanılmaktadır. Bunun için zeka ve otomasyon gerekir.

Yapay zeka etken faktörü, çevreyi algılamak ve ona göre hareket etmek için sensörler ve aktüatörler kullanan herhangi bir şey olarak tanımlanır. Sensörler aracılığıyla çevresinden bilgi alır, işlemleri yürütür ve aktüatörler aracılığıyla çıktılar verir.

Makinelerin belirsiz bilgileri insan sezgisini taklit eden bir ustalıkla ele almasını sağlayan Yapay Zekanın adı Bulanık mantıktır.

Mikrodalga fırınlar, arabalar ve masaüstü PC'ler için takılabilir devre kartları gibi pek çok popüler ürün, Yapay Zekanın yaygın olarak kullanılan ilk ticari biçimini kullanır. Yapay zeka robotların belirsiz verileri insan sezgisine benzeyen bir el becerisiyle işlemlerini sağlar.

ILP (Endüktif mantık programlama), yapay zekanın bir alt alanıdır. Çünkü ILP, bilimsel deney döngüsüne katılabilir, böylece esnek bir yapı üretebilir.

Bayes ağı ne sağlar? Etki alanını tam açıklamasını yapar.

Yapay zekada : İki tür ölçüm vardır. Bunlar: Evrensel, varoluşsalıdır.

Aşağıdakilerden hangisi yapay zekanın fikridir?

- Algı
- İnsan-Yapay Zeka Etkileşimi
- Toplumsal Etki

Etken faktör dünya ile etkileşimlerini ve kendi karar verme sürecini gözlemledikçe öğrenme gerçekleşecektir. Öğrenme unsuru performans unsurunu daha iyi karar verecek şekilde değiştirir. Yapay zekada bir öğrenme ögesinin tasarımından etkilenen üç ana konu; bileşenler, geri bildirim ve temsildir. Öğrenme probleminin doğasını belirlemede Geribildirim kullanılır.

Hipotez dilinin ifade gücü ile öğrenme kolaylığı arasında bir denge vardır.

Tutarlı hipotez örneklerle gider, Hipotez negatif olması gerektiğini söylüyor ama pozitif bulaşıyorsa, yanlış negatiftir. Bir hipotez pozitif olması gerektiğini söylüyorsa, ama aslında negatifse, yanlış pozitiftir. Özel bir hipotezde, belirli kısıtlayıcı veya özel koşullara sahip olması gerekir.

3. Makine Öğrenmesi

Makine öğrenimi, elle kodlanmış kurallar yerine verileri kullanarak görevlerin nasıl gerçekleştirileceğini öğrenmek için bir makine öğrenimi modelini eğiten algoritmalarla ilgilidir. Bu görevler genellikle sınıflandırmayı (yani bir resimde ne olduğunu belirlemeyi), tahmin etmeyi (yani bu kullanıcının izlemesi en muhtemel Netflix'in gösterdiği şey), karar vermeyi (yani bu otonom araba dönmeli mi) veya veri oluşturmayı (yani insan konuşma sentezini) içerir.

Makine öğrenimi verileri çoğunlukla girdi-etiket çiftleri (x, y) biçimini alır; burada x , bir makine öğrenimi modelinin girdisidir ve y , etiket veya beklenen çıktıdır. x tipik olarak çok boyutlu bir vektördür. Girdi vektörünün her elemanına özellik denir. Örneğin, bir görüntü sınıflandırma problemi için, x , RGB değerlerine sahip bir görüntü bitmap'i ve y görüntünün içeriğidir (ör. "kedi"). Bir makine çevirisi probleminde, x İngilizce bir cümle ve y İspanyolca bir cümle olabilir.

Veriler genellikle üç bölüme ayrılır: eğitim verileri, doğrulama/geliştirme verileri ve test verileri. Eğitim verileri, modeli eğitmek için kullanılır, doğrulama verileri, model ayarlama amacıyla daha önce görülmemiş veriler üzerinde modelin performansını değerlendirmek için kullanılır ve test verileri, tamamen yeni verilerle nihai bir performans değerlendirmesi için kullanılır. Çok fazla verinin olmadığı durumlarda, genellikle eğitim verileri üzerinde çapraz doğrulama yoluyla gerçekleştirilen doğrulama ile sadece bir eğitim/test ayrımı vardır.

Makine Öğrenimi Modelleri

Yüksek düzeyde, bir makine öğrenimi modeli parametreleştirilmiş bir fonksiyon olarak düşünülebilir $\hat{y} = f(x, \theta)$ burada x giriş verileridir, θ modelden modele değişen bir parametreler kümesidir ve \hat{y} tahmin edilendir çıktı. Örneğin, basit bir doğruya uydurma modelinde, parametreler doğrunun eğimi ve kesişimi olacaktır. Bir sinir ağında, parametreler ağın tüm ağırlıklarıdır. O halde makine öğreniminin amacı, $f(x, \theta)$ istenen sonucu y verecek şekilde θ 'yi bulmaktır. Sorun şu ki, θ genellikle yüksek boyutlu ve süreklidir, bu da ayrıntılı aramayı zorlaştırır. Bunun yerine, tahmin edilen etiketler ile gerçek etiketler arasındaki hatayı en aza indirmek için optimizasyon tekniklerini kullanarak yinelemeli olarak θ hesaplıyoruz.

Klasik makine öğrenimi modelleri, regresyon modellerini, destek vektör makinelerini ve Bayes modellerini içerir. Bir model seçmek, çalışma süresi, gereken veri miktarı ve modelin performansı dahil olmak üzere bir dizi takasın dikkate alınmasını içerir. Ek olarak, modeller genellikle verilerin temel yapısı hakkında varsayımlarda bulunur ve bu varsayımlar doğru değilse modelin performansını etkileyebilir. Örneğin saf Bayes sınıflandırıcısı girdi özelliklerinin birbirinden bağımsız olduğunu varsayar.

Nöral ağlar

Sinir ağları, makine öğreniminin balyozlarıdır. Son derece güçlüler, ancak aynı zamanda çok fazla bilgi işlem gücü ve eğitim verisi gerektiriyorlar. Sinir ağları, daha güçlü donanımların geliştirilmesi ve büyük verilerin yükselişi nedeniyle ancak son birkaç yılda uygulanabilir hale geldi. Sinir ağları, bir nöronun ancak girdilerinin kombinasyonu bir eşiğe ulaştıktan sonra ateşlendiği biyolojik nöronların ateşleme mekanizmasından esinlenmiştir. Bununla birlikte, bir beyindeki nöronların her yerde bağlantılarla kaotik bir şekilde düzenlendiği yerde, bir sinir ağındaki nöronlar tipik olarak, bir katmandaki tüm nöronların bir sonraki katmandaki tüm nöronlara bağlandığı bir dizi katman halinde düzenlenir.

Bu düzenleme ileri beslemeli ağ veya tam bağlantılı ağ olarak bilinir. Bir nöronun "ateşlenmesi", nörona yapılan girdiler üzerinden ağırlıklı bir toplam alınarak ve ardından ağırlıklı toplama doğrusal olmayan bir fonksiyon uygulanarak hesaplanır.

Farklı uygulamalar için sinir ağlarının başka düzenlemeleri mevcuttur. Görüntü işleme görevleri genellikle, aktivasyonların 2B görüntü boyunca bir $n \times n$ evrişimli filtre kaydırılarak hesaplandığı bir evrişimli ağ içerir. Bu, genellikle görüntü işlemenin büyük bir parçası olan uzamsal bilgiyi koruma avantajına sahiptir. Makine çevirisi ve doğal dil anlama gibi dil işleme görevleri, ağın bir girdi sırasını işlerken güncellenen dahili bir durumu koruduğu tekrarlayan sinir ağlarını kullanır. Bu, ağın bir cümledeki kelimelerin sıralaması gibi zamansal bilgileri korumasına izin verir.

Makine Öğreniminin Kısıtlamaları

Makine öğrenimi, bol miktarda temsili verinin olduğu, görevin iyi tanımlanmış girdi ve çıktılara sahip olduğu ve modelin tahminlerindeki hatayı belirlemenin ölçülebilir bir yolunun olduğu uygulamalar için çok uygundur. Bu koşullardan herhangi biri karşılanmazsa, modelin performansı düşecektir.

Temsili veriler, modelin üzerinde eğitildiği ve değerlendirildiği verilerin, vahşi doğada görüleceği verilere benzer olduğu anlamına gelir. Örneğin, Amerikan İngilizcesi ile eğitilmiş bir konuşma tanıma sistemi, ağır bir İskoç aksanıyla karşı karşıya kaldığında büyük olasılıkla zorlanacaktır. Fotoğraflardaki nesnelere tanıma için eğitilmiş bir görüntü sınıflandırma sistemi, elle çizilmiş resimlerde çok kötü performans gösterir. Kötü bir veri kümesi kaçınılmaz olarak kötü bir model oluşturacağından, yeterli veri toplamak genellikle makine öğreniminin en çok zaman alan ve pahalı kısımlarından biridir.

İyi tanımlanmış bir görev, girdilerin ve çıktılarının yapısının bilindiği anlamına gelir. Örneğin otonom bir sürüş durumunda, girdiler sensör okumalarıdır ve çıktılar aracın kontrolleridir. Bir görüntü yerleştirme probleminde, girdiler görüntülerdir ve çıktılar, ilgilenilen nesnelere etrafındaki sınırlayıcı kutulardır. Buna karşılık, "Hükümet politikasına karar verin" gibi bir görev, olası politikaların alanı hem belirsiz hem de sonsuz derecede geniş

olduğundan, iyi tanımlanmamıştır. Makine öğrenimindeki diğer bir zorluk, genel problemlerin belirli, iyi tanımlanmış görevlere dönüştürülmesidir.

Son olarak, ölçülebilir hata önemlidir, çünkü makine öğrenimi modelleri bazı hata ölçümlerinde optimizasyon yoluyla eğitilir. Örneğin regresyonda bu hata tahmin edilen değer ile gerçek değer arasındaki farktır. Sınıflandırmada, çeşitli hata ölçütleri mevcuttur, ancak bunların tümü yanlış sınıflı seçmeyi cezalandırmayı içerir. Öte yandan, sübjektif muhakeme veya yaratıcılık içeren görevler genellikle ölçülebilir değildir. Örneğin, “Bir resim çiz” görevi verildiğinde, çıktının ne kadar “resim-y” olduğu nasıl belirlenir?

3.1. Makine Öğrenimi türleri

Öğrenme sisteminin bileşenleri:

- Hedef
- Model
- Öğrenme kuralları

Hedef, model, öğrenme kuralları ve deneyim, öğrenme sisteminin bileşenleridir.

Yerellik: Mantıksal sistemlerde, ne zaman $A \Rightarrow B$ şeklinde bir kuralımız olsa, A kanıtı verildiğinde, diğer kurallar hakkında endişelenmeden B sonucuna varabiliriz.

Ayırma: Bir B önermesi için mantıksal bir kanıt bulunduğunda, önerme nasıl türetildiğine bakılmaksızın kullanılabilir. Yani, gerekçesinden ayrılma olabilir.

Doğruluk-işlevsellik: Mantıkta, karmaşık cümlelerin doğruluğu, bileşenlerin doğruluğundan hesaplanabilir. Ancak, Kural tabanlı bir sistemde hiçbir Ek özelliği yoktur. Global nitelik, belirli bir problem alanını kullanıcıya özel olarak tanımlar ve kullanıcının problem planına göre değişir.

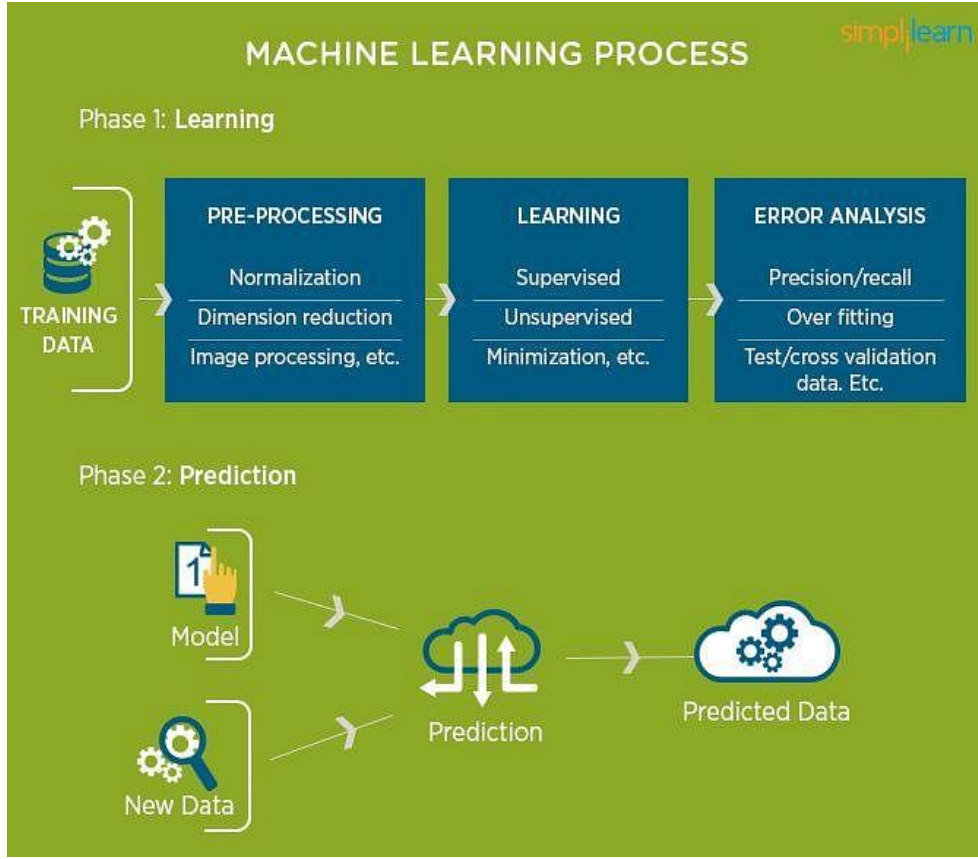
Tümevarımsal öğrenme, örneklerle uyuşan tutarlı bir hipotez bulmayı içerir. Görevin zorluğu seçilen etkin faktöre bağlıdır.

Hesaplamalı öğrenme teorisi, tümevarımsal öğrenmenin örnek karmaşıklığını ve hesaplamalı karmaşıklığını analiz eder.

Makine Öğrenimi Neden Önemli?

"Makine öğrenimi nedir?" sorusunu daha iyi yanıtlamak ve Makine Öğreniminin kullanımlarını anlamak için, Makine Öğreniminin bazı uygulamalarını göz önünde bulundurun: kendi kendini süren Google arabası, siber dolandırıcılık tespiti ve Facebook, Netflix ve Amazon'dan çevrimiçi öneri motorları. . Makineler, doğru sonuçlar elde etmek için yararlı bilgi parçalarını filtreleyerek ve bunları kalıplara göre bir araya getirerek tüm bunları mümkün kılar.

Burada gösterilen süreç akışı, Makine Öğreniminin nasıl çalıştığını gösterir:



Makine Öğrenimindeki (ML) hızlı evrim, kullanım durumlarında, taleplerde ve modern yaşamda ML'nin tam öneminde müteakip bir artışa neden oldu. Büyük Veri de son birkaç yılda çok kullanılan bir moda kelime haline geldi. Bu, kısmen, büyük Veri parçalarının analizini sağlayan Makine Öğreniminin artan karmaşıklığından kaynaklanmaktadır. Makine Öğrenimi, genel yöntemleri/algortmaları otomatikleştirerek veri çıkarma ve yorumlama şeklini de değiştirdi ve böylece geleneksel istatistiksel tekniklerin yerini aldı.

Makine Öğreniminin Temel Kullanımları

Makine öğrenimi uygulamalarından elde edilen tipik sonuçlar genellikle web arama sonuçlarını, web sayfalarında ve mobil cihazlarda gerçek zamanlı reklamları, e-posta spam filtrelemesini, ağa izinsiz giriş algılamayı ve desen ve görüntü tanımayı içerir. Tüm bunlar, büyük hacimli verileri analiz etmek için makine öğrenimi kullanmanın yan ürünleridir.

Geleneksel olarak, veri analizi, büyük, heterojen veri kümelerinin yükselişi sayesinde giderek pratik olmayan bir yaklaşım olan deneme yanılma temelli idi. Makine öğrenimi, büyük ölçekli veri analizi için akıllı alternatifler sağlar. Makine öğrenimi, gerçek zamanlı veri işleme için hızlı ve verimli algortmalar ve veriye dayalı modeller geliştirerek doğru sonuçlar ve analizler üretebilir.

Marketwatch'a göre, küresel makine öğrenimi pazarının 2017-2025 döneminde yüzde 45,9'un üzerinde sağlıklı bir oranda büyümesi bekleniyor. Bu eğilim devam ederse, dünya

çapında geniş bir endüstri yelpazesinde makine öğreniminin daha fazla kullanıldığını göreceğiz. Makine öğrenimi kalıcıdır!

Hangi Makine Öğrenimi Algoritmasını Kullanacağınıza Nasıl Karar Veriyorsunuz?

Aralarından seçim yapabileceğiniz 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?

Tamamen popülerliğe dayalı seçeneklere bakıyorsanız, Matlab, Python, Java Script mevcut birçok kitaplığın yanı sıra yaygın destek sayesinde başını sallar. Veri analizi ve veri madenciliği için idealdir ve birçok algoritmayı (sınıflandırma, kümeleme, regresyon ve boyut azaltma için) ve makine öğrenimi modellerini destekler.

Makine öğrenimi operasyonları (MLOps), Yapay Zeka model tesliminin disiplinidir. Kuruluşların daha hızlı sonuçlar elde etmek için üretim kapasitesini ölçeklendirmesine yardımcı olur ve böylece hayati iş değeri üretir.

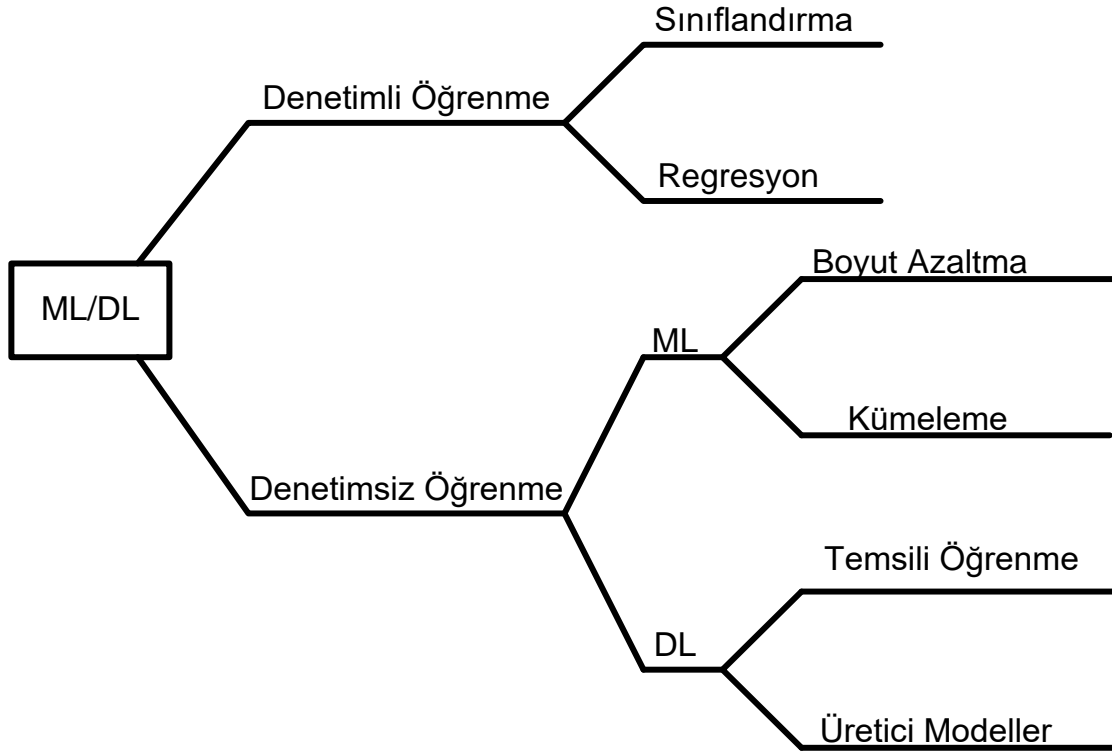
Makine Öğrenimi (ML) için Ön Koşullar

Makine Öğreniminin ötesinde öğrenmeye ilgi duyanlar için, bu alanda başarılı olmak için birkaç gereksinimin karşılanması gerekir. Bu gereksinimler şunları içerir:

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

Makine öğrenimi modeli nedir?

Bir makine öğrenimi modeli, makine öğrenimiyle ilgili görevleri işleme koyan bir soru ya da yanıtlama sistemidir. *İş sonuçlarını iyileştirmek için değerli içgörüler toplamak, etkin olan parametreleri belirlemek için verileri kullanmayı amaçlar.*



Makine Öğrenimi karmaşıktır, bu nedenle denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki ana alana ayrılmıştır. Her birinin belirli bir amacı ve eylemi vardır, sonuçlar verir ve çeşitli veri biçimlerini kullanır. Makine öğreniminin yaklaşık yüzde 70'i denetimli öğrenmedir, denetimsiz öğrenme ise yüzde 10 ila 20 arasında herhangi bir yeri oluşturur. Geri kalan kısım pekiştirmeli öğrenme ile alınır.

Makine Öğrenimi temel olarak üç türe ayrılabilir:

- **Denetimli Öğrenme:** Denetimli öğrenme, makinenin verilerden öğrenmek için harici denetime ihtiyaç duyduğu bir tür Makine öğrenimidir. **Denetimli öğrenme modelleri, etiketli veri kümesi kullanılarak eğitilir.** Regresyon ve Sınıflandırma, denetimli makine öğrenimi modelleridir. Regresyon matematiksel ifadelerin katsayılarının belirlenmesine dayanır.
- **Denetimsiz Öğrenme:** Makinenin verilerden öğrenmek için herhangi bir dış denetime ihtiyaç duymadığı bir makine öğrenmesi türüdür, dolayısıyla denetimsiz öğrenme olarak adlandırılır. **Denetimsiz modeller, etiketlenmemiş veri kümesi kullanılarak eğitilebilir.** Bunlar, ilişkilendirme ve Kümeleme problemlerini çözmek için kullanılır.
- **Takviyeli Öğrenme:** Takviyeli öğrenmede, bir etmen, eylemler üreterek çevresiyle etkileşime girer ve geri bildirim yardımıyla (optimizasyon) öğrenir. Geri bildirim, temsilciye ödül şeklinde verilir, örneğin her iyi eylem için olumlu bir ödül alır ve her kötü eylem için olumsuz bir ödül alır. Temsilciye sağlanan herhangi bir denetim yoktur. Takviyeli öğrenmede Q-Learning algoritması kullanılır.

Otomatik araçta, görüntü girdileri seti ve ilgili eylemler öğrenmeye açıktır, bu nedenle bu, denetimli öğrenmeye bir örnektir. Aktif öğrenmede, sadece öğretmen değil, öğrenen de performansı artırmak için uygun algı-eylem çifti örneklerini sorabilir.

Denetimli, denetimsiz ve takviyeli olmak üzere üç tür makine öğrenimi vardır:

Veriler bir etiket olmadan geliyorsa ve verilerdeki kalıplar ve öngörüler keşfedilmek isteniyorsa, yapısal veri bağlantıları keşfedilmesi için pekiştirmeli eğitim modeli kullanılır. Takviyeli öğrenmede öğretene ödül ve ceza verir

Denetimli öğrenme, veri yığnında nesnelere temel özellikleri bulunmaktadır. Denetimli öğrenme veya örüntü sınıflandırması, nesne tanımayı incelemek için bir çerçeve sağlar.

Denetimsiz öğrenme sorunu, belirli bir çıktı değeri sağlanmadığında girdideki öğrenme modellerini içerir. Belirli çıktının sonucunu test etmesi beklenmez. Burada etken faktör hangi sistemin çıkacağına farkında olmadığı için ne yapacağını bilemez. Bu duruma belirsiz bir önerilmemiş durum diyebiliriz. Denetimsiz öğrenme keşfederek öğrenme olarak da adlandırılır. Öğretmen bulunmadığında denetimsiz öğrenme olarak da adlandırılır.

Denetimsiz Öğrenme

Öğrenme algoritmasına hiçbir etiket verilmez ve girdisinde yapı bulmak için tek başına bırakılır. Denetimsiz öğrenme kendi içinde bir hedef (verilerdeki gizli kalıpları keşfetme) veya bir sona doğru bir araç (özellik öğrenme) olabilir.

- k-means clustering
- t-SNE (t-Distributed Stochastic Neighbor Embedding)
- PCA (Principal Component Analysis)
- Association rule

Makine öğrenmesi türleri, yaklaşımlarına, girdikleri ve çıktıkları veri türlerine ve çözmeleri amaçlanan görev veya sorun türlerine göre farklılık gösterirler.

- Denetimli Öğrenme (Supervised Learning Algorithms)
- Denetimsiz Öğrenme (Unsupervised Learning Algorithms)
- Yarı denetimli Öğrenme
- Takviye Öğrenme
- Transdüksiyon
- Öğrenmeyi öğrenmek

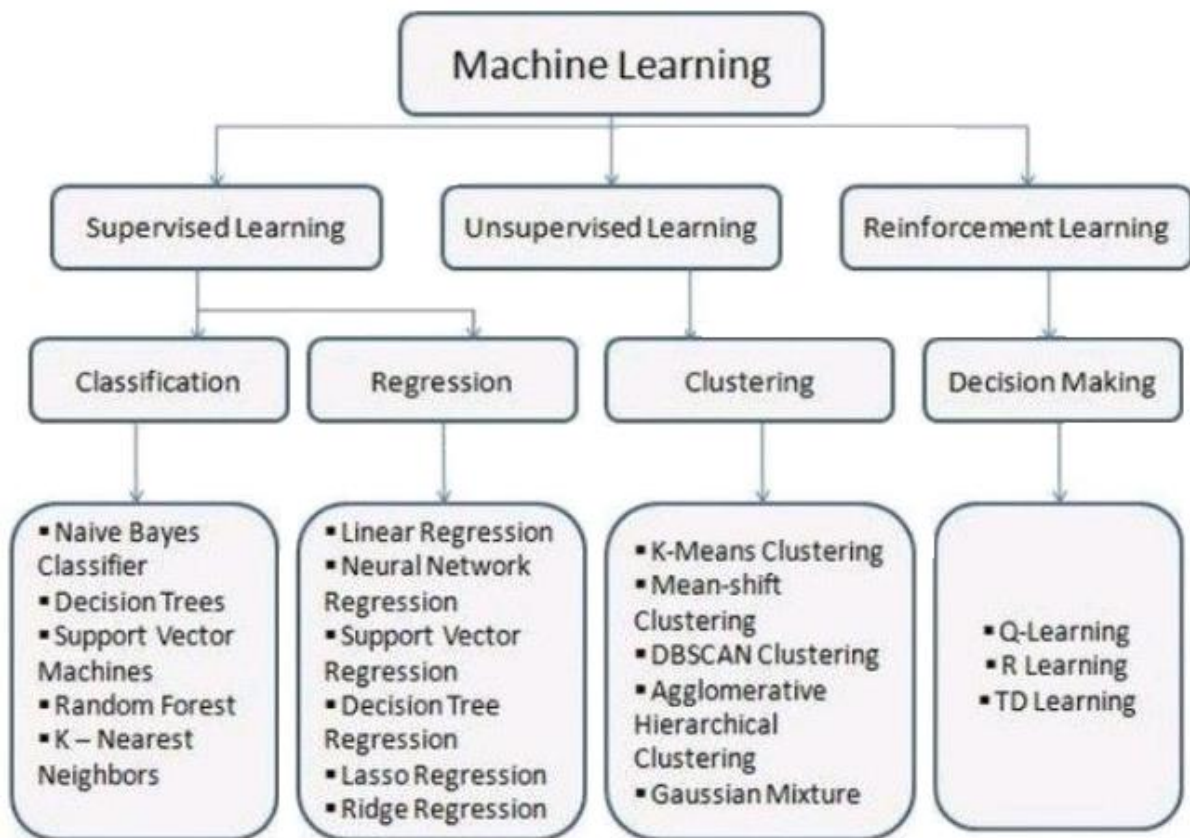
Genellikle, makine öğrenimi yöntemleri iki aşamaya ayrılır:

- 1) Eğitim modeli: Verilerin bir koleksiyonundan öğrenilir.
- 2) Uygulama modeli: Yeni test verileri hakkında kararlar almak için kullanılır.

Makine öğrenimi türlerinden bazıları şunlardır:

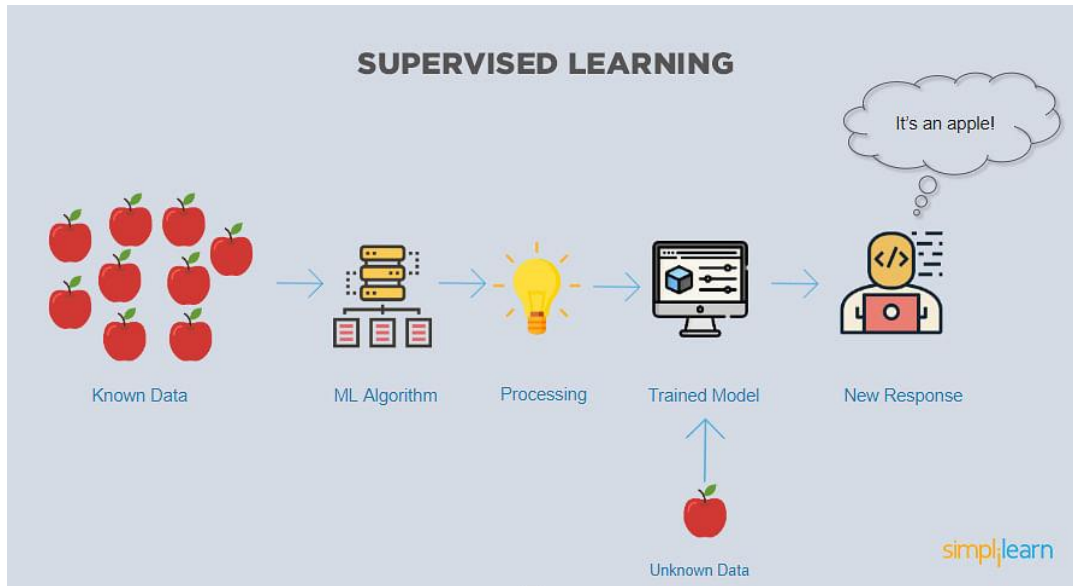
- Eğitim verilerinin doğru yanıtlarla etiketlendiği denetimli öğrenim. En yaygın iki denetimli öğrenme türü, sınıflandırma ve regresyondur.
- Analiz etmek ve keşfetmek istediğimiz kalıpları, etiketlenmemiş verilerden oluşan bir koleksiyondan öğrenen denetimsiz öğrenme. En önemli iki örnek, boyut küçültme ve kümelenmedir.
- 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 edileceğini ve diğerlerini belirlenmesi gerekir.



3.1.1. Denetimli Öğrenme

Denetimli öğrenmede, eğitim verileri için bilinen veya etiketlenmiş verileri kullanırız. Veriler bilindiği için, öğrenme denetlenir, yani başarılı uygulamaya yönlendirilir. Girdi verileri, Makine Öğrenimi algoritmasından geçer ve modeli eğitmek için kullanılır. Model, bilinen verilere göre eğitildikten sonra, bilinmeyen verileri modelde kullanabilir ve yeni bir yanıt alabilirsiniz.



Bu durumda model, verinin elma mı yoksa başka bir meyve mi olduğunu anlamaya çalışır. Model iyi eğitildikten sonra, verinin bir elma olduğunu belirleyecek ve istenen yanıtı verecektir.

Şu anda denetimli öğrenme için kullanılan en iyi algoritmaların listesi şunlardır:

- Polinom regresyonu
- Rastgele orman
- Doğrusal regresyon
- Lojistik regresyon
- Karar ağaçları
- K-en yakın komşular
- Naive Bayes

Denetimli öğrenme, etiketli eğitim verilerinden bir fonksiyon 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 ayırılır: 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 maskeleyme ve diğerlerini içerir.

Denetimli Öğrenmenin işlevleri:

- Sınıflandırmalar
- Regresyon


Denetimli öğrenmeye yönelik standart yaklaşım, örnek setini eğitim seti ve teste bölmektir. Makine öğrenimi gibi bilgi biliminin çeşitli alanlarında, "Eğitim Seti" olarak bilinen potansiyel olarak öngörücü ilişkiyi keşfetmek için bir dizi veri kullanılır. Eğitim seti öğrenen algoritmaya verilen bir örnektir, Test seti ise öğrenci tarafından oluşturulan hipotezlerin doğruluğunu test etmek için kullanılır ve öğrenen algoritmalarından saklanan bir örnek setidir. Eğitim seti, test setinden farklıdır.

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.

Denetimli öğrenmenin ne olduğunu anlamak için bir örnek kullanacağız. Örneğin, 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.

Çocuğa hayvanları nasıl ayırt edeceğini öğretiriz, bu denetimli 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 eğitilmiş 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

Bilgisayar, bir "öğretmen" tarafından verilen örnek girişler ve istenen çıktıları ile sunulur ve amaç, girdileri çıktılarıyla eşleyen genel bir kural öğrenmektir.

Denetimli öğrenme algoritmaları, hem girdileri hem de istenen çıktıları içeren bir veri kümesinin matematiksel bir modelini oluşturur. Veriler, öğrenen verileri olarak bilinir ve bir dizi öğrenme örneğinden oluşur. Her öğrenme örneğinde, denetim sinyali olarak da bilinen bir veya daha fazla giriş ve istenen çıkış bulunur. Matematiksel modelde, her öğrenme örneği bazen özellik vektörü olarak adlandırılan bir dizi veya vektörle temsil edilir ve öğrenme verileri bir matrisle temsil edilir. Nesnel bir fonksiyonun yinelemeli optimizasyonu yoluyla, denetimli öğrenme algoritmaları yeni girdilerle ilişkili çıktıyı tahmin etmek için kullanılabilir bir işlevi öğrenir. Optimal bir fonksiyon, algoritmanın egzersiz verilerinin bir parçası olmayan girişler için çıkışı doğru bir şekilde belirlemesine izin verecektir. Zaman içinde çıktıların veya tahminlerinin doğruluğunu arttıran bir algoritmanın bu görevi yerine getirmeyi öğrendiği söylenir.

Denetimli öğrenme algoritması türleri sınıflandırma ve regresyonu içerir. Sınıflandırma algoritmaları, çıktılar sınırlı bir değer kümesiyle sınırlandığında ve regresyon algoritmaları, çıktılar bir aralık içinde herhangi bir sayısal değere sahip olduğunda kullanılır. Örnek olarak, e-postaları filtreleyen bir sınıflandırma algoritması için girdi gelen bir e-posta olur ve çıktı da e-postanın dosyalanacağı klasörün adı olur.

Benzerlik öğrenme, regresyon ve sınıflandırma ile yakından ilişkili olan denetimli bir makine öğrenmesi alanıdır, ancak amaç iki nesnenin ne kadar benzer veya ilişkili olduğunu ölçen bir benzerlik işlevi kullanan örneklerden öğrenmektir. Sıralama, öneri sistemleri, görsel kimlik takibi, yüz doğrulaması ve konuşmacı doğrulaması gibi uygulamaları vardır.

Denetimli Öğrenmede iyi olasılıkları tahmin etmek için kullanılan iki yöntem şunlardır:

- Platt Kalibrasyonu
- İzotonik Regresyon


Bu yöntemler ikili sınıflandırma için tasarlanmıştır ve önemsiz değildir.

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

3.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenmede, eğitim verileri bilinmez ve etiketlenmez - bu, daha önce hiç kimsenin verilere bakmadığı anlamına gelir. Bilinen verilerin yönü olmadan girdi, denetimsiz terimin kaynaklandığı algoritmaya yönlendirilemez. Bu veriler Makine Öğrenimi algoritmasına beslenir ve modeli eğitmek için kullanılır. Eğitilen model, bir model aramaya ve istenen yanıtı vermeye çalışır. Bu durumda, genellikle algoritma, Enigma makinesi gibi kodu kırmaya çalışıyor, ancak insan zihni doğrudan dahil değil, daha çok bir makine gibi.



Bu durumda bilinmeyen veriler birbirine benzeyen elma ve armutlardan oluşmaktadır. Eğitilmiş model, benzer gruplarda aynı şeyleri elde edebilmemiz için hepsini bir araya getirmeye çalışır.

Şu anda denetimsiz öğrenme için kullanılan en iyi 7 algoritma şunlardır:

- Kısmi en küçük kareler
- Bulanık araçlar
- Tekil değer ayrıştırması
- K-ortalama kümeleme
- Önsel
- Hiyerarşik kümeleme
- Temel bileşenler Analizi

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.

3.1.3. Pekiştirmeli (Takvyeli) Öğrenme

Geleneksel veri analizi türleri gibi, burada da algoritma bir deneme yanılma süreci yoluyla verileri keşfeder ve ardından hangi eylemin daha yüksek ödüllerle sonuçlanacağına karar verir. 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.

Denetimsiz öğrenme algoritmaları, yalnızca girdileri içeren bir veri yığını alır ve verileri yapısal olarak gruplar veya kümeler. Bu nedenle algoritmalar, etiketlenmemiş, sınıflandırılmamış veya kategorize edilmemiş test verilerinden öğrenilir. Geri bildirim yanıt vermek yerine, denetimsiz öğrenme algoritmaları verilerdeki ortaklıkları 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 öğrenme, veri özelliklerini özetleme ve açıklamayı içeren diğer alanları kapsar.

Denetimsiz Öğrenmenin işlevleri:

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

Elmalardan oluşan torbayı taşıyan robotun taşıdığı torba parçalanır ve tüm elmalar (Çürük, büyük, küçük, ort boy, ...) birbirine karışır. Robot, topladığı elmaları önceden

etiketlemediğinden hemen ayrıştırılmaz. Tek başına farklılıkları öğrenerek ayrıştırma işleme yapar. Bu örnekteki robotta hangi öğrenme algoritması bulunmaktadır.

Küme analizi, bir grup gözlemin alt kümeler (kümeler olarak adlandırılır) atanmasıdır, böylece aynı kümedeki gözlemler önceden belirlenmiş bir veya daha fazla kritere göre benzerken, farklı kümelerden alınan gözlemler farklıdır. Farklı kümeleme teknikleri, genellikle bazı benzerlik ölçütleri ile tanımlanan ve örneğin iç kompaktlık veya aynı kümenin üyeleri arasındaki benzerlik ve ayırma, kümeler arasındaki fark ile değerlendirilen verilerin yapısı üzerinde farklı varsayımlar yapar. Diğer yöntemler tahmini yoğunluk ve grafik bağlantısına dayanır.

Denetimli öğrenmenin aksine, denetimsiz öğrenme, verilerdeki gizli yapıları tanımlayan bir işlev olan etiketlenmemiş verilerden kaynaklanır.

Belki de denetimsiz öğrenmenin en temel türü, PCA, t-SNE gibi 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.

Derin öğrenmenin rönesansı ile birlikte, denetimsiz öğrenme, verileri manuel olarak etiketlemekten bizi kurtardığı için gittikçe daha fazla dikkat çekiyor. Derin öğrenmenin ışığında, iki tür denetimsiz öğrenmeyi ele alıyoruz: temsili öğrenme ve üretken modeller.

Temsil öğrenme, bazı aşağı akış görevleri için yararlı olan üst düzey bir temsili özelliği damıtmayı amaçlarken, üretken modeller bazı gizli parametrelerden girdi verilerini yeniden üretmeyi amaçlamaktadır.

Denetimsiz öğrenme görüldüğü gibi çalışır. Bu tür algoritmalarda, etiketlenmiş verilere sahip değiliz. Bu yüzden makinenin giriş verilerini işlemesi ve çıktı hakkında sonuçlara varmaya çalışması gerekir. Örneğin, şekil oyuncağı verdiğimiz çocuğu hatırlıyor musunuz? Bu durumda, farklı şekiller için mükemmel şekil deliğini bulmayı kendi hatalarından öğrenecekti.

Ancak asıl mesele, çocuğu şekillere uyacak yöntemleri öğretmek beslemiyor olmamızdır (etiketli veriler olarak adlandırılan makine öğrenimi amaçları için). Ancak çocuk oyuncağın farklı özelliklerinden öğrenir ve onlar hakkında bir sonuca varmaya çalışır. Kısacası, tahminler etiketlenmemiş verilere dayanmaktadır.

Denetimsiz öğrenme algoritmalarına örnekler:


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

Takviyeli öğrenme, bir tür makine öğrenimidir. Bunda, bir etmen, eylemleri üreterek çevresiyle etkileşime girer ve geri bildirim yardımıyla öğrenir. Geri bildirim, temsilciye ödül şeklinde verilir, örneğin her iyi eylem için olumlu bir ödül alır ve her kötü eylem için olumsuz bir ödül alır. Acenteye herhangi bir etiketli veri veya denetim sağlanmaz. RL'de aracı, çevreyi keşfetmek için sürekli olarak üç şey yapar (eylemler gerçekleştirme, durumu değiştirme ve geri bildirim alma).

Popüler pekiştirmeli öğrenme algoritmaları şunlardır:

- Q-Öğrenme
- SARSA(Devlet Eylemi Ödül Devlet Eylemi)
- Derin Q Sınır Ağı

Takviyeli öğrenmenin çalışması aşağıdaki şema ile anlaşılabilir:



RL tabanlı sistem temel olarak aşağıdaki bileşenlerden oluşur:

- Çevre: faktörün keşfetmesi ve üzerinde hareket etmesi gereken çevresidir.
- Faktör: Faktör, sensörlere ve aktüatörlere ve çevreyi algılama yeteneğine sahip AI programıdır.
- Durum: Çevre tarafından temsilciye iade edilen durumdur.
- Ödül: Her bir eylemi gerçekleştirdikten sonra temsilciye alınan geri bildirim.

RL'de faktör, bazı eylemler yaparak onu keşfetmek için çevre ile etkileşime girer. Her eylemde, faktörün durumu değişir veya bazen aynı kalır ve eylemin türüne göre bir ödül alır. Ödül, eyleme bağlı olarak olumsuz veya olumlu olabilen geri bildirimdir. Temsilcinin amacı, pozitif ödülü maksimize etmek ve problemin amacına ulaşmaktır.

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/çıkı 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.

Pekiştirmeli Öğrenme (Reinforcement Learning)

Genel olarak, bir Güçlendirme Öğrenimi (RL) sistemi iki ana bileşenden oluşur:

1. Bir temsilci
2. Bir ortam



- Ortam, aracının üzerinde işlem yaptığı ayardır ve aracı, RL algoritmasını temsil eder.
- RL süreci, ortamın aracıya bir durum gönderdiğinde başlar ve daha sonra gözlemlerine dayanarak bu duruma yanıt olarak bir eylemde bulunur.
- Sırayla, ortam bir sonraki durumu ve ilgili ödülü aracıya geri gönderir. Aracı, son eylemini değerlendirmek için bilgisini çevre tarafından döndürülen ödülle güncelleyecektir.
- Döngü, ortam uçbirim durumu gönderene kadar devam eder, bu da aracının tüm görevlerini tamamladığı anlamına gelir.

Bunu daha iyi anlamak için, temsilcimizin karşı saldırı oynamayı öğrendiğini varsayalım. RL süreci aşağıdaki adımlara ayrılabilir:

- 1) RL Aracısı (Oyuncu1) ortamdan S^0 durumunu toplar (Karşı Saldırı oyunu)
- 2) S^0 durumuna bağlı olarak, RL ajanı bir A^0 eylemi gerçekleştirir (Eylem, bir sonuca neden olan herhangi bir şey olabilir, yani ajan oyunda sola veya sağa hareket ederse). Başlangıçta, eylem rastgele
- 3) Çevre artık yeni bir S^1 durumunda (oyunda yeni aşama)
- 4) RL aracısı artık ortamdan bir R^1 ödülü alır. Bu ödül ek puan veya jeton olabilir
- 5) Bu RL döngüsü, RL aracısı ölene veya hedefe ulaşana kadar devam eder ve sürekli olarak bir durum, eylem ve ödül dizisi verir.

Q-Learning

Q-öğrenme, pekiştirmeli öğrenmede kullanılan popüler bir algoritmadır. Bellman denkleminde dayanmaktadır. Bu algortmada aracı, belirli koşullar altında ödülleri en üst düzeye çıkarmak için gerçekleştirilecek en iyi eylemleri sağlayabilecek politikaları öğrenmeye çalışır. Aracı, bu optimal politikaları geçmiş deneyimlerden öğrenir.

Q-öğrenmede, Q, her durumdaki eylemlerin kalitesini temsil etmek için kullanılır ve faktörün amacı, Q'nun değerini maksimize etmektir.

Pekiştirmeli Öğrenmede Ödül maksimizasyonun

Ödül maksimizasyonu terimi, pekiştirmeli öğrenmede kullanılır ve pekiştirmeli öğrenme faktörünün bir amacıdır. RL'de ödül, bir durumdan diğerine geçiş için harekete geçerek olumlu bir geri bildirimdir. Temsilci, optimal politikalar uygulayarak iyi bir eylem gerçekleştirirse ödül alır ve kötü bir eylem gerçekleştirirse bir ödül çıkarılır. Temsilcinin amacı, ödül maksimizasyonu olarak adlandırılan optimal politikaları uygulayarak bu ödülleri maksimize etmektir.

Explain reward maximization in Reinforcement Learning.

The RL agent works based on the theory of reward maximization. This is exactly why the RL agent must be trained in such a way that, he takes the best action so that the reward is maximum.

The collective rewards at a particular time with the respective action is written as:

$$G_t = R_{t+1} + R_{t+2} + \dots$$

Reward Maximization Equation – Artificial Intelligence Interview Questions – Edureka

The above equation is an ideal representation of rewards. Generally, things don't work out like this while summing up the cumulative rewards.



Let me explain this with a small game. In the figure you can see a fox, some meat and a tiger.

- Our RL agent is the fox and his end goal is to eat the maximum amount of meat before being eaten by the tiger.
- Since this fox is a clever fellow, he eats the meat that is closer to him, rather than the meat which is close to the tiger, because the closer he is to the tiger, the higher are his chances of getting killed.
- As a result, the rewards near the tiger, even if they are bigger meat chunks, will be discounted. This is done because of the uncertainty factor, that the tiger might kill the fox.

The next thing to understand is, how discounting of rewards work? To do this, we define a discount rate called gamma. The value of gamma is between 0 and 1. The smaller the gamma, the larger the discount and vice versa.

So, our cumulative discounted rewards is:


$$G_t = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \text{ where } \gamma \in [0, 1)$$

$$R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} \dots$$

Keşif ve keşif takası

Takviyeli öğrenmede önemli bir kavram, keşif ve kullanım değiş tokuşudur.

Keşif, adından da anlaşılacağı gibi, bir çevre hakkında daha fazla bilgi keşfetmek ve yakalamakla ilgilidir. Öte yandan, keşif, ödülleri artırmak için zaten bilinen keşif bilgileri kullanmakla ilgilidir.



- Tilki ve kaplan örneğini düşünün, tilki sadece kendisine yakın olan et (küçük) parçalarını yer, ancak daha büyük et parçaları ona daha fazla ödül kazandırsa bile, tepedeki daha büyük et parçalarını yemez.
- Tilki sadece en yakın ödüle odaklanırsa, büyük et parçalarına asla ulaşamaz, buna keşif denir.
- Ancak tilki biraz keşfetmeye karar verirse, daha büyük ödülü, yani büyük et parçasını bulabilir. Bu keşif takasıdır.

3.1.4. Diğer Öğrenme Yöntemleri

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 gerçekleştirilmeden 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.

Özellik öğrenmesi denetimli veya denetimsiz olabilir. 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 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, sınıflandırma gibi makine öğrenmesi görevlerinin genellikle matematiksel ve hesaplama uygun olarak işlenmesi için girdi gerektirmesi gerçeğiyle motive edilir. Bununla birlikte, görüntüler, video ve duyu verileri gibi gerçek dünya verileri, belirli özellikleri algoritmik olarak tanımlama girişimlerine yol açmamıştır. Bir alternatif, açık algoritmalara dayanmadan, bu özellikleri veya gösterimleri muayene yoluyla keşfetmektir.

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 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 merkezietçi 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 artırır. 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 tanımlanan 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 induksiyon veya genelleme sürecini geciktirdiği için Tembel öğrenme algoritması olarak da adlandırılır.

3.2. Makine Öğrenmesi Algoritmaları

Yapay Zeka ya da Makine Öğrenimi, yüksek hesaplama, depolama, veri güvenliği veri haberleşmesi ve ağ gereksinimlerine sahip karmaşık bir süreçtir.

Yapay zeka, makinelerin veya bilgisayarların insan gibi mevcut verilere dayanarak karar verme kapasitesini taklit ettiği herhangi bir yöntemi ifade eden bir genel terimdir. **Makine öğrenimi, otomatikleştirilmiş görevleri mümkün kılmak için özellikle Yapay Zekanın algoritmaları formunda uygulanmasıdır. Makine öğreniminin önemli bir özelliği, daha fazla veriyi kullandıkça öğrenmesi ve zamanla daha iyi kararlar vermesidir.**

Derin öğrenme, yapay zeka algoritmalarının yapısının katmanlı ve daha güçlü olduğu ve sinir ağı olarak adlandırılan özel bir makine öğrenimi kategorisidir. Derin öğrenme modelleri, mühendislerin doğruluğu artırmak ve modelin makine öğreniminin kapasitesinin ötesinde daha fazla nüans katmanını tanımasını sağlamak için modeli sürekli olarak ayarlayacağı tekrarlayan bir test döngüsü sürecinden geçirilmesidir.

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 algoritmalarından yararlanan başka makine öğrenimi araçları ve süreçleri vardır. Bunlar şunları içerir:

- Kapsamlı veri kalitesi ve yönetimi
- Modeller ve süreç akışları oluşturmak için GUI'ler
- Etkileşimli veri keşfi ve model sonuçlarının görselleştirilmesi
- 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

Yapay zeka algoritmalarının yaygın türleri:

Yapay zeka modellerinin amacı, farklı türdeki birden çok girdi arasındaki ilişkiyi anlamaya çalışarak sonuçları tahmin etmek veya kararlar almak için bir veya daha fazla algoritma kullanmaktır. Yapay zeka modelleri, bu göreve nasıl yaklaştıklarına göre farklılık gösterir ve yapay zeka geliştiricileri, bir hedefe veya işleve ulaşmak için birden fazla algoritmayı birlikte devreye alabilir.

- Doğrusal regresyon, genellikle $f(t)=at+b$ şeklinde basit bir çizgi grafiğinde temsil edilen bir veya daha fazla X girişi(leri) ve Y çıkışı arasındaki doğrusal ilişkiyi eşleştirir.
- Lojistik regresyon, ikili bir X değişkeni (doğru veya yanlış, mevcut veya yok gibi) ile Y çıktısı arasındaki ilişkiyi eşleştirir.
- Doğrusal diskriminant analizi, başlangıç verilerinin ayrı kategoriler veya sınıflandırmalarla nitelendirilmesi dışında, lojistik regresyon gibi çalışır.
- Karar ağaçları, karar ağacı bir sonuca ulaşana kadar bir dizi giriş verisine dallanan mantık modelleri uygular.
- Naive Bayes, başlangıç verileri arasında hiçbir ilişki olmadığını varsayan bir sınıflandırma tekniğidir.
- K-en yakın komşu, benzer özelliklere sahip girdilerin korelasyonları grafiğe döküldüğünde (Öklid mesafesi açısından), bunların birbirine yakın olacağını varsayan bir sınıflandırma tekniğidir. Benzer özelliklere sahip girdi verileri arasında ilişkinin yönü ve gücü hesaplandığında bulunan değerlerin birbirine yakın olacağını varsayan bir sınıflandırma tekniğidir.
- Vektör nicelemeyi öğrenmek, k-en yakın komşuya benzer, ancak bireysel veri noktaları arasındaki mesafeyi ölçmek yerine model, veri noktaları gibi prototiplere yakınsar.
- Destek vektör makinesi algoritmaları, daha doğru sınıflandırma için veri noktalarını belirgin şekilde ayıran, hiper düzlem adı verilen bir bölücü oluşturur. Benzer özelliklere sahip girdi verilerini daha doğru sınıflandırmak için verilerin özelliklerini birbirlerinde belirgin şekilde ayıran, hiper düzlem adı verilen bir tampon bölgelerin sınırlarını oluşturur.
- Torbalama, daha doğru bir model oluşturmak için birden fazla algoritmayı birleştirirken, rastgele orman, daha doğru tahmin elde etmek için birden fazla karar ağacını bir araya getirir.
- Derin sinir ağları, girdilerin geçmesi gereken ve nihai bir tahmin veya karar noktası ile sonuçlanan birçok algoritma katmanından oluşan bir yapıyı ifade eder.

Modelleme için Teknoloji Gereksinimleri

Yapay zeka modelleri, o kadar büyüyor ki, onları verimli bir şekilde eğitmek için daha fazla veri gerekiyor ve ne kadar hızlı veri taşırsanız, modeli o kadar hızlı eğitebilir ve devreye alabilirsiniz. Bilgi işleme platformları, yüksek performanslı CPU'lar, yüksek kapasiteli depolama ve yoğun trafik akışını kaldırabilen yüksek bant genişliğine sahip ağ yapıları ile yapay zeka iş yükleri için ayarlanmış yapılandırmalar sağlamaya yardımcı olur.

Makine Öğrenmesi Algoritmaları:

1- Regresyon (Tahmin)

Sürekli değerleri tahmin etmek için regresyon algoritmaları kullanılır.

Regresyon algoritmaları:

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

2-Sınıflandırma

Bir dizi öğenin 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

Özetlemek 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 kullanıyoruz.

İlişkilendirme algoritmaları:

- Apriori

5- Anomali (Sapma) Algılama:

Anormal etkinlikleri ve dolandırıcılık tespiti gibi olağandışı durumları keşfetmek için anormallik algılama kullanılır.

Veri madenciliğinde, aykırı tespit olarak da bilinen anomali tespiti, verilerin çoğundan önemli ölçüde farklılık göstererek şüphe uyandıran nadir maddelerin, olayların veya gözlemlerin tanımlanmasıdır. Tipik olarak, anormal kalemler banka sahtekarlığı, yapısal bir kusur, tıbbi sorunlar veya bir metindeki hatalar gibi bir konuyu temsil eder. Anomalilere aykırı değerler, yenilikler, gürültü, sapmalar ve istisnalar denir.

Özellikle, kötüye kullanım ve ağ izinsiz giriş tespiti bağlamında, ilginç nesnelere genellikle nadir nesnelere değil, faaliyette beklenmedik patlamalardır. Bu model, bir aykırı değer nadir bir nesne olarak ortak istatistiksel tanımına uymaz ve uygun şekilde toplanmadığı süreçte birçok aykırı algılama yöntemi (özellikle denetimsiz algoritmalar) bu verilerde başarısız olur. Bunun yerine, bir küme analiz algoritması bu örüntüler tarafından oluşturulan mikro kümeleri tespit edebilir.

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 ifadesidir. Diğer bir ifadeyle , nesnenin davranışı ile ilgili uzayda gözlenebilir veya ölçülebilir geometrik bilgilerdir. Tersinden desen madenciliği. Örüntü hazırlanır. Veri yığını içerisinde gezinir. Hedef geldiğinde uyarır, kendisini kabul ettirir. Ayrıca veri yığı içerisinde dolaşan ve arayan desenler geliştirilmektedir.

Örüntü Tanımının kullanıldığı alanlar:

- Örüntü Tanıma şu alanlarda kullanılabilir:
- Bilgisayar görüşü
- Konuşma tanıma
- Veri madenciliği
- İstatistik
- Gayri Resmi Erişim
- Biyo-Bilişim

Bir dizideki veri örnekleri arasındaki sonraki veri olaylarını tahmin etmek için sıralı model madenciliği kullanıyoruz.

Dünya ve ötesinde kainat sürekli veri oluşturan sinyal kaynakları (Elektromanyetik, elektrik, ısı, renk, ses, titreşim, çekimsel kuvvetler, ...) ile doludur. Bu kaynaklarından yayılan sinyal örüntüleri yayıldıkları ortamlar ile etkileşime girerler. O halde bu örüntülerin davranış değişikliklerinden kestirimsel tahminler yapılabilir.

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 indirmesi sıkça kullanılır.

Boyut indirgeme yaklaşımları doğrusal ve doğrusal olmayan olarak ikiye ayrılır. Boyut indirgeme var olan özneliklerin bir alt kümesini seçerek ya da yeni öznelikler çıkararak yapılabilir. Boyut indirgemesi gürültü filtreleme, veri görselleştirme ya da kümeleme analizi

amacıyla kullanılabileceği gibi, diğer makine öğrenimi yöntemlerinin ön adımı olarak uygulanabilir.

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.

Günümüzde yapay zeka, makine öğrenimi, derin öğrenme ve diğerleri gibi pek çok vızıltılı kelime duyuyoruz.

Makine öğrenimi algoritmalarını uygulamak için neden Python?

Python, popüler ve genel amaçlı bir programlama dilidir. Python kullanarak makine öğrenimi algoritmaları yazabiliriz ve bu iyi çalışır. Python'un veri bilimcileri arasında bu kadar popüler olmasının nedeni, **Python'un hayatımızı daha rahat hale getiren çok çeşitli modül ve kütüphanelerin halihazırda uygulanmış olmasıdır.**

Bazı heyecan verici Python kütüphanelerine kısaca bir göz atalım:

1. Numpy: Python'da n boyutlu dizilerle çalışmak için bir matematik kitaplığıdır. Hesaplamaları etkili ve verimli bir şekilde yapmamızı sağlar.
2. Scipy: Sinyal işleme, optimizasyon, istatistik ve çok daha fazlasını içeren sayısal algoritmalar ve alana özgü araç kutusudur. Scipy, bilimsel ve yüksek performanslı hesaplamalar için işlevsel bir kitaplıktır.
3. Matplotlib: 2D çizimin yanı sıra 3D çizim de sağlayan modaya uygun bir 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.

Types of Machine Learning

Supervised Learning

Classification

- Fraud detection
- Email Spam Detection
- Diagnostics
- Image Classification

Regression

- Risk Assessment
- Score Prediction

Unsupervised Learning

Dimensionality Reduction

- Text Mining
- Face Recognition
- Big Data Visualization
- Image Recognition

Clustering

- Biology
- City Planning
- Targetted Marketing

Reinforcement Learning

- Gaming
- Finance Sector
- Manufacturing
- Inventory Management
- Robot Navigation

3.2.1. Karar Ağaçları

Karar Ağacı, bir algoritmanın gösterimidir. Karar Ağaçları, Sınıflandırma Görevleri için kullanılabilir.

Karar Ağacı düğümleri:

Karar Düğümleri

Son Düğümler

Şans Düğümleri

Karar Düğümleri kareler, Şans Düğümleri daireler, Son Düğümler üçgenler ile temsil edilir.

- Karar Ağaçlarının avantajları:
- Olası Senaryolar eklenebilir
- Bir beyaz kutu modeli kullanın, Eğer verilen sonuç bir model tarafından sağlanıyorsa
- Farklı senaryolar için en kötü, en iyi ve beklenen değerler belirlenebilir

Öğrenme için kullanılan modeller:

- Karar ağaçları
- Sinir ağları
- Önerme ve FOL kuralları

Karar ağaçları,

- Nitelikler hem sayısal hem de nominaldir
- Hedef işlevi ayrık sayıda değer alır.
- Verilerde hatalar olabilir

3.2.2. Regresyon

Regresyon algoritmaları sayısal, nümerik veriye dayalı olarak gelecekteki sonuçları tahmin etmek için matematiksel fonksiyonların ya da denklemlerin katsayılarının bulunmasıdır. İnsan uzmanlığının, tecrübesinin aktarıldığı kesin parametrelere Hiperparametreler denir.

Makine öğrenmesinde, regresyon katsayıları bulunurken optimal kapsayıcı bir eğri fonksiyonu elde edilirken Yüksek dereceli polinomlardan kaçınılmalıdır. Bir regresyon modeli uydurmaya çalışmadan önce, bağımlı ve bağımsız değişkenler arasında Katsayılar arasında bir ilişki olup olmadığı belirlenmelidir. Regresyon modelinde Korelasyon katsayı 0.12 ise değişkenler arasındaki ilişkide korelasyon yoktur. İki değişken arasında bir ilişkinin olması için korelasyon katsayısı -1 ya da +1 değerine yakın olmalıdır. Sayısal verileri tahmin etmek için Regresyon algoritma kullanılır. Her gün başı sıcaklık kayıt edilmektedir. Bu değerlerden saat başı sıcaklık derecesi bulunmak istenmektedir. Regresyon algoritması kullanılır. Veri yığınınından öğrenen algoritma ile belirlenmiş sayısal verilerden $f(t)=a*t^2+b*t+c$, ile gösterilen $f(t)$, fonksiyonun a,b,c katsayılarını belirleyen makine öğrenmesi algoritması regresyondur.


Sayısal değişkenler arasındaki ilişkiyi bulmaya çalıştığınızda regresyon yöntemi kullanılır. Makine Öğreniminde ve istatistiksel modellemede bu ilişki gelecekteki olayların sonucunu tahmin etmek için kullanılır. Eksik, hatalı ara değerleri belirlemede kullanılır. Sürekli değerleri tahmin etmek için regresyon algoritmaları kullanılır.

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 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.

Makine öğrenmesinde, **regresyon katsayıları bulunurken optimal kapsayıcı bir eğri fonksiyonu elde edilmelidir**. Sınıflandırma yapılırken yüksek dereceli polinomlardan kaçınılmalıdır.



$$f(x) = \lambda_0 + \lambda_1 x \dots (1)$$

$$f(x) = \lambda_0 + \lambda_1 x + \lambda_2 x^2 \dots (2)$$

$$f(x) = \lambda_0 + \lambda_1 x + \lambda_2 x^2 + \lambda_3 x^3 + \lambda_4 x^4 \dots (3)$$

Yeterli veri olduğunda, aşırı uyum sorununu önlemek için "İzotonik Regresyon" kullanılır.

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.

Örneğin,

Giriş ile çıkış arasındaki ifade, $f(t)=at+b$ olsun. Bağımsız değişken: t , Bağımlı değişken: $f(t)$ olur.

Veri yığınının a ve b katsayıları bulunması istenir. Veri yığınının zaman zaman aralığı, örneğin 1 saniye 120 saniye arasında giriş ve çıkış değerleri var. 60 ile 65 saniye arasındaki değerler eksik. 60 ile 65 saniye arasındaki değerleri 0 olarak ya da optimum değerler vererek $f(t)$ çıkış fonksiyonunun a ve b katsayıları belirlenmiş olur. Eksik değerler tamamlandı. 125 saniyede ne olacak diyer sorduğumda $t=125$, girildiğinde $f(t)$ değeri bulunmuş olur. Bu değer tahmindir.

Doğrusal regresyon, değişkenler arasındaki ilişkiyi göstermeye çalışan istatistiksel bir yöntemdir. Farklı veri noktalarına bakar ve bir trend çizgisi çizer. 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 bir regresyon modeli uydurmaya çalışmadan önce, bağımlı ve bağımsız değişkenler arasında bir ilişki olup olmadığı belirlenmelidir.** Aralarında gözle görülür bir korelasyon olmalıdır.

Örneğin, daha yüksek üniversite notları mutlaka daha yüksek bir maaş paketi anlamına gelmez. İki değişken arasında bir ilişkinin belirlenmesinde dağılım grafiği oluşturmak yani 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. Eğer r değeri sıfıra yakın değerler alıyor ise iki değişken arasında bir ilişki olmadığı sonucuna varılır.

$$y = mx + b$$

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)

Pearson Çarpım Moment Korelasyon Katsayısı:

$$r = \frac{n(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{\sqrt{n(\sum x_i^2) - (\sum x_i)^2} \sqrt{n(\sum y_i^2) - (\sum y_i)^2}}$$

Korelasyon katsayısı abs(r)'nin yorumu;


- $r < 0.2$ ise çok zayıf ilişki yada korelasyon yok
- $0.2-0.4$ arasında ise zayıf korelasyon
- $0.4-0.6$ arasında ise orta şiddette korelasyon
- $0.6-0.8$ arasında ise yüksek korelasyon
- $0.8 >$ ise çok yüksek korelasyon olduğu yorumu yapılır.

Örnek:

Hafta olarak ölçülen doğumdaki gebelik yaşı ile gram cinsinden ölçülen doğum ağırlığı arasındaki ilişkiyi araştırmak için 17 bebeği içeren küçük bir çalışma yapılmıştır. Korelasyon katsayısı, $r=0.82$ hesaplanır.

Infant ID #	Gestational Age (weeks)	Birth Weight (grams)
1	34.7	1895
2	36.0	2030
3	29.3	1440
4	40.1	2835
5	35.7	3090
6	42.4	3827
7	40.3	3260
8	37.3	2690
9	40.9	3285
10	38.3	2920
11	38.5	3430
12	41.4	3657
13	39.7	3685
14	39.7	3345
15	41.1	3260
16	38.0	2680
17	38.7	2005

Gebelik yaşı ile bebek doğum ağırlığı arasındaki ilişkiyi tahmin etmek istiyoruz. Bu örnekte, doğum ağırlığı bağımlı değişken ve gebelik yaşı bağımsız değişkendir. Böylece y =doğum ağırlığı ve x =gebelik yaşı. Veriler, aşağıdaki şekilde bir dağılım diyagramında gösterilmektedir.



Her nokta bir (x,y) çiftini temsil eder (bu durumda hafta cinsinden ölçülen gebelik yaşı ve gram cinsinden ölçülen doğum ağırlığı). Bağımsız değişken olan gebelik yaşının yatay ekseninde (veya X ekseninde) ve bağımlı değişkenin (doğum ağırlığı) dikey ekseninde (veya Y ekseninde) olduğuna dikkat edin. Dağılım grafiği, gebelik yaşı ile doğum ağırlığı arasında pozitif veya doğrudan bir ilişki gösterir. Gebelik yaşı daha kısa olan bebeklerin daha düşük ağırlıkla doğma olasılığı daha yüksektir ve gebelik yaşı daha uzun olan bebeklerin daha yüksek ağırlıkla doğma olasılığı daha yüksektir.

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 anlamamız önemli olacaktır.

- **Değişken (Variable):** Sayılabilen veya ölçülebilen herhangi bir sayı, nicelik veya özelliktir. Veri ögesi 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. $y=ax + b$, a ve b katsayıdır, x: bağımsız değişken, y ise bağımlı değişkendir.
- **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.


3.2.3. Kümeleme (Clustering)

Kümeleme algoritması, veri kümesindeki bileşenleri kendi aralarında benzerliklerinden gruplamaya çalışır. Burada kaç grup olacağı veya en uygun küme sayısını kümeleme algoritmanın kendisi belirler. Girdiye aşırı duyarlılık gösteren parametreler sistemde kaotik davranış oluşturtuklarında bu hassasiyet sınırları belirlemede amaç en iyilemeyi bulmaktır.

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 çıktılarının 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 aldığı anda, 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 içerisinde bir tane elmayı belirlesin. Ardından tüm elmaları bulan bir senaryo sizce nasıl olmalıdır? En sonunda sandıkta bir tane elma kalmaması yazdığın senaryonun hangi özelliği sağlamış olur. Performans artmış, deneyim kazanmış olur.

Alışveriş yapılan bir markette kasiyerin bir robot olduğunu 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, ayırım 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 inşa 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 seçiyorlar?

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 Algoritma 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
- Boyut indirgeme

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 buldukları 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 işlemiz 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 gelemmez 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.



- 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 yaklaşır. Ayrıca noktaların çoğunun “üstten-sağdan-aşağıya” olduğunu da görebiliriz. Bu nedenle standart sapma, olasılıkların ağırlıklandığı 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 ortasında, 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:

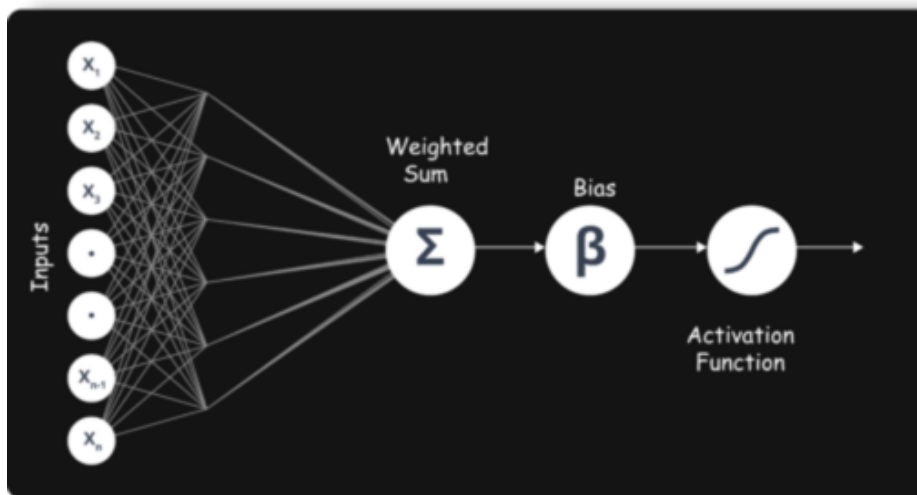
- K-Ortalamalar kümeleme
- Bulanık C-Ortalamalar kümeleme

3.3. Derin Öğrenme

Derin öğrenme, beynimizin çalışma şeklini taklit eder, yani deneyimlerden öğrenir. Karmaşık problemleri çözmek için sinir ağları kavramlarını kullanır.



- Girdi Katmanı: Bu katman tüm girdileri alır ve analiz için gizli katmana iletir.
- Gizli Katman: Bu katmanda çeşitli hesaplamalar yapılır ve sonuç çıktı katmanına aktarılır. Çözmeye çalıştığınız soruna bağlı olarak n sayıda gizli katman olabilir.
- Çıktı Katmanı: Bu katman, sinir ağından dış dünyaya bilgi aktarımından sorumludur.
- Derin Öğrenme, beyin hücresi veya nöron adı verilen beynin temel birimine dayanır. Bir nöronun esinlenerek yapay bir nöron veya bir algılayıcı geliştirildi.
- Bir biyolojik nöronun girdileri almak için kullanılan dendritleri vardır.
- Benzer şekilde, bir algılayıcı birden fazla girdi alır, çeşitli dönüşümler ve işlevler uygular ve bir çıktı sağlar.
- Tıpkı beynimizin nöral ağ adı verilen birden çok bağlantılı nöron içerdiği gibi, derin bir sinir ağı oluşturmak için algılayıcı adı verilen yapay nöronlardan oluşan bir ağa da sahip olabiliriz.



- Bir Yapay Nöron veya bir Algılayıcı, her birine belirli bir ağırlık atanmış bir dizi girdiye sahip bir nöronu modeller. Nöron daha sonra bu ağırlıklı girdiler üzerinde bazı fonksiyonları hesaplar ve çıktıyı verir.

Keras, TensorFlow ve PyTorch gibi Derin Öğrenme çerçevelerinin amacı

- Keras, Python ile yazılmış açık kaynaklı bir sinir ağı kütüphanesidir. Derin sinir ağlarıyla hızlı deneyler yapmak için tasarlanmıştır.
- TensorFlow, veri akışı programlaması için açık kaynaklı bir yazılım kitaplığıdır. Sinir ağları gibi makine öğrenimi uygulamaları için kullanılır.
- PyTorch, Python için Torch'a dayalı açık kaynaklı bir makine öğrenimi kitaplığıdır. Doğal dil işleme gibi uygulamalar için kullanılır.

3.3.1. Yapay Sinir Ağları

İleri Beslemeli Sinir Ağı

- Verinin veya girdinin bir yönde hareket ettiği en basit YSA biçimi.
- Veriler giriş düğümlerinden geçer ve çıkış düğümlerinden çıkar. Bu sinir ağı, gizli katmanlara sahip olabilir veya olmayabilir.

Evrışimsel Sinir Ağı

- Burada girdi özellikleri bir filtre gibi toplu olarak alınır. Bu, ağın görüntüleri parçalar halinde hatırlamasına ve işlemleri hesaplamasına yardımcı olacaktır.
- Esas olarak sinyal ve görüntü işleme için kullanılır

Tekrarlayan Sinir Ağı(RNN) – Uzun Kısa Süreli Bellek

- Bir katmanın çıktısını kaydetme ve katmanın sonucunu tahmin etmeye yardımcı olmak için bunu girdiye geri besleme ilkesine göre çalışır.
- Burada, sinir ağının ön yayılım üzerinde çalışmasına ve daha sonra kullanmak için hangi bilgilere ihtiyaç duyduğunu hatırlamasına izin verirsiniz.
- Bu şekilde her nöron bir önceki zaman adımında sahip olduğu bazı bilgileri hatırlayacaktır.

Otomatik kodlayıcılar

- Bunlar, bir girdi katmanı, bir çıktı katmanı ve bunları birbirine bağlayan bir veya daha fazla gizli katman içeren denetimsiz öğrenme modelleridir.
- Çıkış katmanı, giriş katmanıya aynı sayıda birime sahiptir. Amacı, kendi girdilerini yeniden oluşturmaktır.
- Tipik olarak, boyut azaltma amacıyla ve üretken veri modellerini öğrenmek için.

Sinir Ağları, birçok parametre içeren karmaşık Doğrusal Olmayan Fonksiyonlar içerir. Sinir ağları parametreleri gürültülü verilerden öğrenilebilir ve binlerce uygulama için kullanılmıştır, bu nedenle problemden probleme değişir ve bu nedenle doğrusal olmayan fonksiyonları kullanır.

Bir algılayıcı, yalnızca doğrusal ayrılabilir işlevleri temsil edebilen hiçbir gizli birimi olmayan ileri beslemeli bir sinir ağıdır. Veriler doğrusal olarak ayrılabilirse, verileri tam olarak sıgdırmak için basit bir ağırlık güncelleme kuralı kullanılabilir.

3 girişli bir nöron, giriş 110 olduğunda sıfır ve giriş 111 olduğunda bir çıkış verecek şekilde eğitilir. Genellemeden önceki doğruluk tablosu oluşturulur. Çıkışlar: 0,1, Bilinmeyendir. Bilinmeyen vakaları temsil eder ve çıktı rastgeledir. Değişen bit ile genelleme yapılır. Değişmeyen bitlerden kesin 0 ve 1 çıkışı elde edilir. Geri kalanlar için, değişen bit, 0 ise çıkış, 0; değişen bit, 1 ise çıkış, 1 olur? Hangi durumlar 0'ı temsil eder? 4 3 000 veya

110 veya 011 veya 101 010 veya 100 veya 110 veya 101 000 veya 010 veya 110
veya 100 100 veya 111 veya 101 veya 001

Algılayıcı, tek katmanlı bir ileri beslemeli sinir ağıdır. Geri bildirim olmadığı için oto-ilişkili bir ağ değildir ve ön işleme aşaması nöronlardan yapılmadığı için çok katmanlı bir sinir ağı da değildir.

4 girişli bir nöronun ağırlıkları 1, 2, 3 ve 4'tür. Aktarım işlevi doğrusaldır ve orantı sabiti 2'ye eşittir. Girişler sırasıyla 4, 10, 5 ve 20'dir. Çıktı ne olacak? Açıklama: Çıktı, ağırlıkların ilgili girdileri ile çarpılması, sonuçların toplanması ve transfer fonksiyonu ile çarpılmasıyla bulunur. Öyleyse: Çıktı = oran sabiti * (a1*b1 + a2*b2 + a3*b3 + a4*b4). Burada a1,a2,a3,a4: nöron ağırlıkları; b1,b2,b3,b4: girişler.

- (i) Ortalama olarak, sinir ağı geleneksel bilgisayarlardan daha yüksek hesaplama oranlarına sahiptir.
- (ii) (ii) Sinir ağı örnek olarak öğrenir.
- (iii) (iii) Sinir ağı, insan beyninin çalışma şeklini taklit eder.

Örüntü tanıma, tek katmanlı sinir ağlarının en iyi olduğu şeydir, ancak bir resmin eşliğini bulma veya iki şeklin bağlantılı olup olmadığını belirleme yetenekleri yoktur.

Sinir ağı,

- Bir dizi düğüm ve bağlantıya sahiptir
- Her düğüm ağırlıklı girdisini hesaplar
- Düğüm uyarılmış durumda veya uyarılmamış durumda olabilir

Neuro yazılımı Güçlü ve kolay sinir ağıdır. G

Bir algılayıcı, aldığı tüm ağırlıklı girdileri toplar ve belirli bir değeri aşarsa 1 verir, aksi takdirde sadece 0 verir.

NN (Neural Network) uygulamaları:

- Satış tahmini
- Veri doğrulama
- Risk yönetimi

Yaygın olarak kullanılan bazı Yapay Sinir ağları

Yapay sinir ağları, nöron adı verilen insan beyin hücrelerinin işleyişinden esinlenen istatistiksel modeldir. Bu sinir ağları, derin öğrenme ve makine öğrenimi gibi çeşitli yapay zeka teknolojilerini içerir.

Bir Yapay sinir ağı veya YSA, Girdi katmanı, Çıktı Katmanı ve gizli katmanlar dahil olmak üzere birden çok katmandan oluşur.

YSA, çeşitli derin öğrenme tekniklerinin yardımıyla örüntü tanıma, yüz tanıma vb. gibi çeşitli karmaşık sorunları çözmeye yönelik yapay zeka araçlarıdır.

Yaygın olarak kullanılan bazı Yapay sinir ağları:

- İleri Beslemeli Sinir Ağı
- Evrişimli Sinir Ağı
- Tekrarlayan Sinir Ağı
- Otomatik kodlayıcılar

Sinir ağlarında fazla takılmayı önlemek için bir teknik

Bırakma Tekniği: Bırakma tekniği, sinir ağı modellerinde fazla uydurmayı önlemek için popüler tekniklerden biridir. Eğitim sırasında rastgele seçilen nöronların bırakıldığı düzenleme tekniğidir.

NLP'nin çeşitli bileşenleri

NLP, yapay zekanın bir dalı olan Doğal Dil İşleme anlamına gelir. Makinelerin insan dilini anlamasını, yorumlamasını ve manipüle etmesini sağlar. NLP'nin Bileşenleri:

Doğal Dil işlemenin temel olarak aşağıda verilen iki bileşeni vardır:

A. Doğal Dil Anlama (NLU:Natural Language Understanding):

Aşağıdaki görevleri içerir:

- a. Girdiyi faydalı temsillerle eşleştirmek için.
- b. Dilin farklı yönlerini analiz etmek.

B. Doğal Dil Üretimi (NLG: Natural Language Generation)

- a. Metin Planlama
- b. Cümle Planlama
- c. Metin Gerçekleştirme


Facebook tarafından kullanılan yüz tanıma algoritması

Facebook, Facebook'a bir fotoğraf yüklediğinizde size fotoğraf etiketi önerilerinin gelmesini sağlayan yüz doğrulama için derin öğrenme algoritmalarını kullanan DeepFace aracını kullanır. Derin yüz, sinir ağı modellerini kullanarak dijital görüntülerdeki yüzleri tanımlar. DeepFace'in çalışması aşağıdaki adımlarda verilmiştir:

- Önce yüklenen resimleri tarar. Görüntünün 3 boyutlu modelini yapar ve ardından bu görüntüyü farklı açılara döndürür.

- Bundan sonra eşleşmeye başlar. Bu görüntüyü eşleştirmek için, bir kişinin diğer fotoğrafları arasındaki üst düzey benzerlikleri belirlemek için bir sinir ağı modeli kullanır. Gözler arasındaki mesafe, burun şekli, göz rengi gibi farklı özellikleri kontrol eder.
- Ardından, her insan yüzü 68 belirli yüz noktasından oluştuğundan, 68 dönüm noktası testi için özinelemeli kontrol yapar.
- Haritalama işleminden sonra görüntüyü kodlar ve o kişinin bilgilerini arar.

Facebook, yüz doğrulama için DeepFace'i kullanır. Sinir ağı modelleri kullanılarak Yapay Zeka (AI) teknikleriyle yapılandırılmış yüz doğrulama algoritması üzerinde çalışır.



Yüz doğrulama şu şekilde yapılır:

Giriş: Büyük karmaşık verilerle vahşi bir fotoğraf biçimi taranır. Bu, bulanık görüntüleri, yüksek yoğunluklu ve kontrastlı görüntüleri içerir.

Süreç: Modern yüz tanımda süreç 4 ham adımda tamamlanır:

- Yüz özelliklerini algılama
- Özellikleri hizalayın ve karşılaştırın
- 3B grafikler kullanarak anahtar kalıpları temsil edin
- Görüntüleri benzerliğe göre sınıflandırın


Çıktı: Nihai sonuç, 9 katmanlı derin sinir ağından türetilen bir yüz temsidir.

Eğitim Verileri: 4000'den fazla kişinin 4 milyondan fazla yüz görüntüsü

Sonuç: Facebook, iki görüntünün aynı kişiyi temsil edip etmediğini tespit edebilir

Bir sinir ağında aşırı uyumu önlemeye yardımcı olan bir teknik

Bırakma, bir sinir ağında aşırı uyumu önlemek için kullanılan bir tür düzenleme tekniğidir. Eğitim sırasında rastgele seçilen nöronların düşürüldüğü bir tekniktir.



Bir ağın Dropout (Bırakma) değeri akılcıca seçilmelidir. Çok düşük bir değer, minimum etkiye neden olur ve çok yüksek bir değer, ağ tarafından yetersiz öğrenmeye neden olur.

Derin Sinir Ağlarında hiperparametreler

Hiperparametre, tüm eğitim sürecini belirleyen ve kontrol eden parametrelerdir. Bu parametrelere örnek olarak Öğrenme hızı, Gizli Katmanlar, Gizli birimler, Etkinleştirme işlevleri vb. verilebilir. Bu parametreler modelin dışındadır. İyi hiperparametrelerin seçimi daha iyi bir algoritma yapar.

- Hiperparametreler, ağın yapısını tanımlayan değişkenlerdir. Örneğin, öğrenme oranı gibi değişkenler ağın nasıl eğitildiğini tanımlar.
- Bir ağda bulunması gereken gizli katmanların sayısını tanımlamak için kullanılırlar.
- Daha fazla gizli birim ağın doğruluğunu artırabilirken, daha az sayıda birim yetersiz donanıma neden olabilir.

Hiperparametreler ile model parametreleri arasındaki farklar

Model Parameters	Hyperparameters
Model parameters are the features of training data that will learn on its own during training.	Model Hyperparameters are the parameters that determine the entire training process.
For example, <ul style="list-style-type: none"> • Weights and Biases • Split points in Decision Tree 	For example, <ul style="list-style-type: none"> • Learning Rate • Hidden Layers • Hidden Units
They are internal to the model and their value can be estimated from data.	They are external to the model and their value cannot be estimated from data.

Hiperparametre optimizasyonu için kullanılan farklı algoritmalar

Izgara Arama: Izgara arama, iki hiper parametre seti, öğrenme oranı ve katman sayısı kullanarak her kombinasyon için ağı eğitir. Daha sonra Çapraz Doğrulama tekniklerini kullanarak modeli değerlendirir.

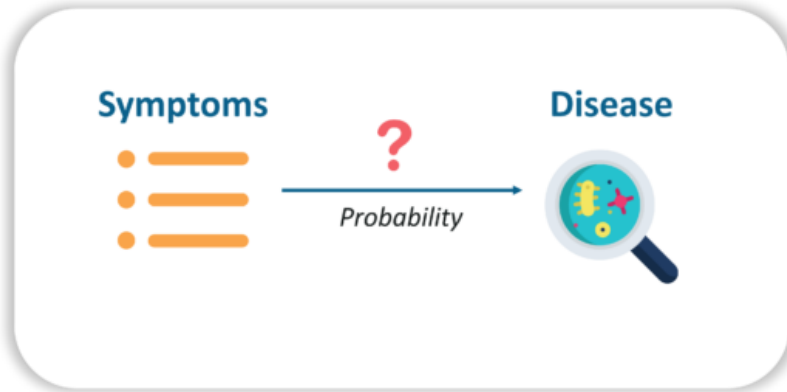
Rastgele Arama: Arama alanını rastgele örnekler ve belirli bir olasılık dağılımından kümeleri değerlendirir. Örneğin, 10.000 örneğin tümünü kontrol etmek yerine, rastgele seçilen 100 parametre kontrol edilebilir.

Bayes Optimizasyonu: Bu, otomatik model ayarlamayı etkinleştirerek hiperparametrelerin ince ayarını yapmayı içerir. Amaç fonksiyonuna yaklaşmak için kullanılan modele vekil model (Gauss Süreci) denir. Bayes Optimizasyonu, önceki işlemlere dayalı tahminler yapmak için sonsal işlemler elde etmek için Gauss İşlemi (GP) işlevini kullanır.

3.4.2. Bayes Ağları

Bayes ağı, bir dizi değişkeni ve bunların koşullu bağımlılıklarını yönlendirilmiş bir döngüsel olmayan grafik biçiminde temsil eden istatistiksel bir modeldir.

Bir olayın meydana gelmesi üzerine, Bayes Ağları, bilinen birkaç olası nedenden herhangi birinin katkıda bulunan faktör olma olasılığını tahmin etmek için kullanılabilir.



Bayesian Network

Örneğin, hastalıklar ve semptomlar arasındaki ilişkiyi incelemek için bir Bayes ağı kullanılabilir. Çeşitli semptomlar göz önüne alındığında, Bayes ağı, çeşitli hastalıkların varlığının olasılıklarını hesaplamak için idealdir.

Bayes ağı yapay zekada neden önemlidir?

Bayes ağları, bir dizi değişken arasındaki olasılık ilişkisini göstermek için kullanılan grafik modellerdir. Birden çok kenar içeren yönlendirilmiş bir döngü grafiğidir ve her kenar koşullu bir bağımlılığı temsil eder. Bayes ağları olasılıksaldır, çünkü bu ağlar bir olasılık dağılımından oluşturulur ve ayrıca tahmin ve anomali tespiti için olasılık teorisini kullanır. Bayes teoremine dayandığından ve olasılık sorularını yanıtlamak için kullanılabilirdiğinden AI'da önemlidir.

3.4.3. Markov'un Karar süreci

Hidden Markov modeli, geiş ve sensör modelinden bağımsız olan zamansal olasılıksal muhakemeyi çözmek için kullanılır. Bir HMM, sürecin durumunun tek bir ayrık rasgele deęişken tarafından tanımlandığı zamansal bir olasılık modelidir. Deęişkenin olası deęerleri Olası durumlardır.

Ek deęişkenlerin HMM'de eklendięi yerler:

- Zamansal model
- Gerçeklik modeli
- Olasılık modeli

HMM çerçevesinde kalırken geçici bir modele ek durum deęişkenleri eklenebilir.HMM'nin kısıtlı yapısı tüm temel algoritmanın basit ve matris uygulamasına izin verir.

Saklı Markov Modelinin kullanıldığı yerler:Konuşma tanıma
Bir dilin temel öęesi Rastgele deęişken

Takviyeli öğrenme probleminin çözümü, Markov karar süreci veya MDP (Markov decision process) kullanılarak elde edilebilir. Bu nedenle, MDP, RL (Reinforcement Learning) problemini resmileştirmek için kullanılır. Takviyeli öğrenme problemini çözmek için matematiksel yaklaşım olarak söylenebilir. Bu sürecin temel amacı, optimum politikayı seçerek maksimum olumlu ödüller elde etmektir.

MDP'nin dört unsuru vardır:

- Sonlu durum S 'in bir A kümesi
- Sonlu eylem A 'ların bir A kümesi
- Ödüller
- Politika P_a

Bu süreçte etmen, S_1 durumundan S_2 durumuna veya başlangıç durumundan bitiş durumuna geçiş yapmak için bir A eylemi gerçekleştirir ve bu eylemleri yaparken aracı bazı ödüller alır. Aracı tarafından gerçekleştirilen eylemler dizisi politika olarak tanımlanabilir.

Özdeęerler ve özvektörler

Özvektörler ve özdeęerler, Lineer cebirin iki ana kavramıdır. Özvektörler, büyüklüğü 1.0'a eşit olan birim vektörlerdir. Özdeęerler, özvektörlere uygulanan katsayılarıdır veya bunlar özvektörün ölçeklendięi büyüklüktür.

Gizli Markov modeli

Gizli Markov modeli, bir gözlem zinciri üzerindeki olasılık dağılımlarını temsil etmek için kullanılan istatistiksel bir modeldir. Gizli markov modelinde, gizli, belirli bir zamanda üretilen bir sürecin durumunun gözlemciden gizlendiğini varsaydığı bir özellięi tanımlar ve Markov,

sürecin Markov özelliğini karşıladığını varsaydığını tanımlar. HMM modelleri çoğunlukla zamansal veriler için kullanılır.

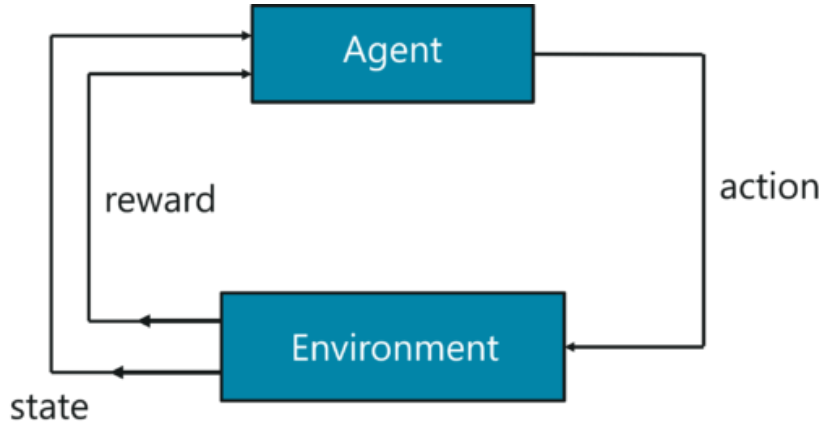
HMM, pekiştirmeli öğrenme, zamansal örüntü tanıma vb. gibi çeşitli uygulamalarda kullanılır.

Markov'un karar sürecinin bir örnekle açıklanması

The mathematical approach for mapping a solution in Reinforcement Learning is called Markov's Decision Process (MDP).


The following parameters are used to attain a solution using MDP:

- Set of actions, A
- Set of states, S
- Reward, R
- Policy, π
- Value, V



To briefly sum it up, the agent must take an action (A) to transition from the start state to the end state (S). While doing so, the agent receives rewards (R) for each action he takes. The series of actions taken by the agent, define the policy (π) and the rewards collected define the value (V). The main goal here is to maximize rewards by choosing the optimum policy.

To better understand the MDP, let's solve the Shortest Path Problem using the MDP approach:



Given the above representation, our goal here is to find the shortest path between 'A' and 'D'. Each edge has a number linked with it, this denotes the cost to traverse that edge. Now, the task at hand is to traverse from point 'A' to 'D', with minimum possible cost.

In this problem,

- The set of states are denoted by nodes i.e. {A, B, C, D}
- The action is to traverse from one node to another {A -> B, C -> D}
- The reward is the cost represented by each edge
- The policy is the path taken to reach the destination

You start off at node A and take baby steps to your destination. Initially, only the next possible node is visible to you, thus you randomly start off and then learn as you traverse through the network. The main goal is to choose the path with the lowest cost.

Since this is a very simple problem, I will leave it for you to solve. Make sure you mention the answer in the comment section.

3.4.4. Doğal Dil İşleme

Doğal Dil İşleme (NLP – Natural Language Processing) ve Metin madenciliği arasında ayrımlar.

Text Mining	Natural Language Processing
Aim of text mining is to extract useful insights from structured & un-structured text.	Aim of NLP is to understand what is conveyed in speech.
Text Mining can be done using text processing languages like Perl, statistical models, etc.	NLP can be achieved using advanced machine learning models, deep neural networks, etc.
Outcome: <ul style="list-style-type: none">• Frequency of words• Patterns• Correlations	Outcome: <ul style="list-style-type: none">• Semantic meaning of text• Sentimental analysis• Grammatical structure

NLP'nin Bileşenleri



Doğal Dil Anlayışı şunları içerir:


- Girdiyi faydalı temsillere eşleme
- Dilin farklı yönlerini analiz etme

Doğal Dil Üretimi şunları içerir:

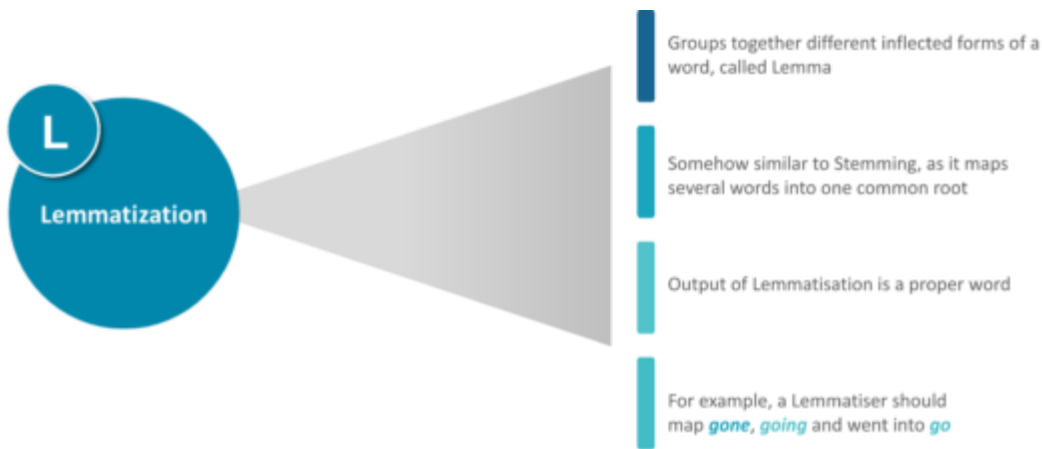
- Metin Planlama
- Cümle Planlama
- Metin Gerçekleştirme

NLP'de Stemming & Lemmatization

Stemming algoritmaları, çekimli bir kelimedeki bulunabilecek yaygın önek ve soneklerin bir listesini dikkate alarak kelimenin sonunu veya başlangıcını keserek çalışır. Bu ayırım gözetmeyen kesim bazı durumlarda başarılı olabilir, ancak her zaman değil.




Lemmatizasyon ise kelimelerin morfolojik analizini dikkate alır. Bunu yapmak için, algoritmanın formu lemmasına geri bağlamak için inceleyebileceği ayrıntılı sözlüklere sahip olmak gerekir.



Chatbot

Chatbot, Doğal dil işlemeyi kullanarak insanlarla veya kullanıcılarla bir konuşmayı simüle edebilen Yapay zeka yazılımı veya aracıdır. Görüşme bir uygulama, web sitesi veya mesajlaşma uygulamaları aracılığıyla gerçekleştirilebilir. Bu sohbet robotları aynı zamanda dijital asistanlar olarak da adlandırılır ve insanlarla yazılı veya sesli olarak etkileşime girebilir. AI sohbet robotları, HDFC Eva sohbet botu, Vainubot vb. gibi müşterilerine 7 gün 24 saat sanal müşteri desteği sağlamak için çoğu işletmede yaygın olarak kullanılmaktadır.

Örnek: Odalardan herhangi birine (0,1,2,3,4) bir ajan yerleştirin ve amaç binanın dışına (5. oda) ulaşmaktır. Bu yapay zeka ile başarılabilir mi? Evet ise, nasıl yapılabileceğini açıklayın.




In the above figure:


- 5 rooms in a building connected by doors
- Each room is numbered 0 through 4
- The outside of the building can be thought of as one big room (5)
- Doors 1 and 4 directly lead into the building from room 5 (outside)

This problem can be solved by using the Q-Learning algorithm, which is a reinforcement learning algorithm used to solve reward based problems.

Let's represent the rooms on a graph, each room as a node, and each door as a link, like so:



Next step is to associate a reward value to each door:



- doors that lead directly to the goal have a reward of 100
- Doors not directly connected to the target room have zero reward
- Because doors are two-way, two arrows are assigned to each room
- Each arrow contains an instant reward value


Now let's try to understand how Q-Learning can be used to solve this problem. The terminology in Q-Learning includes the terms state and action:

- The room (including room 5) represents a state
- Agent's movement from one room to another represents an action

In the figure, a state is depicted as a node, while "action" is represented by the arrows. Suppose, the Agent traverses from room 2 to room 5, then the following path is taken:

1. Initial state = state 2
2. State 2 -> state 3
3. State 3 -> state (2, 1, 4)
4. State 4 -> state 5

Next, we can put the state diagram and the instant reward values into a reward table or a matrix R, like so:



	Action					
State	0	1	2	3	4	5
0	-1	-1	-1	-1	0	-1
1	-1	-1	-1	0	-1	100
2	-1	-1	-1	0	-1	-1
3	-1	0	0	-1	0	-1
4	0	-1	-1	0	-1	100
5	-1	0	-1	-1	0	100

The -1's in the table represent null values

The next step is to add another matrix Q, representing the memory of what the agent has learned through experience.

- The rows of matrix Q represent the current state of the agent
- columns represent the possible actions leading to the next state

The formula to calculate the Q matrix:

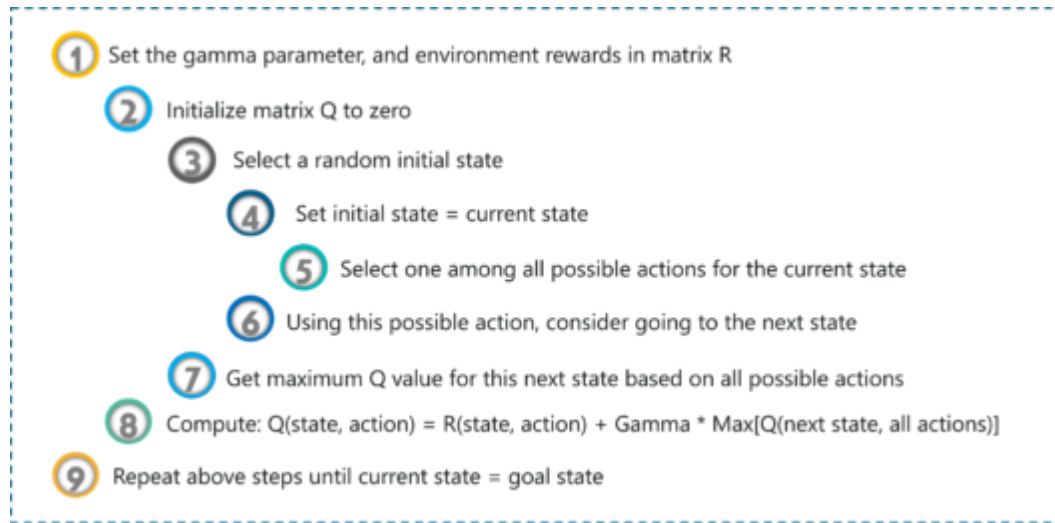
$$Q(\text{state}, \text{action}) = R(\text{state}, \text{action}) + \text{Gamma} * \text{Max} [Q(\text{next state}, \text{all actions})]$$

Here, $Q(\text{state}, \text{action})$ and $R(\text{state}, \text{action})$ represent the state and action in the Reward matrix R and the Memory matrix Q.

Note: The Gamma parameter has a range of 0 to 1 ($0 \leq \text{Gamma} < 1$).

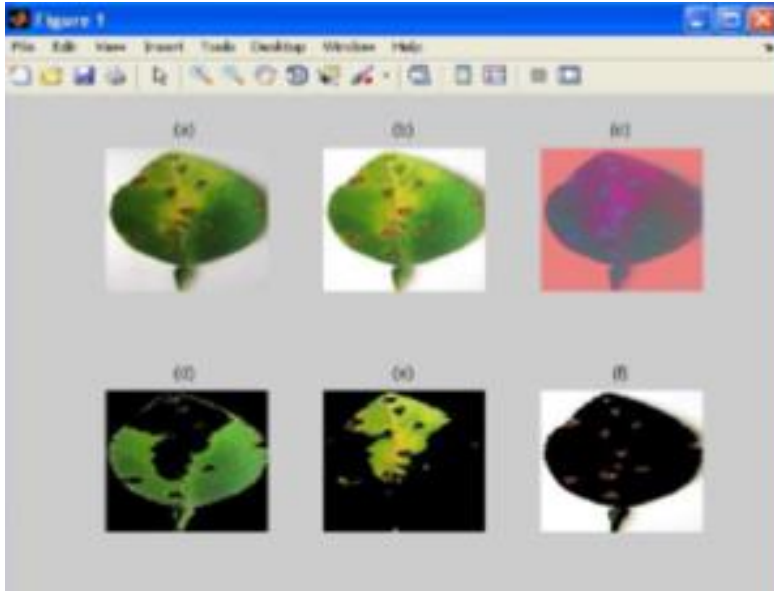
- If Gamma is closer to zero, the agent will tend to consider only immediate rewards.
- If Gamma is closer to one, the agent will consider future rewards with greater weight

Finally, by following the below steps, the agent will reach room 5 by taking the most optimal path:



Örnek: Hindistan'da mahsul verimi düşüyor çünkü çiftçiler mahsullerdeki hastalıkları erken aşamalarda tespit edemiyorlar. Makine Öğrenmesi, mahsullerde hastalık tespiti için kullanılabilir mi? Öyleyse, açıklayın.

Makine Öğrenmesi, yaprak hastalıklarının çıkarılması ve sınıflandırılması için görüntü işleme ve sınıflandırma tekniklerini uygulamak için kullanılabilir.



Karmaşıklığı önlemek için adımlara ayırılım:

Görüntü Toplama: Örnek görüntüler toplanır ve bir girdi veri tabanı olarak saklanır.

Görüntü Ön İşleme: Görüntü ön işleme aşağıdakileri içerir:

- İstenmeyen bozulmayı önleyen görüntü verileri iyileştirilir.
- Görüntü özellikleri geliştirilir.
- Görüntü kırpma, geliştirme, renk alanı dönüştürülür.
- Bir görüntünün kontrastını ayarlamak için Histogram eşitleme gerçekleştirilir.

Görüntü Segmentasyonu: Sayısal bir görüntünün, görüntü analizinin kolaylaşması için birden çok parçaya bölünmesi işlemidir. Segmentasyon, renk, doku gibi görüntü özelliklerine dayanmaktadır. Segmentasyon için kullanılan popüler bir Makine Öğrenimi yöntemi, K-means kümeleme algoritmasıdır.

Özellik Çıkarımı: Bu, belirli bir örneğin önemini bulmak için kullanılacak bilgileri çıkarmak için yapılır. Haar Wavelet dönüşümü doku analizi için kullanılabilir ve hesaplamalar Gray-Level Co-Occurrence Matrix kullanılarak yapılabilir.

Sınıflandırma: Son olarak, yaprak hastalıklarının sınıflandırılması için Lineer Destek Vektör Makinesi kullanılmaktadır. SVM, iki sınıf arasındaki karar sınırı olarak adlandırılan bir hiper düzlem kullanan ikili bir sınıflandırıcıdır. Bu, iki sınıfın oluşumuyla sonuçlanır:

1. Hastalıklı yapraklar
2. Sağlıklı yapraklar

Bu nedenle, AI, görüntüleri inceleyerek ve işleyerek hastalıkları sınıflandırmak ve tespit etmek için Bilgisayarla Görmede kullanılabilir. Bu, yapay zekanın en derin uygulamalarından biridir.

3.4. ML modellerinde Performans Değerlendirmesi

Makine Öğrenmesinde kullanılan adımlar

Yapay zeka, denetimli ve denetimsiz öğrenme algoritmaları gibi farklı makine öğrenimi algoritmaları kullanarak dolandırıcılık tespitinde geniş ölçüde yardımcı olabilir. Makine öğreniminin kural tabanlı algoritmaları, herhangi bir işlem için kalıpları analiz etmeye ve hileli işlemleri engellemeye yardımcı olur.

Makine öğrenmesinde kullanılan adımları yazınız.

Veri Çıkarma, Veri Temizleme, Veri Keşfi ve Analizi, Öğrenen modeli oluşturma, Model Değerlendirmesi

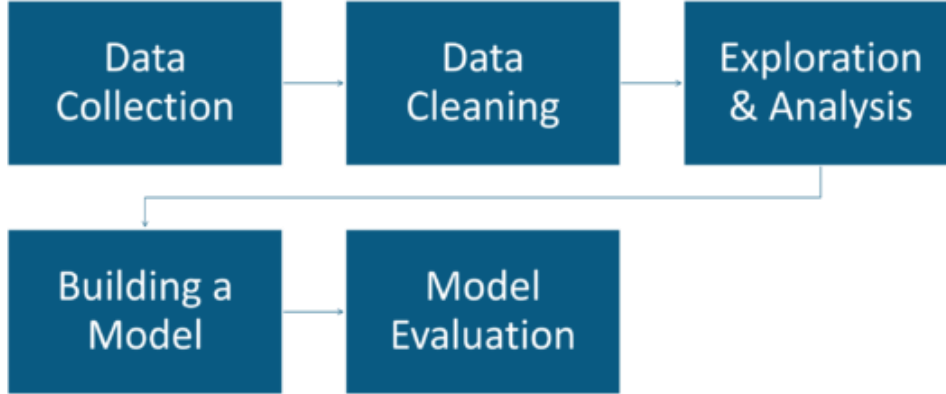
Makine öğreniminde kullanılan adımlar aşağıda verilmiştir:

- **Veri Çıkarma (Data Extraction):** Bu aşamada ya anket yoluyla veriler toplanır ya da web kazıma yapılır. Kredi kartı sahtekarlığını tespit etmeye çalışıyorsanız, müşteriyle ilgili bilgiler toplanır. Buna işlem, alışveriş, kişisel ayrıntılar vb. dahildir. İlk adım veri çıkarmadır. Veriler bir anket yoluyla veya web kazıma araçları yardımıyla toplanır. Veri toplama, modelin türüne bağlıdır ve oluşturmak istiyoruz. Genellikle işlem detaylarını, kişisel detayları, alışverişi vb. içerir.
- **Veri Temizleme (Data Cleaning):** Bu aşamada fazlalık veriler kaldırılmalıdır. Herhangi bir tutarsızlık veya eksik değer yanlış tahminlere yol açabilir, bu nedenle bu tür tutarsızlıklar bu adımda ele alınmalıdır. Bu adımda alakasız veya fazlalık veriler kaldırılır. Verilerde mevcut olan tutarsızlık yanlış tahminlere yol açabilmektedir.
- **Veri Keşfi ve Analizi (Data Exploration & Analysis):** Bu, yapay zekadaki en önemli adımdır. Burada çeşitli yordayıcı değişkenler arasındaki ilişkiyi incellersiniz. Örneğin, bir kişi belirli bir günde olağandışı bir miktarda para harcamışsa, dolandırıcılık olasılığı çok yüksektir. Bu tür kalıplar bu aşamada tespit edilmeli ve anlaşılmalıdır. Bu, farklı tahmin değişkenleri arasındaki ilişkiyi bulmamız gereken en önemli adımlardan biridir.
- **Bir Makine Öğrenimi modeli oluşturma (Building a Machine Learning model):** Sahtekarlığı tespit etmek için kullanılacak birçok makine öğrenimi algoritması vardır. Böyle bir örnek, bir sınıflandırma algoritması olan Lojistik Regresyon'dur. Olayları hileli ve hileli olmayan olmak üzere 2 sınıfa ayırmak için kullanılabilir. Model Oluşturma: Şimdi son adım, iş gereksinimine bağlı olarak farklı makine öğrenimi algoritmaları kullanarak modeli oluşturmaktır. **Regresyon veya sınıflandırma gibi.**

- Model Değerlendirmesi (**Model Evaluation**): Burada, temel olarak makine öğrenimi modelinin verimliliğini test edersiniz. İyileştirme için herhangi bir yer varsa, parametre ayarı yapılır. Bu, modelin doğruluğunu artırır.

Sahtekarlığı tespit etmede Makine Öğrenmesi Algoritmaları

Anormallikleri tespit etmek ve verilerdeki gizli kalıpları incelemek için Makine Öğrenimi algoritmaları uygulayarak Dolandırıcılık tespit problemlerinde kullanılır.



ML modelinin performansını değerlendirmenin bazı popüler yolları şunlardır:

- **Karışıklık Matrisi:** Makine öğrenmesinde sınıflandırma modelinin performansını belirlemek için kullanılan farklı değer setlerine sahip $N \times N$ tablosudur.
- **F1 puanı:** ML modelini değerlendirmek için en iyi ölçütlerden biri olarak kullanılan kesinlik ve hatırlamanın harmonik ortalamasıdır.
- **Kazanç ve artış çizelgeleri:** Kazanç ve Yükseliş çizelgeleri, olasılıkların sıra sırasını belirlemek için kullanılır.
- **AUC-ROC eğrisi:** AUC-ROC, başka bir performans ölçüsüdür. ROC, hassasiyet arasındaki alandır. Area Under the Curve (AUC) of Receiver Characteristic Operator (ROC). AUC-ROC eğrisinin makine öğrenimi sınıflandırmasının ne kadar iyi performans gösterdiğini görselleştirilmesine yardımcı olur. Sadece ikili sınıflandırma problemlerinde işe yaramasına rağmen, çok sınıflı sınıflandırma problemlerini de değerlendirmek için genişletilebilmektedir. Değerlendirme kriterleri - AUC ne kadar yüksekse model o kadar iyidir.

Karışıklık matrisi (confusion matrix):

		ACTUAL VALUES	
		POSITIVE	NEGATIVE
PREDICTED VALUES	POSITIVE	TP	FP
	NEGATIVE	FN	TN

Duyarlılık / Gerçek Pozitif Oranı (TPR - True Positive Rate) / Geri Çağırma:

Duyarlılık (Sensitivity) pozitif sınıfın ne kadarının doğru sınıflandırıldığını söyler. Basit bir örnek, gerçek hasta insanların ne kadarının model tarafından doğru bir şekilde tespit edildiğini belirlemek olabilir.

$$Duyarlılık = \frac{TP}{TP + FN}$$

Yanlış Negatif Oran (FNR - False Negative Rate), pozitif sınıfın ne kadarının sınıflandırıcı tarafından yanlış sınıflandırıldığını söyler. Pozitif sınıfı doğru bir şekilde sınıflandırmak istediğimiz için daha yüksek bir TPR ve daha düşük bir FNR arzu edilir.

$$FNR = \frac{FN}{TP + FN}$$

Özgüllük / Gerçek Negatif Oran (True Negative Rate):

Özgüllük negatif sınıfın ne kadarının doğru sınıflandırıldığını söyler. Duyarlılık ile aynı örneği alırsak, Özgüllük, model tarafından doğru bir şekilde tanımlanmış sağlıklı insanların oranını belirlemek anlamına gelir.

$$Özgüllük = \frac{TN}{TN + FP}$$


Yanlış Pozitif Oran (FPR - False Positive Rate):

FPR, sınıflandırıcı tarafından negatif sınıfın ne kadarının yanlış sınıflandırıldığını söyler. Negatif sınıfı doğru bir şekilde sınıflandırmak istediğimiz için daha yüksek bir TNR ve daha düşük bir FPR arzu edilir. Bu ölçütlerden Duyarlılık ve Özgüllük belki de en önemlileridir ve bunların bir değerlendirme ölçütü oluşturmak için nasıl


kullanıldığını daha sonra göreceğiz. Ancak ondan önce, tahmin olasılığının neden hedef sınıfı doğrudan tahmin etmekten daha iyi olduğunu anlayalım.

$$FPR = \frac{FP}{TN + FP} = 1 - \text{Duyarlılık}$$


Alıcı Operatör Karakteristik (ROC) eğrisi, ikili sınıflandırma sorunları için bir değerlendirme metriğidir. Çeşitli eşik değerlerinde FPR'ye karşı TPR'yi çizen ve esas olarak "sinyali" "gürültüden" ayıran bir olasılık eğrisidir. Eğrinin Altındaki Alan (AUC), bir sınıflandırıcının sınıfları ayırt etme yeteneğinin ölçüsüdür ve ROC eğrisinin bir özeti olarak kullanılır. AUC ne kadar yüksek olursa, modelin pozitif ve negatif sınıfları ayırt etmedeki performansı o kadar iyi olur.



AUC = 1 olduğunda, sınıflandırıcı tüm Pozitif ve Negatif sınıf puanlarını doğru bir şekilde mükemmel bir şekilde ayırt edebilir. Bununla birlikte, AUC 0 olsaydı, sınıflandırıcı tüm Negatifleri Pozitif olarak ve tüm Pozitifleri Negatif olarak tahmin ediyor olurdu.



$0.5 < AUC < 1$ olduğunda, sınıflandırıcının pozitif sınıf değerlerini negatif sınıf değerlerinden ayırt edebilme olasılığı yüksektir. Bunun nedeni, sınıflandırıcının Yanlış negatifler ve Yanlış pozitiflerden daha fazla sayıda Doğru pozitif ve True negatif tespit edebilmesidir.



AUC=0.5 olduğunda, sınıflandırıcı Pozitif ve Negatif sınıf puanları arasında ayırım yapamaz. Yani, sınıflandırıcı tüm veri noktaları için rastgele sınıfı veya sabit sınıfı tahmin ediyor. Dolayısıyla, bir sınıflandırıcının AUC değeri ne kadar yüksek olursa, pozitif ve negatif sınıfları ayırt etme yeteneği o kadar iyi olur.

Örnek:

		Point C	
		Actual	
		+ve	-ve
Predicted	+ve	4	2
	-ve	1	3

TPR/Sensitivity = 0.8
 FPR = 0.4
 Specificity = 1-FPR = 0.6

		Point D	
		Actual	
		+ve	-ve
Predicted	+ve	3	2
	-ve	2	3

TPR/Sensitivity = 0.6
 FPR = 0.4
 Specificity = 1-FPR = 0.6

C ve D noktaları arasında, aynı Özgüllük için C noktasındaki Hassasiyet D noktasından daha yüksektir. Bu, aynı sayıda yanlış sınıflandırılmış Negatif sınıf puanı için

sınıflandırıcının daha yüksek sayıda Pozitif sınıf puanı öngördüğü anlamına gelir. Bu nedenle, C noktasındaki eşik D noktasından daha iyidir.

E Noktası, Özgüllüğün en yüksek olduğu yerdir. Yani model tarafından sınıflandırılan Yanlış Pozitifler yoktur. Model, tüm Negatif sınıf puanlarını doğru bir şekilde sınıflandırabilir! Sorunumuz, kullanıcılarımıza mükemmel şarkı önerileri vermek olsaydı, bu noktayı seçerdik.

		Point E	
		Actual	
		+ve	-ve
Predicted	+ve	3	0
	-ve	2	5

TPR/Sensitivity = 0.6
FPR = 0
Specificity = 1-FPR = 1

Bu mantıkla hareket ederek, mükemmel bir sınıflandırıcıya karşılık gelen noktanın grafikte nerede olduğunu tahmin edebilir misiniz? Evet! Kartezyen düzlemde (0, 1) koordinatına karşılık gelen ROC grafiğinin sol üst köşesinde olacaktır. Burada hem Duyarlılık hem de Özgüllük en yüksek olur ve sınıflandırıcı tüm Pozitif ve Negatif sınıf noktalarını doğru bir şekilde sınıflandırır.

- **Gini Katsayısı:** Gini İndeksi olarak da bilinen sınıflandırma problemlerinde kullanılır. Değişkenlerin değerleri arasındaki belirsizliği belirler. Gini'nin yüksek değeri iyi bir modeli temsil eder.
- **Kök ortalama kare hatası:** Regresyon modelinin değerlendirilmesinde kullanılan en popüler metriklerden biridir. Hataların tarafsız olduğunu ve normal dağılıma sahip olduğunu varsayarak çalışır.
- **Çapraz Doğrulama:** Makine öğrenimi modelinin performansını değerlendirmek için bir başka popüler tekniktir. Bunda modeller, girdi verilerinin alt kümeleri üzerinde eğitilir ve verilerin tamamlayıcı alt kümesi üzerinde değerlendirilir.

Parametrik ve parametrik olmayan modeller

Makine öğrenmesinde temel olarak Parametrik ve Parametrik Olmayan olmak üzere iki tür model vardır. Burada parametreler, makine öğrenimi modelini oluşturmak için kullanılan tahmin değişkenleridir. Bu modellerin açıklaması aşağıda verilmiştir:

Parametrik Model: ML modelini oluşturmak için sabit sayıda parametre kullanır. **Veriler hakkında güçlü varsayımları dikkate alır.** Parametrik modellerin örnekleri, Lineer regresyon, Lojistik Regresyon, Naive Bayes, Perceptron, vb.'dir.

Parametrik Olmayan Model: Esnek sayıda parametre kullanır. **Veriler hakkında birkaç varsayımı dikkate alır. Bu modeller daha yüksek veriler için iyidir ve ön bilgi yoktur.** Parametrik olmayan modellere örnek olarak Karar Ağacı, K-En Yakın Komşu, Gauss çekirdekli SVM vb. verilebilir.

Parametrik ve parametrik olmayan modeller arasındaki farklar

Parametric model	Non-parametric model
It uses a fixed number of parameters to build the model.	It uses flexible number of parameters to build the model.
Considers strong assumptions about the data.	Considers fewer assumptions about the data.
Computationally faster	Computationally slower
Require lesser data	Require more data
Example – Logistic Regression & Naïve Bayes models	Example – KNN & Decision Tree models

Makine Öğrenmesinde Aşırı Uyum

Makine öğrenimi algoritması tüm veri noktalarını yakalamaya çalıştığında ve sonuç olarak gürültüyü de yakaladığında, modelde fazla uyum oluşur. **Bu fazla uydurma sorunu nedeniyle, algoritma düşük sapmayı, ancak çıktıda yüksek varyansı gösterir.** Aşırı uyum, makine öğrenimindeki ana sorunlardan biridir.

Veri aşırı uyum nasıl oluşur ve nasıl düzeltilebilir?

Aşırı uyum, istatistiksel bir model veya makine öğrenimi algoritması verilerin gürültüsünü yakaladığında meydana gelir. Bu, bir algoritmanın düşük yanlılık göstermesine ancak sonuçta yüksek varyans göstermesine neden olur.

Aşırı uyum, aşağıdaki metodolojiler kullanılarak önlenir:

ML'de Aşırı Uyumu Önleme Yöntemleri:

- Çapraz Doğrulama
- Daha fazla veri ile eğitim
- Düzenleme
- Topluluk
- Gereksiz Özelliklerin Kaldırılması
- Eğitimi Erken Durdurma.

Çapraz doğrulama: Çapraz doğrulamanın ardındaki fikir, birden çok mini tren testi bölmeleri oluşturmak için eğitim verilerini bölmektir. Bu bölmeler daha sonra modelinizi ayarlamak için kullanılabilir.

Daha fazla eğitim verisi: Makine öğrenimi modeline daha fazla veri beslemek, daha iyi analiz ve sınıflandırma yapılmasına yardımcı olabilir. Ancak, bu her zaman işe yaramaz.

Özelliklerin kaldırılması: Çoğu zaman, veri seti, analiz için gerekli olmayan alakasız özellikler veya tahmin değişkenleri içerir. Bu tür özellikler, yalnızca modelin karmaşıklığını artırır, böylece veri fazlalığı olasılıklarına yol açar. Bu nedenle, bu tür gereksiz değişkenler kaldırılmalıdır.

Erken durdurma: Bir makine öğrenimi modeli yinelemeli olarak eğitilir, bu, modelin her yinelemesinin ne kadar iyi performans gösterdiğini kontrol etmemizi sağlar. Ancak belirli sayıda yinelemeden sonra modelin performansı doygun hale gelmeye başlar. **Daha fazla eğitim, fazla uyumla sonuçlanacaktır, bu nedenle eğitimin nerede durdurulacağını bilmek gerekir. Bu, erken durdurma adı verilen bir mekanizma ile sağlanabilir.**

Düzenleştirme (Regularization): Düzenleme n sayıda yolla yapılabilir, yöntem uyguladığınız öğrenmenin türüne bağlı olacaktır. Örneğin, karar ağaçlarında budama yapılır, bırakma

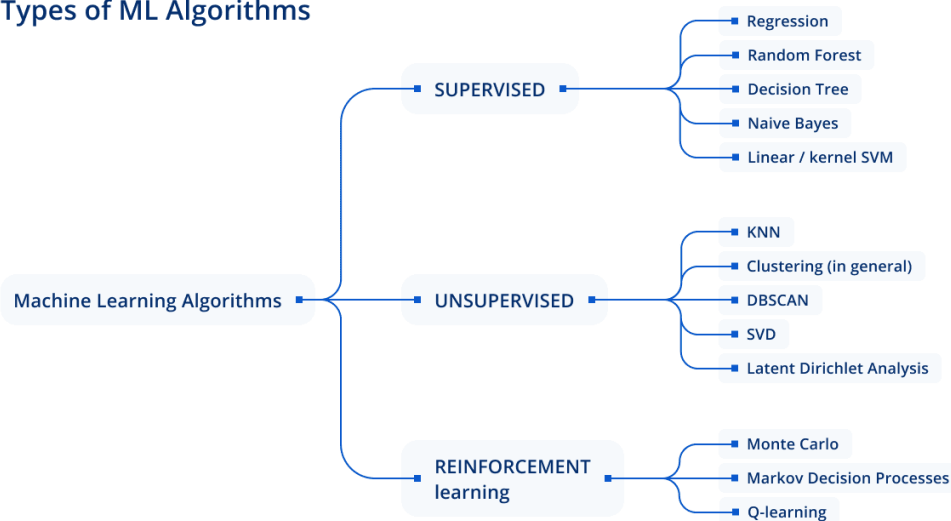
teknikçi sinir ağlarında kullanılır ve fazla uydurma sorunlarını çözmek için parametre ayarlama da uygulanabilir.

Topluluk modellerini kullanılması (Use Ensemble models): Topluluk öğrenimi, daha doğru sonuçlar üretmek için birleştirilen birden çok Makine Öğrenimi modeli oluşturmak için kullanılan bir tekniktir. Bu, aşırı uyumu önlemenin en iyi yollarından biridir. Bir örnek Rastgele Orman'dır, daha doğru tahminler yapmak ve fazla uydurmayı önlemek için bir karar ağaçları topluluğu kullanır.

How to Choose ML Algorithm

According to ML classification, there are supervised, unsupervised, and reinforcement learning options to be utilized for this business need. In supervised learning, we encounter an idea of training based on labeled input and output data. (Regression and classification are algorithms of this group.) As for unsupervised learning models, they require data with input features, but without labeled output and are capable of finding structures within the given data. (Segmentation and clustering belong to this category.) In the case of Reinforcement learning, ML models solve a task by improvising and through further analysis of the feedback regarding taken actions and solutions.

Types of ML Algorithms



mobidev

Once you've learned about the types of ML algorithms, you can take a look at a step-by-step guide to choosing an appropriate algorithm for business application:

1. Define the business problem and algorithms that are the most suitable for tackling it
2. Check available data (amount, characteristics, type, and behavior)
3. Think about optimal evaluation metric and speed
4. Decide on a suitable number of features and parameters

5. Stick to a baseline model or more sophisticated solution (if simple linear algorithms work well, there is no need to complicate the work)

With all the diversity of top Machine Learning algorithms, you might get confused about what method to choose. Try to adhere to a data-related or problem-related approach. Remember that better data is of greater significance than an algorithm, which can be easily enhanced by extending the training time. However, if you need to apply technology and drive significant business change, our [experienced AI engineers](#) are ready to help with choosing and implementing ML algorithms into your business.

Demand Forecasting Methods

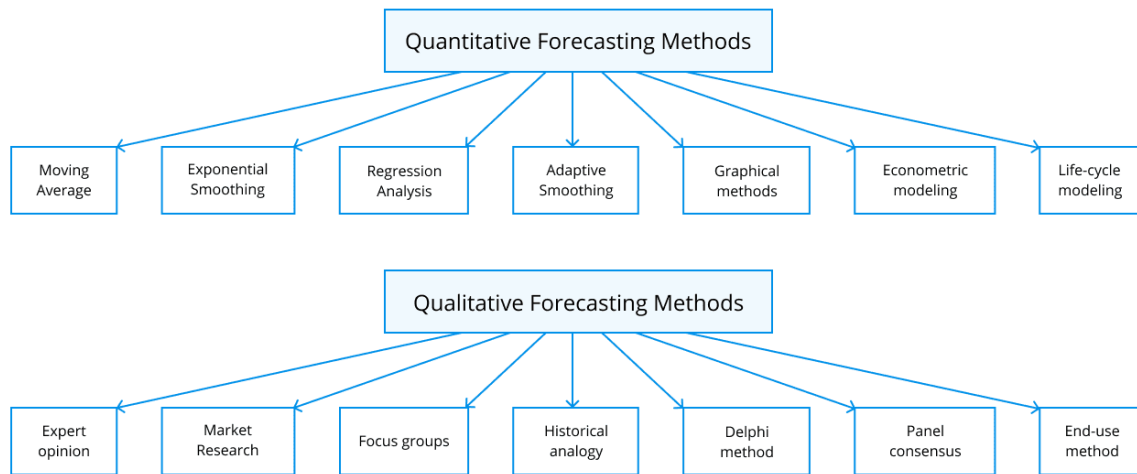
Demand forecasting is the process of predicting what the demand for certain products will be in the future. This helps manufacturers to decide what they should produce and guides retailers toward what they should stock.

Demand forecasting is aimed at improving the following processes:

- **Supplier relationship management.** By having the prediction of customer demand in numbers, it's possible to calculate how many products to order, making it easy for you to decide whether you need new supply chains or to reduce the number of suppliers.
- **Customer relationship management.** Customers planning to buy something expect the products they want to be available immediately. Demand forecasting allows you to predict which categories of products need to be purchased in the next period from a specific store location. This improves customer satisfaction and commitment to your brand.
- **Order fulfillment and logistics.** Demand forecasting features optimizing supply chains. This means that at the time of order, the product will be more likely to be in stock, and unsold goods won't occupy prime retail space.
- **Marketing campaigns.** Forecasting is often used to adjust ads and marketing campaigns and can influence the number of sales. This is one of the use cases of [machine learning in marketing](#). Sophisticated machine learning forecasting models can take marketing data into account as well.
- **Manufacturing flow management.** Being part of the ERP, the time series-based demand forecasting predicts production needs based on how many goods will eventually be sold.

There are methods of qualitative and quantitative demand assessment methods.

Demand Forecasting Methods



mobidev

Machine Learning Approach to Demand Forecasting Methods

The above-listed traditional sales forecasting methods have been tried and tested for decades. With Artificial Intelligence development, they are now upgraded by modern forecasting methods using Machine Learning (ML).

[Machine learning techniques](#) allows for predicting the amount of products/services to be purchased during a defined future period. In this case, a software system can learn from data for improved analysis. Compared to traditional demand forecasting methods, a machine learning approach allows you to:

- Accelerate data processing speed
- Provide a more accurate forecast
- Automate forecast updates based on the recent data
- Analyze more data
- Identify hidden patterns in data
- Create a robust system
- Increase adaptability to changes

How to Develop an ML-Based Demand Forecasting Software

When initiating the demand forecasting feature development, it's recommended that you understand the workflow of ML modeling. This offers a data-driven roadmap on how to optimize the development process.

Let's review the process of how [AI engineers at MobiDev](#) approach ML demand forecasting tasks.

Brief Data Review

The first task when initiating the demand forecasting project is to provide the client with meaningful insights. The process includes the following steps:

1. Gather available data
2. Briefly review the data structure, accuracy, and consistency
3. Run a few data tests and pilots
4. Look through a statistical summary

In my experience, a few days is enough to understand the current situation and outline possible solutions.

Goals And Success Metrics

This stage establishes the client's highlights of business aims and additional conditions to be taken into account. Our team provides [data science consulting](#) to combine it with the client's business vision. The goal is to achieve something similar to:

"I want to integrate the demand forecasting feature so to forecast sales and plan marketing campaigns."

Success metrics offer a clear definition of what is "valuable" within demand forecasting. A typical message might state:

"I need such machine learning solution that predicts demand for [...] products, for the next [week/month/a half-a-year/year], with [...]% accuracy."

These points will help you to identify what your success metrics look like. You will want to consider the following:

Product Type/Categories

What types of products/product categories will you forecast? Different products/services have different demand forecasting outputs. For example, the demand forecast for perishable products and subscription services coming at the same time each month will likely be different.

Time Frame

What is the length of time for the demand forecast?

Short-term forecasts are commonly done for less than 12 months – 1 week/1 month/6 month. These forecasts may have the following purposes:

- Uninterrupted supply of products/services
- Sales target setting and evaluating sales performance
- Optimization of prices according to the market fluctuations and inflation
- Finance maintenance
- Hiring of required specialists

Long-term forecasts are completed for periods longer than a year. The purpose of long-term forecasts may include the following:

- Long-term financial planning and funds acquisition
- Decision making regarding the expansion of business
- Annual strategic planning

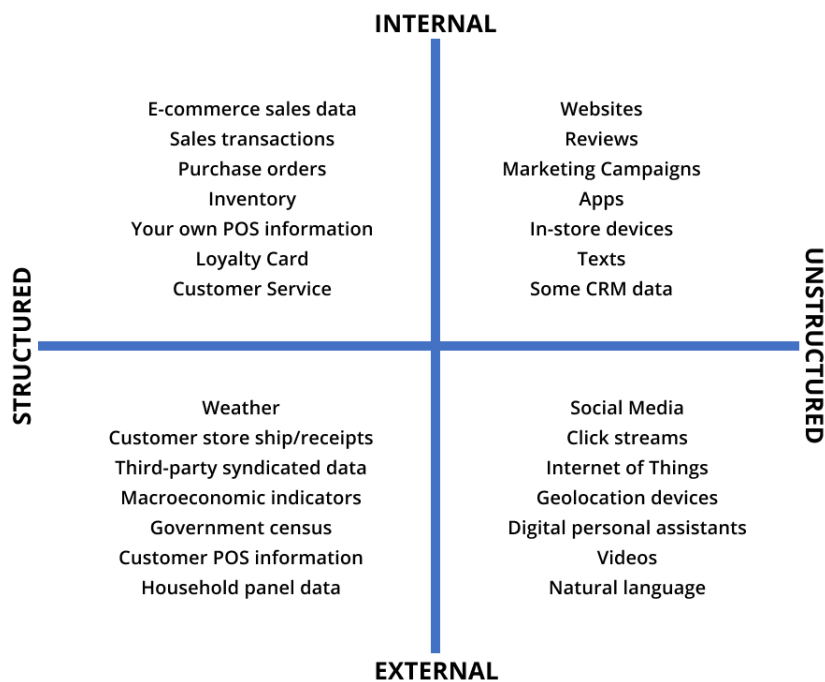
Accuracy

What is the minimum required percentage of demand forecast accuracy for making informed decisions? Implementing [retail software development](#) projects, we were able to reach an average accuracy level of 95.96% for positions with enough data. The minimum required forecast accuracy level is set depending on your business goals.

The example of metrics to measure the forecast accuracy are [MAPE](#) (Mean Absolute Percentage Error), [MAE](#) (Mean Absolute Error) or custom metrics.

Data Understanding & Preparation

Regardless of what we'd like to predict, data quality is a critical component of an accurate demand forecast. This following data could be used for building forecasting models:



Data Quality Parameters

When building a forecasting model, the data is evaluated according to the following parameters:

- Consistency
- Accuracy
- Validity
- Relevance
- Accessibility
- Completeness
- Detalization

In reality, the data collected by companies often isn't ideal. This data usually needs to be cleaned, analyzed for gaps and anomalies, checked for relevance, and restored. When developing [POS](#) applications for our retail clients, we use data preparation techniques that allow us to achieve higher data quality.

Once the data was cleaned, generated, and checked for relevance, we structure it into a comprehensive form. Below, you can see an example of the minimum required processed data set for demand forecasting:

Transactions Forecasting

Date	Product name	Quantity (Target)
2019-06-06 04:00:15	lime	500
2019-06-06 10:00:00	lime	100
2019-06-06 10:30:11	apple	250
2019-06-06 10:35:08	orange	300
2019-06-06 10:40:01	banana	750
...



Data understanding is the next task once preparation and structuring are completed. It's not modeling yet but an excellent way to understand data by visualization. Below you can see how we visualized *the data understanding process*:

Product Sales For The Last Year



Machine Learning Models Development

There are no “one-size-fits-all” forecasting algorithms. Often, demand forecasting features consist of several machine learning approaches. The choice of machine learning models depends on several factors, such as business goal, data type, data amount and quality, forecasting period, etc.

Here I describe those machine learning approaches when applied to our retail clients. But if you have already read some articles about demand forecasting, you might discover that these approaches work for most demand forecasting cases.

- ARIMA/SARIMA
- Linear Regression
- XGBoost
- K-Nearest Neighbors Regression
- Random Forest
- Long Short-Term Memory (LSTM)

TIME SERIES APPROACH

This involves processed data points that occur over a specific time that are used to predict the future. Time series is a sequence of data points taken at successive, equally-spaced points in time. The major components to analyze are: trends, seasonality, irregularity, cyclicity.

The analysis algorithm involves the use of historical data to forecast future demand. That historical data includes trends, cyclical fluctuations, seasonality, and behavior patterns.


In the retail field, the most applicable time series models are the following:

1. **ARIMA** (auto-regressive integrated moving average) models aim to describe the auto-correlations in the time series data. When planning short-term forecasts, ARIMA can make accurate predictions. By providing forecasted values for user-specified periods, it clearly shows results for demand, sales, planning, and production.
2. **SARIMA** (Seasonal Autoregressive Integrated Moving Average) models are the extension of the ARIMA model that supports uni-variate time series data involving backshifts of the seasonal period.
3. **Exponential Smoothing** models generate forecasts by using weighted averages of past observations to predict new values. The essence of these models is in combining Error, Trend, and Seasonal components into a smooth calculation.

DEMAND FORECASTING MODELS INTEGRATION



FORECAST ACCURACY



Training & Deployment

Training

Once the forecasting models are developed, it's time to start the training process. When training forecasting models, data scientists usually use historical data. By processing this data, algorithms provide ready-to-use trained model(s).

Validation

This step requires the optimization of the forecasting model parameters to achieve high performance. By using a cross-validation tuning method where the training dataset is split into ten equal parts. Data scientists train forecasting models with different sets of hyper-parameters. The goal of this method is to figure out which model has the most accurate forecast.

Improvement

When researching the best business solutions, data scientists usually develop several machine learning models. Since models show different levels of accuracy, the scientists choose the ones that cover their business needs the best. The improvement step involves the optimization of analytic results. For example, using model ensemble techniques, it's possible to reach a more accurate forecast. In that case, the accuracy is calculated by combining the results of multiple forecasting models.

Deployment

This stage assumes the forecasting model(s) integration into production use. We also recommend setting a **pipeline to aggregate new data** to use for your next AI features. This can save you a lot of data preparation work in future projects. Doing this also increases the accuracy and variety of what you could be able to forecast.

Sales Forecasting For Retail During Uncertainty

When integrating demand forecasting systems, it's essential to understand that they are vulnerable to anomalies like the COVID-19 pandemic. It means that machine learning models should be upgraded according to current reality.

As the demand forecasting model processes historical data, it can't know that the demand has radically changed. For example, if last year, we had one demand indicator for medical face masks and antiviral drugs, this year, it would be completely different.

In that case, there might be several ways to get an accurate forecast, here are the **main six** of them:

1. Collect data about new market behavior. Once the situation becomes more or less stable, develop a demand forecasting model from scratch.
2. Apply a feature engineering approach. By processing external data, news, a current market state, price index, exchange rates, and other economic factors, machine learning models are capable of making more up-to-date forecasts.
3. Upload the most recent POS data. The period of a loadable dataset might vary from one to two months, depending on the products' category. In this way, we can detect shifts in demand patterns and enhance forecast accuracy in a timely manner.

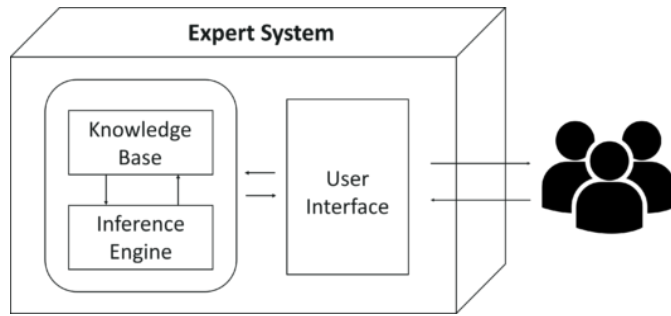
4. Apply the transfer learning approach. If there is any gathered historical data about past pandemics or similar behavior shifts, we can use them to predict demand in the context of the current crisis.
5. Apply information cascade modeling approach. Combining the most recent POS data with the cascade modeling, the demand forecasting system can identify herd patterns of human behavior. In other words, we can forecast how people will make buying decisions according to the behavior patterns of most people.
6. Apply natural language processing (NLP) approach. NLP technology enables the processing of real comments from social networks, media platforms, and other available social sources. By utilizing text mining and sentiment analysis approaches, NLP models gather samples of customer's conversations. This method allows the detection of people's preferences, choices, sentiment, and behavior shifts.

4. Yapay Zeka Uygulamaları

Makine öğrenimi, özellikle hemen hemen tüm sektörlerdeki işletmeler çeşitli makine öğrenimi teknolojilerini kullandığından, bilim kurgu çağından modern işletmelerin önemli bir bileşenine doğru ilerlemiştir. Örnek olarak, sağlık sektörü, daha doğru teşhisler elde etmek ve hastalarına daha iyi tedavi sağlamak için makine öğrenimi iş uygulamalarını kullanıyor.

Perakendeciler ayrıca, doğru malları ve ürünleri stoklar tükenmeden doğru mağazalara göndermek için makine öğrenimini kullanır. Pek çok kişi bu teknolojinin yardımıyla daha yeni ve daha etkili ilaçlar sunduğundan, tıp araştırmacıları da makine öğrenimini kullanma konusunda dışlanmış değil. Lojistik, üretim, konaklama, seyahat ve turizm, enerji ve kamu hizmetlerinde makine öğrenimi uygulandığı için tüm sektörlerden birçok kullanım örneği ortaya çıkıyor.

Uzman Sistemlerin bileşenleri



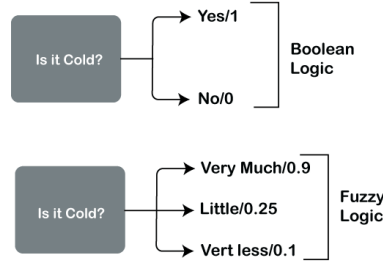
- Bilgi (**Knowledge**) tabanı: Özel ve yüksek kaliteli bilgi içerir.
- Çıkarım (Inference) Mantığı: Belirli bir çözüme ulaşmak için bilgi tabanından bilgiyi alır ve manipüle eder.
- Kullanıcı arayüzü (User Interface): Kullanıcı arayüzü, kullanıcı ile Uzman Sistemin kendisi arasında etkileşim sağlar.

Bir uzman sistem temel olarak üç bileşen içerir:

- Kullanıcı Arayüzü (User Interface): Bir problemin çözümünü bulmak için bir kullanıcının uzman sistemle etkileşime girmesini veya iletişim kurmasını sağlar.
- Çıkarım Mantığı (Inference Engine): Uzman sistemin ana işlem birimi veya beyni olarak adlandırılır. Bundan bir sonuç çıkarmak için bilgi tabanına farklı çıkarım kuralları uygular. Sistem, bir çıkarım motoru yardımıyla KB'den bilgileri çıkarır.
- Bilgi Bankası (Knowledge Base): Bilgi tabanı, alana özgü ve yüksek kaliteli bilgiyi depolayan bir tür depolama alanıdır.

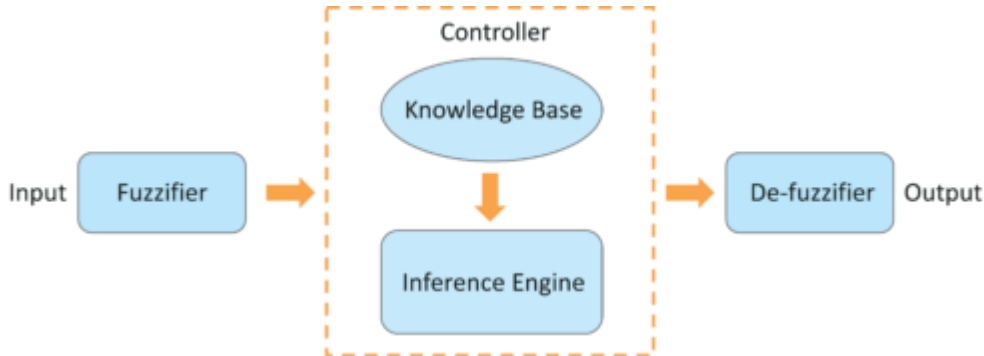
Bulanık mantık

Bulanık mantık, yapay zekaya uygulanan ve insan muhakemesine benzeyen bir akıl yürütme yöntemidir. Burada "bulanık" kelimesi net olmayan şeyleri tanımlar, durumun Doğru mu Yanlış mı olduğuna karar vermenin zor olduğu durumları ifade eder. Evet ile HAYIR arasında meydana gelen tüm olasılıkları içerir. Aşağıdaki şema, bulanık mantık ile Boolean mantığı arasındaki farkı göstermektedir.



İnsan muhakemesini andırdığı için sinir ağlarında kullanılabilir.

Bulanık Mantık mimarisi



- Bulanıklaştırma (**Fuzzification**) Modülü – Sistem girdileri, girdileri bulanık kümelere dönüştüren Bulanıklaştırıcıya beslenir.
- Bilgi (**Knowledge**) Tabanı – Uzmanlar tarafından sağlanan EVET-HAYIR kuralları gibi analitik ölçüleri depolar.
- Çıkarım Mantığı (**Inference**) – Girdiler ve IF-THEN kuralları üzerinde bulanık çıkarımlar yaparak insan akıl yürütme sürecini simüle eder.
- Durulaştırma (**Defuzzification**) Modülü – Çıkarım motoru tarafından elde edilen bulanık kümeyi kesin bir değere dönüştürür.

Oyun teorisinde Yapay Zeka

Oyun teorisi, iki veya daha fazla rasyonel oyuncu arasındaki olası etkileşimlerin bir modelini oluşturan mantıksal ve bilimsel çalışmadır. Burada rasyonel, her oyuncunun diğerlerinin de aynı derecede rasyonel olduğunu ve aynı düzeyde bilgi ve anlayışa sahip olduğunu düşünmesi anlamına gelir. Önyargılara dikkat edilmelidir. Oyun teorisinde, oyuncular çok etmenli bir durumda verilen seçenekler kümesiyle ilgilenir, bu, bir oyuncunun seçiminin diğer veya rakip oyuncuların seçimini etkilediği anlamına gelir.

Oyun teorisi,

- insan makine (yazılımsal - simülasyon ve optimizasyon, donanımsal) ilişkisi; bir işçi maden ocağına girmeden bir ofiste makineleri kullanarak maden çıkarabilir.
- Makinelerin ya da bilgisayar sisteminin makineleri yönettiği bir ortam olabilir.
- İşin içine insanlar da katılabilir; maden ocağında insanlar, makineler yapay zeka uygulaması ile birlikte çalışıyorlar.

Oyun teorisi ve yapay zeka birbiriyle çok ilgili ve kullanışlıdır. **Yapay zekada oyun teorisi, birden fazla oyuncunun bir hedefe ulaşmak için birbiriyle etkileşime girmeye çalıştığı çok etmenli ortamda gereken bazı temel yetenekleri etkinleştirmek için yaygın olarak kullanılır.**

Poker, Satranç vb. gibi farklı popüler oyunlar, **kuralları belirlenmiş mantıksal oyunlardır**. Bu oyunları çevrimiçi veya dijital olarak, örneğin Mobil, dizüstü bilgisayar vb.'de oynamak için, bu tür oyunlar için algoritmalar oluşturmak gerekir. Ve bu algoritmalar yapay zeka yardımıyla uygulanmaktadır.

Oyun teorisi ve AI ilişkisi

“Yapay zeka (AI) ve derin öğrenme sistemleri bağlamında, bir hedefe ulaşmak için farklı AI programlarının etkileşime girmesi veya rekabet etmesi gereken çok etmenli ortamlarda gerekli olan bazı temel yetenekleri etkinleştirmek için oyun teorisi esastır.”



Minimax Algoritması nedir? Bir Minimax probleminde yer alan terminolojileri açıklayın.

Minimax, diğer oyuncunun da en iyi şekilde oynadığını varsayarak bir oyuncu için en uygun hamleyi seçmek için kullanılan özyinelemeli bir algoritmadır.

Bir oyun, aşağıdaki bileşenlerle bir arama problemi olarak tanımlanabilir:

- **Oyun Ağacı:** Tüm olası hareketleri içeren bir ağaç yapısı.
- **Başlangıç durumu:** Başlangıç konumu ve kimin hamlesi olduğunu gösterir.
- **Ardıl işlevi:** Bir oyuncunun yapabileceği olası doğru hamleleri tanımlar.
- **Terminal durumu:** Oyun bittiğinde tahtanın konumudur.
- **Fayda işlevi:** Bir oyunun sonucu için sayısal bir değer atayan bir işlevdir.


Tic-Tac-Toe Game kullanarak Minimax algoritmasının çalışmasının gösterilmesi

Bir oyunda yer alan iki oyuncu vardır:

- **MAKS:** Bu oyuncu mümkün olan en yüksek puanı almaya çalışır.
- **MIN:** MIN mümkün olan en düşük puanı almaya çalışır.


Minimax algoritmasını kullanan bir Tic-Tac-Toe oyunu için aşağıdaki yaklaşım benimsenmiştir.

Adım 1: İlk olarak, oyunun mevcut konumundan başlayarak terminal durumlarına kadar tüm oyun ağacı oluşturulur.



Adım 2: Tüm terminal durumları için yardımcı program değerlerini almak için yardımcı program işlevini uygulanır.

Adım 3: Terminal düğümlerinin yardımcı programlarının yardımıyla daha yüksek düğümlerin yardımcı programları belirlenir. Örneğin, aşağıdaki şemada, karelerde yazılmış terminal durumları için yardımcı programlar var.



Terminalin üzerindeki katmanın sol düğümü(kırmızı) için yardımcı programı hesaplayalım:
 $MIN\{3, 5, 10\}$, yani 3.
 Bu nedenle, kırmızı düğüm için yardımcı program 3'tür.
 Benzer şekilde, aynı katmandaki yeşil düğüm için:
 $MIN\{2,2\}$, yani 2.

Adım 4: Fayda değerlerini hesaplayın.

Adım 5: Sonunda, yedeklenen tüm değerler ağacın köküne ulaşır. Bu noktada MAX, en yüksek değeri seçmelidir:

yani, 3 olan $MAX\{3,2\}$.

Bu nedenle, MAX için en iyi açılış hareketi sol düğümdür (veya kırmızı olan).

Özetlemek,

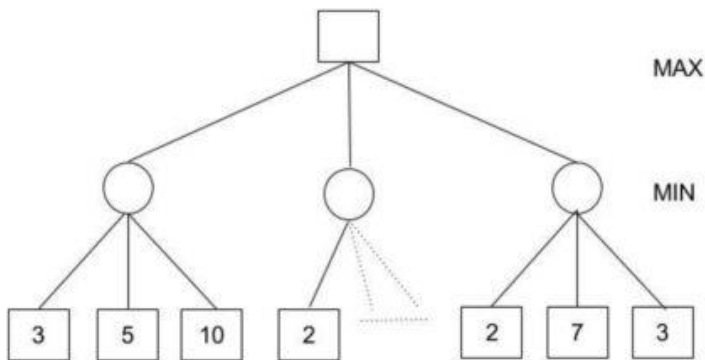
Minimaks Kararı = $MAKS\{MIN\{3,5,10\}, MIN\{2,2\}\}$

= $MAKS\{3,2\}= 3$

Minimax tabanlı bir oyunu optimize etmek

Alfa-beta Budama

Standart bir minimax algoritmasına alfa-beta budama uygularsak, standart olanla aynı hareketi döndürür, ancak muhtemelen nihai kararı etkilemeyen tüm düğümleri kaldırır.



Metaverse

Metaverse (Sanal evren, Evren Ötesi, Öte Evren), sanal ve artırılmış gerçeklik uygulamaları aracılığıyla kalıcı çevrimiçi 3-boyutlu sanal ortamları destekleyen, internet'in varsayımsal bir yinelemesidir. Aynı zamanda evren ötesi ya da öte evren olarak da adlandırılan Metaverse, bilgisayarlar, android cihazlar, VR (Virtual reality: Sanal Gerçeklik) lensler ve çeşitli 3D kullanıcı ara yüzleri sayesinde içinde bulunulan zaman ve mekân boyutundan uzaklaşarak, fiziksel olarak içinde bulunulan evrenin ötesine geçme potansiyeli olarak da tanımlanmaktadır. Metaverse 4. Sanayi devriminin çıktılarında bir tanesi Toplum 5.0 ve daha ilerisinin ise en görünür yaşam tarzlarından biri olmaya adaydır.

Bugün dünyadaki en önemli metaverse yatırımcılarının başında sanal gerçeklik cihazları üzerine çalışan Oculus şirketini 2 milyar dolara alan Facebook gelmektedir. Nitekim Facebook bu alanda Microsoft gibi önemli yazılım şirketleriyle iş birliği anlaşmaları imzalamıştır. Ayrıca Roblox gibi oyun platformları da bu alanda büyük arge yatırımları yapmaktadır.

Metaverse terimleri

1. Sanal Dünya: Sanal dünya, çok sayıda birey tarafından erişilebilen simüle edilmiş bir ortamdır. Sanal ortam, kullanıcının algısal verilerini ve gerçek zamanlı kullanıcı davranışlarını ve tartışmalarını görüntüler. Sanal gerçeklik şu anda video oyunlarında kullanılmaktadır, ancak gelecekte sanal toplantılarda, tıbbi eğitimde ve askeri eğitimde kullanıma potansiyeline sahiptir

2. Karma Gerçeklik: Karma gerçeklik kullanımları arasında video oyunları, eğitim, askeri eğitim, sağlık hizmetleri ve insan-robot işbirliği yer alır. Bir üniversite dersi sırasında sanal gerçeklik başlıklarında veya gözlüklerinde sunulan çizelgelerin veya kavramların 3D temsilleri gibi konuma özgü simülasyonlar, karma gerçeklik simülasyonlarının örnekleridir.

3.Artırılmış Gerçeklik: Artırılmış gerçeklik; grafikler, müzik, duyuşsal veriler veya koku alma verileri gibi dijital duyuşsal öğeleri birleştirerek gerçek dünyayı zenginleştirir. Müşterilerin bir ürünü kendileriyle karşılaştırılabilir bir durumda görselleştirmelerine yardımcı olmak için kullanılabilir.

4.Sanal Ekonomiler: "Sanal ekonomi" terimi, başlangıçta çevrimiçi oyunlarda sanal öğelerin alınıp satılması için kullanılmıştır.Bu oyunların birçoğunda, kullanıcılar birbirlerinden bir şeyler satın alabilir ve oyun parası için gerçek parayı takas edebilir. Kripto para birimleri ve takas edilemeyen tokenler sanal ekonomilerde kullanılabilir.

Artırılmış Gerçeklik Uygulamaları

Videolarda ya da resimlerde artırılmış gerçeklik uygulamaları: Işık ve gölge oyunları ile resimdeki bir cismin ön plana çıkarılması

GPT-4

GPT-4 (Generative Pre-trained Transformer 4), OpenAI tarafından oluşturulan çok modlu büyük bir dil modelidir. GPT serisinin dördüncüsüdür. 14 Mart 2023'te yayınlanmıştır ve API aracılığıyla ve ChatGPT Plus kullanıcıları için kullanılabilir olacaktır. Microsoft, GPT kullanan Bing sürümlerinin resmi yayınlanmadan önce aslında GPT-4 kullandığını doğruladı.

Yetenekleri

- GPT-4 daha karmaşık ve nüanslı girdileri anlayabilir. OpenAI'ye göre, GPT-4 " **çeşitli profesyonel ve akademik kriterlerde insan seviyesinde performans sergiliyor.**
- GPT-4 çok modlu yeteneklere sahiptir. Sadece metin değil, aynı zamanda görüntü ve video gibi diğer ortamları da işleyebilir.
- GPT-4 yüksek derecede yönlendirilebilirlik sunar. OpenAI ayrıca, kullanıcıların modelin çıktısını istedikleri şekilde etkileyebilecekleri ve yönlendirebilecekleri konusunda iddialıdır.
- GPT-4 daha güvenli ve yararlı yanıtlar üretir. OpenAI, GPT-4'ün zararlı veya yanlış bilgileri azalttığını ve kullanıcıların ihtiyaçlarına uygun yanıtlar verdiğini söylüyor.
- GPT-4 performans iyileştirmeleri sunar. OpenAI, GPT-4'ün önceki sürümlerine göre daha hızlı ve verimli olduğunu belirtiyor.

OpenAI tarafından geliştirilen ve çığır açan bir dil modeli olarak genel kabul gören ChatGPT, ilk duyurulduğundan bu yana dikkate değer bir evrim geçirdi. GPT-4 mimarisine dayanan ChatGPT, mevcut en gelişmiş yapay zeka dil modellerinden biri haline geldi ve kullanıcıların sistemle doğal ve dinamik konuşmalar yapmasına olanak sağladı.

ChatGPT'nin yolculuğu, 2018'de orijinal GPT ile başlayan GPT serisinin piyasaya sürülmesiyle başladı. Bu model, Vaswani ve diğerleri tarafından tanıtılan bir sinir ağı modeli olan Transformer mimarisine dayanıyordu.

OpenAI'nin 2019'da piyasaya sürülen GPT-2'si, tutarlı ve bağlamsal olarak alakalı metin oluşturma becerisiyle büyük ilgi gördü, ancak bu modellerin gerçek potansiyeli, 2020'de GPT-3'ün piyasaya sürülmesine kadar ortaya çıkmadı.

GPT-3'ün dikkate değer dil anlama ve oluşturma yetenekleri, ChatGPT'nin geliştirilmesi için de oldukça büyük bir zemin hazırladı.

Bu 10 maddede serimizde gündemden düşmeyen GPT-4'ün doğuşu, başarısı ve geliştiriciler için ne ifade ettiğini ele alacağız.

GPT-3'ün doğrudan soyundan gelen ChatGPT, kullanıcılarla daha doğal, dinamik konuşmalar yapmak için GPT-3 modülünü farklı bir platform üzerinde entegre etti. Model, konuşma bağlamında gelişmiş yanıtlar üretmesine izin veren İnsan Geri Bildiriminden (RLHF)

Güçlendirmeli Öğrenim kullanılarak günden güne geliştirildi. ChatGPT'nin ilk sürümleri, öncelikle araştırma ve deneyler için kullanılıyordu. Bununla birlikte OpenAI, geliştiricilerin ve araştırmacıların uygulama ve hizmetler oluşturması için API'ye sınırlı erişim sağlıyordu. Bu yüzden kullanıcıların ChatGPT'yi denemeyebilmesi için bir Waitlist beklemeleri gerekiyordu.

Teknoloji ve yapay zeka (AI) geliştikçe, bazı mesleklerin yapısı ve talebi değişir. GPT-4 ve benzeri AI teknolojileri, özellikle tekrarlayan ve düşük seviyeli analitik beceri gerektiren işleri otomatikleştirebilir. Bu, bazı işlerin ve mesleklerin risk altında olduğu anlamına gelir.

Ancak, AI aynı zamanda yeni iş olanakları ve sektörlerin gelişmesine de katkıda bulunabilir. Örneğin, AI ve teknoloji alanındaki işlerde, veri bilimi ve makine öğrenimi mühendisliği gibi rollerin talebi artmaktadır.

GPT-4 veya benzer AI sistemleri mesleğinizi elimizden alıp almayacağı, işinizin doğası ve ne kadar rutin ve öngörülebilir olduğuna bağlıdır. AI teknolojilerinin gelişmesiyle, insanlar daha yaratıcı, eleştirel düşünme ve insanlar arası iletişim becerilerine dayalı işlerde daha çok yer bulabilirler. Bu nedenle, AI sistemlerine uyum sağlamak ve teknolojiyi avantaja dönüştürmek için becerilerinizi geliştirmeye odaklanmanız önemlidir.

Sonuç olarak, GPT-4 ve benzeri AI sistemleri bazı mesleklerde işleri otomatikleştirebilir, ancak aynı zamanda yeni iş fırsatları da yaratabilir. AI'ye uyum sağlamak ve sürekli öğrenmeye odaklanmak, gelecekteki iş güvenliğinizi ve başarınızı sağlamak için önemlidir.

Gerçek zamanlı chatbot sistemleri

Chatbotlar, otomasyonun en önde gelen biçimlerinden biridir. Bireylerin dile getirdiği gereksinimlere veya isteklere göre eylemler gerçekleştirebilen makinelerle iletişim kurmamızı sağlayarak insanlarla teknoloji arasındaki iletişim boşluğunu kapattılar. İlk nesil sohbet robotları, botlara belirli anahtar kelimelere dayalı olarak hangi eylemlerin gerçekleştirileceği konusunda talimat veren komut dosyası kurallarına uyacak şekilde tasarlanmıştır.

Bununla birlikte, AI teknoloji gövdesinin bir başka parçası olan ML (makine öğrenimi) ve NLP (doğal dil işleme), sohbet robotlarının daha üretken ve daha etkileşimli olmasını sağlar. Bu yeni sohbet robotları, kullanıcıların ihtiyaçlarına daha iyi yanıt veriyor ve giderek daha fazla gerçek insan olarak iletişim kuruyor. Çağdaş sohbet robotlarının bazı dikkat çekici örnekleri arasında şunlar bulunmaktadır: Alexa, Google Asistan, Siri, Watson Asistan ve binicilerin talep hizmetindeki sohbet platformları.

Otomasyonun en eski biçimlerinden biri, insanların, daha sonra insanlar tarafından dile getirilen isteklere veya gereksinimlere dayalı olarak harekete geçebilen makinelerle esasen sohbet etmelerine izin vererek, insanlarla teknoloji arasındaki iletişim boşluğunu kapatan sohbet robotlarıdır. İlk nesil sohbet robotları, botlara anahtar kelimelere göre hangi eylemlerin gerçekleştirileceğini söyleyen komut dosyası kuralları izledi.

Bununla birlikte, yapay zeka teknoloji ailesinin bir başka üyesi olan makine öğrenimi ve doğal dil işleme veya NLP, sohbet robotlarının daha etkileşimli ve daha üretken olmasını sağlar. Bu yeni sohbet robotları, kullanıcının ihtiyaçlarına daha iyi yanıt veriyor ve giderek daha fazla gerçek insanlar gibi sohbet ediyor. ABI Research baş analisti Lian Jye Su, "Siri, Google Asistan ve Alexa gibi dijital asistanlar, makine öğrenimi algoritmalarına dayanıyor ve bu teknoloji, geleneksel sohbet robotlarının yerini alan yeni müşteri hizmetleri ve etkileşim platformlarında yolunu bulabilir" dedi. .

Chatbotlar, iş dünyasında en yaygın kullanılan makine öğrenimi uygulamaları arasındadır.

IBM tarafından "hızlı, anlaşılır yanıtlar" sağlamasıyla lanse edilen Watson Assistant, ne zaman netlik istemesi gerektiğini ve isteği bir insana ne zaman önceliklendirmesi gerektiğini bilmek üzere programlanmıştır.

Müzik akışı platformunun Facebook Messenger botu, kullanıcıların müzik dinlemesine, aramasına ve paylaşmasına ve öneriler almasına olanak tanır.

Biniciler, sohbet platformları aracılığıyla veya sesli olarak hizmet talep eder ve sürüşlerini tespit etmek için sürücü plakasının ve araba modelinin görüntüleri gönderilir.

Karar desteđi

Bu, makine öğrenimi iş uygulamalarının kuruluşlara sahip oldukları verilerin çođunu deđer sunan yararlı ve yürütülebilir içgörülere dönüştürmede yardımcı olabileceđi başka bir yöndür. Bu alanda, çeşitli ilgili veri kümeleri ve geçmiş veriler üzerinde eğitilmiş algoritmalar, bilgileri analiz edebilir ve çok sayıda olası senaryoyu, insanların benimsemesi gereken en iyi eylem planını önermesi imkansız olan bir ölçekte ve hızda işleyebilir. Karar destek sistemleri, bazıları sađlık sektörü, tarım sektörü ve işletmeyi içeren çeşitli endüstri sektörlerinde kullanılmaktadır.

Karar desteđi, makine öğreniminin işletmelerin sahip oldukları çok sayıda veriyi deđer sađlayan eyleme geçirilebilir içgörülere dönüştürmesine yardımcı olabileceđi başka bir alandır. Burada, geçmiş veriler ve diđer ilgili veri kümeleri üzerinde eğitilmiş algoritmalar, bilgileri analiz edebilir ve insanların en iyi eylem planına ilişkin önerilerde bulunması imkansız olan bir ölçekte ve hızda birden fazla olası senaryoyu çalıştırabilir.

İnsanların yerini almaz, aksine insanların işleri daha iyi yapmasına yardımcı olur; insanları çok daha etkili hale getirebilir.

Karar destek sistemlerinin çeşitli endüstri sektörlerinde nasıl kullanıldığına dair bazı örnekler:

Sađlık sektöründe, makine öğrenimini içeren klinik karar destek araçları, klinisyenlere teşhis ve tedavi seçenekleri konusunda rehberlik ederek hasta bakıcı verimliliđini ve hasta sonuçlarını iyileştirir.

Tarımda, makine öğrenimi destekli karar destek araçları, çiftçilerin ürün yönetimi konusunda karar vermelerine yardımcı olmak için iklim, enerji, su, kaynaklar ve diđer faktörlerle ilgili verileri birleştirir.

İş dünyasında karar destek sistemleri, yönetimin eğilimleri tahmin etmesine, sorunları belirlemesine ve kararları hızlandırmasına yardımcı olur. Bilgiler, çizelgeler ve diđer grafikler şeklinde yönetici panoları aracılıđıyla sunulur.

Müşteri tavsiye motorları

ML, özelleştirilmiş deneyimler sunmak ve genel müşteri deneyimini geliştirmek için oluşturulmuş müşteri tavsiyesi motorlarına güç sağlar. Burada algoritmalar, müşterinin önceki satın alımları ve demografik eğilimler, bir kuruluşun mevcut envanteri ve diğer müşterilerin satın alma geçmişleri gibi diğer veri kümeleri de dahil olmak üzere her bir müşteri hakkındaki veri noktalarını analiz eder ve her birine tavsiye olarak hangi hizmetlerin ve ürünlerin sunulacağını bilmek için bireysel müşteri. Aşağıdakiler, kurumsal modelleri öneri motorlarına dayanan birkaç işletme örneğidir: Amazon, Walmart, Netflix ve YouTube.

Makine öğrenimi, müşteri deneyimini geliştirmek ve kişiselleştirilmiş deneyimler sağlamak için tasarlanmış müşteri tavsiye motorlarına güç sağlar. Bu kullanım durumunda, algoritmalar, müşterinin geçmiş satın almaları gibi bireysel bir müşteri hakkındaki veri noktalarını ve ayrıca hangi ürün ve hizmetlerin önerileceğini belirlemek için bir şirketin mevcut envanteri, demografik eğilimleri ve diğer müşterilerin satın alma geçmişleri gibi diğer veri kümelerini işler. her bir müşteriye.

İş modelleri tavsiye motorlarına dayanan birkaç şirket örneği:

Amazon ve Walmart gibi büyük e-ticaret şirketleri, alışveriş deneyimini kişiselleştirmek ve hızlandırmak için öneri motorlarını kullanıyor.

Bu makine öğrenimi uygulamasının bir başka iyi bilinen dağıtıcısı, bir müşterinin izleme geçmişini, benzer eğlence ilgi alanlarına sahip müşterilerin izleme geçmişini, bireysel şovlar hakkında bilgileri ve müşterilerine kişiselleştirilmiş öneriler sunmak için diğer veri noktalarını kullanan akıllı eğlence hizmeti Netflix'tir. .

Çevrimiçi video platformu YouTube, kullanıcıların zevklerine uygun videoları hızla bulmalarına yardımcı olmak için öneri motoru teknolojisini kullanır.

Müşteri kaybı modellemesi

İşletmeler ayrıca, bir müşterinin sadakatinin ne zaman azalmaya başladığını belirlemek ve bunu çözmek için stratejiler bulmak için makine öğrenimi ve yapay zekayı kullanır. Bu kullanım durumunda, gelişmiş makine öğrenimi iş uygulamaları, işletmelere en uzun ve en yaygın kurumsal sorunlardan biri olan müşteri kaybıyla başa çıkmada yardımcı olur.

Bu şekilde algoritmalar, bir şirketin müşteri kaybının arkasındaki nedeni tam olarak belirlemek ve anlamak için büyük hacimli satışlardaki eğilimleri, geçmiş ve demografik verileri belirler. Kuruluş daha sonra, hangi müşterilerin işletmeyi bırakıp başka bir yere gitme olasılığının olduğunu bulmak, bu müşterilerin ayrılma kararının arkasındaki nedenleri belirlemek ve ardından işletmenin atması gereken adımları belirlemek için mevcut müşteriler arasındaki kalıpları değerlendirmek için ML yeteneklerini kullanabilir. onları tutmak için.

Aşağıdaki şirketler, kayıp modellemeyi kullanan işletmelere örnektir: The Wall Street Journal, Bloomberg News, The New York Times, Spotify, HBO, Amazon, Netflix, Salesforce ve Adobe.

İşletmelerin yapay zekayı ve makine öğrenimini kullanmalarının bir başka yolu da, bir müşteri ilişkisinin ne zaman kötüye gitmeye başladığını tahmin etmek ve bunu düzeltmenin yollarını bulmaktır. Bu şekilde, yeni ML yetenekleri, şirketlerin en eski tarihsel iş sorunlarından biriyle başa çıkmasına yardımcı olur: müşteri kaybı.

Burada algoritmalar, bir şirketin neden müşteri kaybettiğini belirlemek ve anlamak için büyük hacimli tarihsel, demografik ve satış verilerindeki kalıpları belirler. Şirket daha sonra, hangi müşterilerin işlerini başka bir yere götürme riski altında olduğu konusunda uyararak için mevcut müşteriler arasındaki davranışları analiz etmek, bu müşterilerin ayrılma nedenlerini belirlemek ve ardından şirketin onları elde tutmak için hangi adımları atması gerektiğini belirlemek için makine öğrenimi yeteneklerini kullanabilir.

Kayıp oranı, herhangi bir işletme için önemli bir performans göstergesidir, ancak özellikle abonelik tabanlı ve hizmet şirketleri için önemlidir. Müşteri kaybı modellemesini kullanan şirketlere örnekler aşağıdakileri içerir:

The New York Times, Bloomberg News ve The Wall Street Journal gibi medya şirketleri;
Netflix, Amazon, HBO ve Spotify gibi müzik ve film akışı şirketleri;
Salesforce (CRM yazılımı), Adobe (multimedya, pazarlama yazılımı) gibi hizmet olarak yazılım şirketleri ve büyük telekom şirketleri.

Dinamik veya talep fiyatlandırma stratejileri

İşletmeler, mevsimden hava durumuna ve günün saatine kadar belirli dinamiklerin ürün ve hizmetlere olan talebi nasıl etkilediğini anlamak için çok sayıda başka değişkene ilişkin veri kümelerinin yanı sıra geçmiş fiyatlandırma verilerini de incelemeye başlayabilir.

ML algoritmaları, bu tür verilerden öğrenebilir ve işletmelerin ürünlerini bu geniş ve bol değişkenlere göre dinamik olarak fiyatlandırmasına yardımcı olmak için içgörüyü daha fazla tüketici ve pazar verileriyle birleştirebilir - bu, işletmelerin gelirlerini en üst düzeye çıkarmasını sağlayan bir taktiktir.

Talep fiyatlandırmasının veya dinamik fiyatlandırmanın en belirgin örneği ulaşım sektöründe görülebilir. Bolt ve Uber'deki dalgalanma fiyatlandırması buna örnektir.

Şirketler, belirli dinamiklerin - günün zamanından hava durumuna ve mevsimlere kadar - mal ve hizmetlere olan talebi nasıl etkilediğini anlamak için bir dizi başka değişkene ilişkin veri kümeleriyle birlikte geçmiş fiyatlandırma verilerini araştırabilir. Makine öğrenimi algoritmaları bu bilgilerden öğrenebilir ve bu içgörüyü ek pazar ve tüketici verileriyle birleştirerek şirketlerin mallarını bu çok sayıda ve çok sayıda değişkene göre dinamik olarak fiyatlandırmasına yardımcı olur - bu, şirketlerin geliri en üst düzeye çıkarmasına yardımcı olan bir stratejidir.

Dinamik fiyatlandırmanın (bazen talep fiyatlandırması olarak da adlandırılır) en görünür örneği ulaşım endüstrisinde gerçekleşir:

Koşullar, okul tatil haftalarında aynı anda yolculuk yapmak isteyen insan sayısını veya uçak biletleri için çok yüksek fiyatları artırdığında, Uber'deki aşırı fiyat artışını düşünün.

Müşteri segmentasyonu ve pazar araştırması

Makine öğrenimi iş uygulamaları yalnızca işletmelerin fiyatları belirlemesine yardımcı olmakla kalmaz; ayrıca işletmelerin müşteri segmentasyonu ve tahmine dayalı envanter planlaması yoluyla uygun mal ve hizmetleri uygun alanlara uygun zamanda sağlamalarına yardımcı olurlar.

Örneğin perakendeciler, belirli bir satış noktasını etkileyen mevsimsel koşullara, o bölgenin demografisine ve sosyal medyadaki trend haberler gibi diğer veri noktalarına bağlı olarak satış noktalarından hangisinde en çok satacak envanteri tahmin etmek için ML'yi kullanır. Bu makine öğrenimi uygulaması herkes tarafından kullanılabilir! Sigorta endüstrisinden Starbucks'a.

Makine öğrenimi uygulamaları yalnızca şirketlerin fiyatları belirlemesine yardımcı olmaz; ayrıca şirketlerin tahmine dayalı envanter planlaması ve müşteri segmentasyonu yoluyla doğru ürünleri ve hizmetleri doğru zamanda doğru alanlara ulaştırmasına yardımcı olur. Örneğin perakendeciler, belirli bir mağazayı etkileyen mevsimsel faktörlere, o bölgenin demografisine ve sosyal medyada neyin trend olduğu gibi diğer veri noktalarına dayanarak hangi envanterin hangi mağazalarında en çok satacağını tahmin etmek için makine öğrenimini kullanıyor. UST Global'de baş mimar olan Adnan Masood, yapay zeka ve makine öğrenimi konusunda uzmanlaşmıştır.

Perakende için yapılmış bir öneri motoru olarak düşünün.

Benzer şekilde, makine öğrenimi uygulamaları işletmeler tarafından genel müşteri tabanlarındaki belirli segmentleri daha iyi anlamak için kullanılır; Örneğin perakendeciler, ister benzer yaşlara, ister gelirlere veya eğitim seviyelerine dayalı bir grup olsun, vb. belirli müşteri gruplarının satın alma alışkanlıklarına ilişkin içgörüler elde etmek için teknolojiyi kullanır, böylece stoklama gibi ihtiyaçlarını daha iyi hedefleyebilirler. Belirlenen segmentin en çok isteyeceği ürünlere sahip mağazalar.

Dolandırıcılık tespiti

Makine öğreniminin kalıpları deşifre etme ve bu eğilimlerin dışında ortaya çıkan anormallikleri anında tespit etme yeteneği, onu dolandırıcılık faaliyetlerini belirlemek için mükemmel bir araç haline getirir.

Nitekim finans sektöründeki işletmeler yıllardır bu yönde ML'yi başarıyla kullanıyorlar. Dolandırıcılık tespitinde makine iş uygulamalarının kullanımı şu sektörlerde görülebilir: perakende, oyun, seyahat ve finansal hizmetler. Makine öğreniminin kalıpları anlama ve bu kalıpların dışında kalan anormallikleri anında görme kapasitesi, onu dolandırıcılık faaliyetlerini tespit etmek için değerli bir araç haline getirir. Aslında finans kurumları bu alanda makine öğrenimini yıllardır başarıyla kullanıyor.

Şu şekilde çalışır: Veri bilimcileri, müşterinin kredi kartını ne zaman ve nerede kullandığı gibi bireysel bir müşterinin tipik davranışını anlamak için makine öğrenimini kullanır. Makine öğrenimi, diğer veri kümelerinin yanı sıra bu bilgileri alabilir ve hangi işlemlerin normal aralıkta olduğunu ve bu nedenle yasal olup olmadığını, hangi işlemlerin beklenen normların dışında olduğunu ve bu nedenle muhtemelen hileli olduğunu yalnızca milisaniyeler içinde doğru bir şekilde belirleyebilir. Endüstriler arasında dolandırıcılığı tespit etmek için makine öğrenimi uygulamaları şunları içerir:

- finansal hizmetler
- yolculuk
- oyun oynamak
- perakende

Görüntü sınıflandırma ve görüntü tanıma

Şirketler, görüntüleri anlamlandırmalarına yardımcı olmak için sinir ağlarına, derin öğrenmeye ve makine öğrenimine yönelmeye başladı. Bu makine öğrenimi teknolojisinin uygulaması çok geniştir - Facebook'un platformunda yayınlanan resimleri etiketleme niyetinden, güvenlik ekiplerinin suç faaliyetlerini gerçek zamanlı olarak tespit etmeye yönlendirmesine ve otomatik arabaların yolu görmesi ihtiyacına kadar.

İşletmeler ayrıca, görüntülerden anlam çıkarmalarına yardımcı olmak için makine öğrenimi, derin öğrenme ve sinir ağlarına (kalıpları tanımak için tasarlanmış algoritmalar kümesi) yöneliyor. Bu makine öğrenimi teknolojisi, Facebook'un sitesinde yayınlanan fotoğrafları etiketleme isteğinden, güvenlik ekiplerinin gerçek zamanlı olarak suç davranışlarını belirleme çabasına, otomatik arabaların yolu görme ihtiyacına kadar geniş bir uygulama alanına sahiptir.

Perakendeciler ayrıca aşağıdakiler de dahil olmak üzere görüntü sınıflandırma ve görüntü tanıma için bir dizi uygulamaya sahiptir:

robotları bilgisayarla görme ve makine öğrenimi ile donatarak hangi ürünlerin stokta olmadığını veya stokta olmadığını veya yanlış yerleştirildiğini belirlemek için rafları taramak; tüm ürünlerin alışveriş sepetlerinden çıkarılmasını ve satın alınmak üzere taranmasını sağlamak için görüntü tanımayı kullanmak, böylece kasıtsız satış kayıplarını sınırlamak; ve hırsızlık gibi şüpheli faaliyetleri tespit etmek ve tehlikeli ekipmanların yetkisiz kullanımı gibi iş yeri güvenlik ihlallerini tespit etmek için görselleri analiz ederek güvenli olmayan koşullarla mücadele etmek.

Operasyonel verimlilik

Bazı ML kullanım durumları yüksek bir uzmanlığa sahip olsa da, birçok şirket, yazılım geliştirme ve finansal işlemler gibi rutin kurumsal süreçleri yönetmede kendilerine yardımcı olacak teknolojiyi benimsiyor. Guptill'e göre, "Tecrübemde (şimdiye kadar) en yaygın olarak görülen kullanım örnekleri, kurumsal finans organizasyonları, üretim sistemleri ve süreçleri ve en etkili şekilde yazılım geliştirme ve testtir.

Ve hemen hemen her vaka homurdanma işinde gerçekleşir". Makine öğrenimi, bu süreci büyük ölçüde artırmak ve geliştirmek için yazılım testi otomasyonunun bir bileşeni olarak makine öğrenimini kullanabilen operasyon ekipleri, finans firmaları ve departmanları ve BT departmanları dahil olmak üzere çeşitli iş departmanları tarafından verimliliği artırmak için kullanılır.

Bazı makine öğrenimi kullanım durumları son derece uzmanlaşmış olsa da, birçok şirket, finansal işlemler ve yazılım geliştirme gibi rutin iş süreçlerinin ele alınmasına yardımcı olmak için teknolojiyi uyguluyor.

Guptill, "Deneyimlerime göre (şimdiye kadar) en yaygın olarak görülen kullanım örnekleri, kurumsal finans organizasyonları, üretim sistemleri ve süreçleri ve en etkili şekilde yazılım geliştirme ve testtir. Ve hemen hemen her vaka, homurdanan işlerde gerçekleşir."

Makine öğrenimi, aşağıdakiler de dahil olmak üzere birçok işletme departmanında verimliliği artırmak için kullanılır:

İş hızlandırmak ve insan hatasını azaltmak için makine öğrenimini kullanan finans departmanları ve firmalar;
ekipmanı izlemek ve bakım ve onarımların ne zaman gerekli olacağını önceden belirlemek için makine öğrenimi tabanlı çözümleri kullanan operasyon ekipleri; ve bu süreci önemli ölçüde hızlandırmak ve iyileştirmek için yazılım testi otomasyonunun bir parçası olarak makine öğrenimini kullanabilen bilgi teknolojisi departmanları, daha iyi yazılımların daha hızlı ve daha düşük maliyetlerle geliştirilmesini sağlar.

Veri çıkarma

Doğal dil işlemeli ML, gerekli veriler yarı yapılandırılmış veya yapılandırılmamış formatlarda saklansa bile, önemli yapısal bilgileri belgelerden otomatik olarak toplayacaktır. İşletmeler bu ML uygulamasını faturalardan vergi belgelerine ve yasal sözleşmelere kadar her şeyi işlemek için kullanabilir, bu da bu tür süreçlerde daha fazla doğruluk ve daha yüksek verimlilik sağlar ve sonuç olarak insan çalışanlarını monoton, tekrarlayan görevlerden kurtarır.

NLP ile makine öğrenimi, gerekli bilgiler yapılandırılmamış veya yarı yapılandırılmış biçimlerde tutulsa bile, belgelerdeki yapılandırılmış verilerin önemli parçalarını otomatik olarak tanımlayabilir.

Scott Likens, yeni hizmetler ve gelişen teknoloji uygulamalarının lideri PwC Scott Likens Danışmanlık firması PwC'nin yeni hizmetleri ve gelişen teknoloji uygulamalarının lideri Scott Likens, "Belgeleri anlamak için makine öğrenimini kullanmak, endüstriler arasında büyük bir fırsattır" dedi.

Kuruluşlar, vergi formlarından faturalara ve yasal sözleşmelere kadar her şeyi işlemek için kullanılabilir, bu tür süreçlere daha fazla verimlilik ve gelişmiş doğruluk getirir ve insan yeteneklerini sıradan, tekrarlayan işlerden kurtarır. Bu bir kullanım durumu, dedi, "seksi değil, ancak herhangi bir iş için gerçek bir değer."

Hedef Pazar oluşturmada makine öğrenmesi

Hedef Pazarlama, bir pazarı segmentlere ayırmayı ve onu, ihtiyaç ve istekleri ürününüzle en yakından eşleşen müşterilerden oluşan birkaç ana segmente yoğunlaştırmayı içerir. Yeni işler çekmenin, satışlarınızı artırmanın ve şirketi büyütmenin anahtarıdır. Hedef pazarlamanın güzelliği, pazarlama çabalarınızı belirli tüketici gruplarına hedefleyerek, ürünlerinizin ve/veya hizmetlerinizin tanıtımını, fiyatlandırılmasını ve dağıtımını daha kolay ve daha uygun maliyetli hale getirmesidir.



Hedeflenen pazarlamada Makine Öğrenimi:

- Metin Analitiği Sistemleri (*Text Analytics Systems*): Metin analitiği uygulamaları, arama uygulamalarından, metin sınıflandırmasından, adlandırılmış varlık tanımadan kalıp arama ve değiştirme uygulamalarına kadar uzanır.
- Kümeleme (Clustering): Müşteri segmentasyonu, hızlı arama ve görselleştirme gibi uygulamalarla.
- Sınıflandırma (Classification): Pazarlamada metin sınıflandırması için kullanılabilen karar ağaçları ve sinir ağı sınıflandırıcıları gibi.

- Öneri Sistemleri(*Recommender Systems*): Ve pazarlama verilerinizi analiz etmek için kullanılacak birliktelik kuralları
- Pazar Sepeti Analizi (*Market Basket Analysis*): Pazar sepeti analizi, sık kullanılan ürünlerin kombinasyonlarını açıklar.


Pazar sepeti analizi

Pazar sepeti analizi, öğeler arasındaki ilişkileri bulmak için popüler bir tekniktir. Büyük perakendeciler tarafından maksimum kar elde etmek için sıklıkla kullanılır. Bu yaklaşımda, sıklıkla birlikte satın alınan ürünlerin kombinasyonlarını bulmamız gerekiyor.

Örneğin, bir kişi ekmek alırsa, tereyağı da alma şansı çok yüksektir. Bu nedenle, bu tür korelasyonları anlamak, perakendecilerin müşterilerine uygun teklifler sunarak işlerini büyütmelerine yardımcı olabilir.

'Bunu alan müşteriler bunu da aldı...' Amazon'da alışveriş yaparken bunu sıklıkla görüyoruz. Öneri motorlarının arkasındaki mantık nedir?

Amazon gibi e-ticaret siteleri, müşterilerine ürün önermek için Machine Learning'den yararlanır. Bu tür bir önerinin temel fikri, işbirlikçi filtrelemeden gelir. Ortak filtreleme, benzer alışveriş davranışına sahip yeni bir kullanıcıya ürün önermek için benzer alışveriş davranışlarına sahip kullanıcıları karşılaştırma işlemidir.



Bunu daha iyi anlamak için bir örneğe bakalım. Diyelim ki spor meraklısı bir A kullanıcısı pizza, makarna ve kola satın aldı. Şimdi birkaç hafta sonra, bisiklete binen başka bir B kullanıcısı pizza ve makarna alıyor. Kola satın almıyor, ancak alışveriş davranışları ve yaşam tarzı A kullanıcısına oldukça benzediği için Amazon B kullanıcısına bir şişe kola öneriyor. İşbirlikçi filtreleme bu şekilde çalışır.

Pazar sepeti analizinde makine öğrenmesi algoritmaları

Pazar sepeti analizi, işlemlerde sıklıkla birlikte ortaya çıkan ürün kombinasyonlarını açıklar. Örneğin, bir kişi ekmek alırsa, tereyağı da alma olasılığı %40'tır. Ürünler arasındaki bu tür korelasyonları anlayan şirketler, bu tür ürünler üzerinde ilgili teklifler ve indirim kodları vererek işlerini büyütebilirler.

Pazar Sepeti Analizi, piyasadaki hemen hemen her büyük perakendeci tarafından takip edilen iyi bilinen bir uygulamadır. Bunun arkasındaki mantık, Association Rule Mining ve Apriori algoritması gibi Makine Öğrenimi algoritmalarıdır:

- *Birliktelik kuralı madenciliği, öğelerin birbirleriyle nasıl ilişkilendirildiğini gösteren bir tekniktir.*
- *Apriori algoritması, birliktelik kuralları oluşturmak için sık öğe kümelerini kullanır. Bir sık öğe kümesinin bir alt kümesinin aynı zamanda bir sık öğe kümesi olması gerektiği kavramına dayanır.*

A ⇒ B

Örneğin, yukarıdaki kural, bir kişi A öğesini satın alırsa, B öğesini de satın alacağını önerir. Bu şekilde perakendeci, A ve B Öğelerini satın aldığıında %30 indirim olacağını belirten bir indirim teklifi verebilir. C maddesine göre. Bu tür kurallar Machine Learning kullanılarak oluşturulur. Bunlar daha sonra satışları artırmak ve bir işi büyütmek için ürünlere uygulanır.


Online alışveriş işinde önümüzdeki aylara ait satışları tahmin etmek için Doğrusal Regresyon

Geçmiş verileri inceleyerek ve satışların belirli bir süre içinde nasıl değiştiğini gösteren bir model oluşturarak yapılabilir. Doğrusal Regresyon, satışları tahmin etmek için kullanılan en iyi Makine Öğrenimi algoritmalarından biridir. Hem satış hem de zaman doğrusal bir ilişkiye sahip olduğunda, basit bir doğrusal regresyon modeli kullanmak en iyisidir.

Doğrusal Regresyon, bağımsız değişkenlerin (X) değerlerine dayalı olarak bağımlı değişkeni (Y) tahmin etme yöntemidir. Bazı sürekli miktarları tahmin etmek istediğimiz durumlar için kullanılabilir.

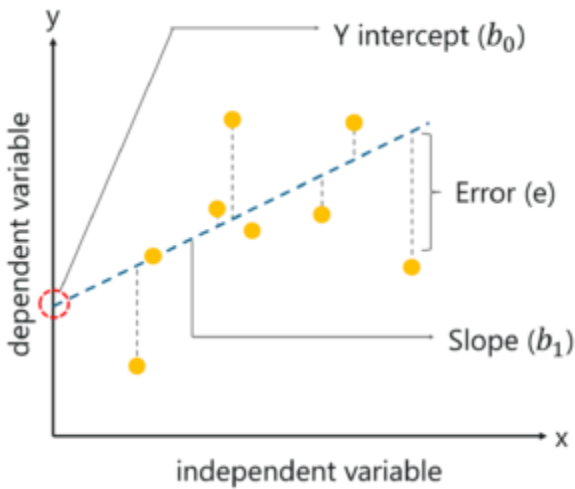
- Bağımlı değişken (Y): Değeri tahmin edilmesi gereken yanıt değişkeni.
- Bağımsız değişken (X): Yanıt değişkenini tahmin etmek için kullanılan tahmin değişkeni.

Bu örnekte, bağımlı değişken 'Y' satışları, bağımsız değişken 'X' ise süreyi temsil etmektedir. Satışlar belirli bir süre boyunca değiştiğinden, satışlar bağımlı değişkendir.



Doğrusal bir regresyon modelini temsil etmek için aşağıdaki denklem kullanılır:

$$Y = b_0 + b_1 x + e$$



Burada,

- Y = Bağımlı değişken
- b_0 = Y -Kesme
- b_1 = Çizginin eğimi
- x = Bağımsız değişken
- e = Hata


Bu nedenle, Y ekseninin satışları, X ekseninin ise dönemi ifade ettiği Lineer Regresyon modelini kullanarak, önümüzdeki aylardaki satışları kolayca tahmin edebiliriz.

Kredi onaylamada kullanılan makine öğrenmesi algoritması, KNN

Bu sorun ifadesi, başvuranın kredi talebini iki sınıfa ayıracak olan KNN algoritması kullanılarak çözülebilir:

1. Onaylandı
2. Onaylanmadı

K En Yakın Komşu, komşu veri noktalarının özelliklerine bağlı olarak yeni bir veri noktasını hedef sınıfa sınıflandıran bir Denetimli Öğrenme algoritmasıdır.



Bir kredinin onaylanması gerekip gerekmediğini tahmin etmek için aşağıdaki adımlar gerçekleştirilebilir:

Veri Çıkarma (Data Extraction): Bu aşamada ya anket yoluyla veriler toplanır ya da web kazıma yapılır. Müşteriler hakkında veriler toplanmalıdır. Buna hesap bakiyesi, kredi tutarı, yaş, meslek, kredi kayıtları vb. dahildir. Bu verileri kullanarak bir başvuru sahibinin kredisini onaylayıp onaylamayacağını tahmin edebiliriz.

Veri Temizleme (Data Cleaning): Bu aşamada gereksiz değişkenler kaldırılmalıdır. Bu değişkenlerden bazıları, örneğin Telefon, Eşzamanlı krediler vb. gibi değişkenler, bir başvuru sahibinin kredisini tahmin etmede önemli değildir. Bu tür değişkenler, yalnızca Makine Öğrenimi modelinin karmaşıklığını artıracaklarından kaldırılmalıdır.

Veri Keşfi ve Analizi (**Data Exploration & Analysis**): Bu, yapay zekadaki en önemli adımdır. Burada çeşitli yordayıcı değişkenler arasındaki ilişkiyi incelersiniz. Örneğin, bir kişinin ödenmemiş kredi geçmişi varsa, kredi başvurusunda bulunan kişiden onay alamama olasılığı vardır. Bu tür kalıplar bu aşamada tespit edilmeli ve anlaşılmalıdır.

Bir Makine Öğrenimi modeli oluşturma (**Building a Machine Learning model**): : Başvuru sahibi kredi talebinin onaylanıp onaylanmadığını tahmin etmek için kullanılacak n sayıda makine öğrenimi algoritması vardır. Böyle bir örnek, bir sınıflandırma ve bir regresyon algoritması olan K-En Yakın Komşudur. Başvuru sahibinin kredi talebini Onaylandı ve Onaylanmadı olmak üzere iki sınıfa ayıracaktır.

Model Değerlendirmesi (**Model Evaluation**): Burada, temel olarak makine öğrenimi modelinin verimliliğini test edersiniz. İyileştirme için herhangi bir yer varsa, parametre ayarı yapılır. Bu, modelin doğruluğunu artırır.

Görüntü sınıflandırmasında Denetimli veya denetimsiz sınıflandırma mı? Savunun.

- Denetimli sınıflandırmada, görüntüler, özellik sınıfları oluşturmak için Makine Öğrenimi uzmanı tarafından manuel olarak beslenir ve yorumlanır.
- Denetimsiz sınıflandırmada, Makine Öğrenimi yazılımı görüntü piksel değerlerine dayalı özellik sınıfları oluşturur.

Bu nedenle, doğruluk açısından görüntü sınıflandırması için denetimli sınıflandırmayı seçmek daha iyidir.


Bilgisayarla Görme, görüntülerden veya çok boyutlu verilerden bilgi elde etmek için kullanılan bir Yapay Zeka alanıdır. Görüntü Segmentasyonu için K-means gibi Makine Öğrenimi algoritmaları kullanılır, Görüntü Sınıflandırma için Destek Vektör Makinesi gibi algoritmalar da kullanılır.



Bu nedenle Computer Vision, Nesne Algılama, Görüntü İşleme vb. gibi karmaşık sorunları çözmek için AI teknolojilerini kullanır.

Görüntü işlemedeki sonlu fark filtreleri gürültüye karşı çok hassastır. Bununla başa çıkmak için, gürültüden kaynaklanan en az bozulma olması için kullanılan yöntem


Görüntü Yumuşatma (Image Smoothing), pikselleri komşularına daha çok benzemeye zorlayarak paraziti azaltmak için kullanılan en iyi yöntemlerden biridir; bu, kontrastlardan kaynaklanan bozulmaları azaltır.



Spam mesajlarını tespit etmek ve filtrelemek için maline öğrenmesi

Spam algılamayı anlamak için Gmail örneğini ele alalım. Gmail, bu tür istenmeyen iletileri gelen kutumuzdan filtrelemek için makine öğreniminden yararlanır. Bu spam filtreleri, e-postaları spam ve spam olmayan e-postalar olmak üzere iki sınıfa ayırmak için kullanılır.

Makine öğrenimi kullanılarak spam algılamının nasıl yapıldığını anlayalım:



- **Bir makine öğrenimi süreci her zaman veri toplama ile başlar.** Hepimiz Google'ın sahip olduğu verilerin kağıt dosyalarda olmadığını biliyoruz. Müşterinin verilerini tutan veri merkezlerine sahiptirler. E-posta içeriği, başlık, gönderen vb. veriler saklanır.

- Bunu veri temizliđi takip eder. Kesin bir makine öğrenimi modeli oluşturmak için yalnızca ilgili verilerin kullanılması için gereksiz duraklama sözcüklerinden ve noktalama işaretlerinden kurtulmak önemlidir. Bu nedenle, bu aşamada 'the', 've', 'a' gibi durak sözcükleri kaldırılır. Metin, analiz edilebilecek şekilde biçimlendirilmiştir.
- **Veri temizlemeden sonra veri keşfi ve analizi gelir.** Çođu zaman, belirli kelimeler veya ifadeler spam e-postalarda sıklıkla kullanılır. "Piyango", "kazan", "tam geri ödeme" gibi, **e-postanın spam olma olasılıđının daha yüksek olduđunu gösteren kelimelere belirlenir. Bu tür kelimeler ve ortak ilişkiler bu aşamada anlaşılmalıdır.**
- Verilerden faydalı bilgiler alındıktan sonra bir makine öğrenimi modeli oluşturulur. **E-postaları istenmeyen veya istenmeyen posta olarak sınıflandırmak için Lojistik Regresyon, Naïve Bayes vb. gibi makine öğrenimi algoritmalarını kullanabilirsiniz. Makine öğrenimi modeli, eğitim veri kümesi kullanılarak oluşturulur. Bu veriler, modeli eğitmek ve geçmiş kullanıcı e-posta verilerini kullanarak öğrenmesini sağlamak için kullanılır.**
- Bu aşamayı model deđerlendirmesi takip eder. Bu aşamada model, yeni bir dizi e-postadan başka bir şey olmayan **test veri seti kullanılarak test edilir.** Bundan sonra, makine öğrenimi modeli, e-postaları dođru bir şekilde sınıflandırabilme dođruluđuna göre derecelendirilir.
- Deđerlendirme sona erdikten sonra, birkaç deđerşken/parametre ayarlanarak modelde daha fazla iyileştirme sađlanabilir. Bu aşama aynı zamanda parametre ayarlama olarak da bilinir. Burada, temel olarak, modeli oluşturmak için kullandıđınız birkaç parametreyi deđerştirerek makine öğrenimi modelinin verimliliđini artırmaya çalışıyorsunuz.
- Son aşama dađıtımdır. Burada model, e-postaları gerçek zamanlı olarak işlediđi ve e-postanın spam olup olmadıđını tahmin ettiđi son kullanıcılara dađıtılır.

Apple'ın Vision Pro gözlüğünü, İnteraktif gözlük

Piyasadaki benzerlerinden farklı olarak Apple, pili üründen ayırmış, dolayısıyla gözlük başınızda ağırlık yapmıyor. Batarya bir kabloya bağlı şekilde yanınızda olmak zorunda. Cihaz açıldığında çevrenizdeki ortamı görüyorsunuz ama camın içinden görmek gibi değil. Cihazın önündeki kameralar vasıtasıyla görüyorsunuz. "Karma gerçeklik" deneyimi için bu önemli çünkü sanal öğeler çevrenize yansıtılıyor.

Gözlüğün sağ üst tarafında bir tuşa basıyorsunuz ve eğer iPhone kullanıyorsanız size tanıdık gelecek bazı uygulama sembolleri önünüze geliyor. iMessage, photos, Apple TV gibi... (Bunların sayıları artacak.)

Bundan sonrası ise tamamen sizin jest ve hareketlerinizle kontrol ediliyor. Cihaz nereye baktığınızı takip ediyor ve örneğin bir uygulamaya baktığınızda baş parmağınız ile işaret parmağınızı birlikte kullanarak onu açabiliyorsunuz. Fotoğraf galerisi çok etkileyiciydi. Tabii bunlar çok özenli şekilde hazırlanmış, güzel çekilmiş kareler.

Cihazdaki kameralarla 3D video çekmeniz mümkün. Canlı video görüşmesinde, gerçek görüntüsü yerine gerçekçi bir avatarıyla konuşulmakta. Dijital olarak karartılmış, sinema salonuna benzeyen bir odada sanal bir ekrana bakarak film bölümleri izlendiğinde üç boyutlu devasa bir T-Rex yüzünüze doğru solur. Bir de meditasyon sırasında dijital bir çiçeğin yapraklarının odada dolaştığını görürsünüz. Önünüzdeki görüntünün ne kadar içerisinde olacağınızı ayarlayabiliyorsunuz. Gözlükteki imajlar tüm odayı da kaplayabiliyor, karşınızdaki duvarda bir projeksiyon gibi küçük de görülebiliyor. Her durumda, eğer gerçek ortamda karşınızdaki birisi yürüyorsa onu görebiliyorsunuz.

Genelde karma gerçeklik cihazları, oyun sektörüne ya da büyük, abartılı deneyimlere hitap eder. Ev kadar büyük canavarı öldürmek ya da Wembley Stadyumu'nda sahnedeki bir rock star olmak gibi. Telefonunda yaptığın her şeyi, daha büyük, daha parlak şekilde ve evinin ortamında yap!

Yapay Ses

Şimdiye kadar hiç müzikle ilgili böyle bir hayal kurdunuz mu? En sevdiğiniz müzik türleri arasında geçiş olsa, mesela en sevdiğiniz şarkıcı, başkalarının şarkılarını farklı dilde bile olsa, söylese! Üstelik bu sadece başka dilde değil, hayata veda etmiş bir şarkıcı farklı şarkıları kendi sesi ile çok farklı zamanların şarkılarını seslendirse.

Üretken yapay zekanın yükselişi, tanınmış sanatçıların seslerini, şarkı sözlerini veya seslerini, genellikle rızaları olmadan inandırıcı bir şekilde taklit edebilen "deepfake" şarkılarda bir artışa neden oldu. Bu hayal Yapay Zeka sayesinde öylesine hızlı biçimde yayılmaya başladı ki; "Google ve Universal "deepfakes" konusunda anlaşmaya vardılar" bu dün Financial Times'da Anna Nikolaou ve Madhumite Murcia'nın kaleme aldıkları makalenin başlığı...

Sesleri taklit edebilen yeni teknoloji, giderek büyüyen bir trend. Müzik sektörü en büyük tehditlerinden birini paraya çevirmeye çalışırken Google ve Universal Music, yapay zeka tarafından üretilen şarkılar için sanatçıların melodilerini ve seslerini lisanslamak üzere görüşmeler yapıyor, Yeni yapay zeka teknolojisinin sonuçlarıyla boğuşan bir sektör için ortaklık kurmayı amaçlıyor.

Yapay zekanın ilgi görmeye başlamasıyla birlikte bazı büyük yıldızlar, çalışmalarının şarkılarının ve seslerinin sahte versiyonları tarafından sulandırılacağı endişesini dile getirdiler.

Bu arada, başkasının sesini, başka dilde duymak güzel bir deneyim. Peki ya sizin sesinizin, hiç olmadığınız yerde, hiç konuşmadıklarınızın kanıtı bir mahkemeye, iş görüşmesine veya eşinizin önüne gelse nasıl bir deneyim olurdu?

Yapay Zeka, tüm belaları ve mucizeleri ile geldi, bu treni kaçırmayın

5. Sorular

Q1. Ulusal bir fast food zinciri için çalışan veri bilimi ekibinin bir parçasısınız. Trendi gösteren basit bir rapor oluşturun: Mağazayı daha sık ziyaret eden ve daha küçük fiyatlı ürünleri satın alan müşteriler, daha az sıklıkta ziyaret eden ve daha büyük ürünleri satın alan müşterilerden daha fazla harcama yapar. Ekibinizin oluşturacağı en olası algoritma nedir?

- multiclass classification diagram
- **linear regression and scatter plots**
- pivot table
- K-means cluster diagram

Sınıflandırma için Naïve Bayes, Karar ağaçları, SVM, Random Forest sınıflandırıcı, KNN, lojistik regresyon gibi birçok algoritma kullanıyoruz. Dengesiz veri kümesine sahip birden fazla sınıfa sahip sınıflandırma problemleri, ikili bir sınıflandırma probleminden farklı bir zorluk sunar. Çarpık dağılım, birçok geleneksel makine öğrenimi algoritmasını, özellikle azınlık sınıfı örneklerini tahmin etmede daha az etkili hale getirir. **Çok Sınıflı Sınıflandırma:** İki'den fazla sınıfı olan bir sınıflandırma görevi; örneğin, portakal, elma veya armut olabilecek bir dizi meyve görüntüsünü sınıflandırılmasıdır. Çok sınıflı sınıflandırma, her örneğin bir ve yalnızca bir etikete atandığı varsayımını yapar: bir meyve, elma veya armut olabilir, ancak ikisi aynı anda olamaz.

Dağılım diyagramı, iki değişken arasındaki ilişkiyi göstermek için kullanılan son derece basit bir istatistiksel araçtır. Genellikle iki değişken arasına bir model uydurmak için kullanılan basit bir doğrusal regresyon çizgisi ile birleştirilir.

Pandalardaki özet tablo (**pivot table**), diğer iki kategorik değişkene dayalı olarak bir veya daha fazla sayısal değişkeni özetlemek için mükemmel bir araçtır. DataFrame olarak elektronik tablo stilinde bir pivot tablo oluşturun. Pandaların pivot tablosundaki seviyeler, DataFrame sonucunun indeksi ve sütunlarındaki Çoklu indeks nesnelere (hiyerarşik indeksler) saklanacaktır.

K-Means kümeleme, mevcut girdi verilerinin etiketli bir yanıtı olmadığı denetimsiz algoritmalarından biridir. K-Means kümeleme, denetimsiz bir öğrenme algoritmasıdır. Denetimli öğrenmenin aksine, bu kümeleme için etiketlenmiş veri yoktur. K-Means, nesnelere benzerlerini paylaşan ve başka bir kümeye ait nesnelere benzemeyen kümelere bölünmesini gerçekleştirir.

Q2.

Büyük şirketlere spam filtreleme hizmeti satan bir kuruluşta çalışıyorsunuz. Kuruluşunuz, ürününü makine öğrenimi algoritması kullanacak şekilde kullanmak istiyor. Şu anda 250 anahtar kelimedenden oluşan bir liste. Bir ileti bu anahtar kelimelerden beş adet anahtar kelime bulunduğunda spam olarak tanımlanır. Bu durumda makine öğrenimine geçmenin avantajlarından biri ne olabilir?

- Ürün, spam iletilerinde yeni kalıplar arar.
- Ürün, anahtar kelime listesinden çok daha hızlı geçebilir.
- Ürün çok daha uzun bir anahtar kelime listesine sahip olabilir.
- **Ürün, çok daha az anahtar kelime kullanarak spam iletileri bulabilir.**

Q3.

Bir müzik akışı hizmeti için çalışıyorsunuz ve müziği farklı türlere göre sınıflandırmak için denetimli makine öğrenimini kullanmak istiyorsunuz. Her türde binlerce şarkı toplandı ve siz bunun belirlediğiniz bir kısmını eğitim verisi olarak kullandınız. Şimdi hizmetinizdeki tüm şarkılardan rasgele küçük bir alt kümesini çıkarırsanız, amacınız nedir?

Soru: Bir müzik akışı hizmeti için çalışıyorsunuz ve müziği farklı türlere göre sınıflandırmak için hangii makine öğrenimini kullanırsınız?

Denetimli

Q4.

Geleneksel bilgisayar programcılığında komutlar girilir. Bu komutları veriler manipülasyon edilir (Aritmetik, karşılaştırma, mantıksal, transfer). Makine öğreniminde neyi kullanıyoruz?

- patterns
- programs
- rules
- **data**

Q5.

Şirketiniz, mevcut otomotiv sigortası müşterilerinin ev sahibi sigortası satın alma olasılığının daha yüksek olup olmadığını tahmin etmek istiyor. Ev sahibi sigortası hakkında en iyi müşteri temasını daha iyi tahmin etmek için bir model oluşturdu ve **modelin varyansı düşük, ancak yanlılığı yüksekti**. Bu, veri modeli hakkında ne denir?

- **Sürekli yanlıtı.**
- Tutarsız bir şekilde yanlıtı.
- Sürekli olarak doğruydu.
- Aynı derecede doğru ve yanlıtı.

Aşırı Uyum: Eğitim veri kümesi modeli ile test veri kümesinin aynı sonucu vermesidir. Test eğitim modelinin eğitim veri modeline çok benzerse aşırı uyum problemi kendini gösterir.

Varyans, Makine Öğrenimi bağlamında, bir modelin eğitim setindeki küçük dalgalanmalara duyarlılığı nedeniyle oluşan bir hata türüdür. Yüksek varyans, bir algoritmanın eğitim setindeki gürültüyü ya da hatayı modellemesine neden olur. Buna en yaygın olarak aşırı uyum denir.

Önyargı, Makine Öğrenimi bağlamında, öğrenme algoritmasındaki hatalı varsayımlar nedeniyle oluşan bir hata türüdür. Çoğu durumda, bu iki hatadan birini en aza indirmeye çalışmak, diğerini artırmaya yol açacaktır. Bu nedenle, ikisi genellikle bir değiş tokuş olarak görülür.

Q6.

İklim değişikliğinden etkilenmiş olabilecek küresel hava durumu modellerini belirlemek istiyorsunuz. Bunu yapmak için, bir insan meteoroloğu tarafından algılanamayacak olan kalıpları bulmak için makine öğrenimi algoritmalarını kullanmak istiyorsunuz. Başlamak için en iyi yer neresidir?

- Güneşli günlerin etiketli verileri bulunur, böylece makine kötü havayı tanımlamayı öğrenecektir.
- **Denetimsiz öğrenme kullanılır, makinenin devasa bir hava durumu veritabanındaki anormallikleri araması sağlanır.**
- Alışılmadık kalıplardan oluşan bir eğitim seti oluşturulur ve makine öğrenimi algoritmalarından bunları sınıflandırmasını istenir.
- Normal hava koşullarından oluşan bir eğitim seti oluşturulur ve makinenin benzer kalıpları araması sağlanır.

Q7.

naive Bayes sonucunun üzerinde çalışarak K-en yakın komşu sonucunun doğruluğunu artırmak isteyen bir veri bilimi ekibinde çalışıyorsunuz. Bu neyin örneği?

- Regresyon
- Yükseltme
- torbalama
- **Kümeleri yığınlara ayırma**

Regresyon, bağımsız değişkenler veya özellikler ile bağımlı değişken veya sonuç arasındaki ilişkiyi anlamaya yönelik bir yöntemdir. Bağımsız ve bağımlı değişkenler arasındaki ilişki tahmin edildikten sonra sonuçlar tahmin edilebilir. Bir ilişki var ise ve matematiksel olarak ifade edilir(fonksiyon, diferansiyen denklem, lineer denklem, algoritma). Regresyon, makine öğrenimindeki tahmin modellerinin önemli bir bölümünü oluşturan istatistiksel analize dayalı bir çalışma alanıdır. Tahmine dayalı modellemede sürekli sonuçları tahmin etmek için

bir yaklaşım olarak kullanılır, dolayısıyla verilerden sonuçları tahmin etme faydası vardır. Makine öğrenimi regresyonu genellikle veri noktalarından en uygun çizginin çizilmesini içerir. En uygun çizgiyi elde etmek için her nokta ile çizgi arasındaki mesafe en aza indirilir.

Yükseltme, tahmine dayalı veri analizindeki hataları azaltmak için makine öğreniminde kullanılan bir yöntemdir. Veri bilimciler, makine öğrenimi modelleri olarak adlandırılan makine öğrenimi yazılımlarını *etiketli veriler üzerinde eğiterek etiketsiz veriler hakkında tahminlerde bulunur*. Tek bir makine öğrenimi modeli, eğitim veri kümesinin doğruluğuna bağlı olarak tahmin hataları yapabilir. Örneğin, yalnızca beyaz kedi resimleriyle eğitilen bir kedi tanıma modeli, siyah bir kediyi bazen yanlış tanımlayabilir. Yükseltme, genel sistemin doğruluğunu geliştirmek için birden çok modeli sırayla eğiterek bu sorunun üstesinden gelmeye çalışır.

Önyükleme toplama olarak da bilinen torbalama, gürültülü bir veri kümesindeki varyansı azaltmak için yaygın olarak kullanılan topluluk öğrenme yöntemidir. Torbalamada, bir eğitim setindeki rastgele bir veri örneği değiştirilerek seçilir; bu, bireysel veri noktalarının birden fazla seçilebileceği anlamına gelir. Birkaç veri örneği oluşturulduktan sonra, bu zayıf modeller daha sonra bağımsız olarak eğitilir ve görev türüne (örneğin, regresyon veya sınıflandırma) bağlı olarak, bu tahminlerin ortalaması veya çoğunluğu daha doğru bir tahmin verir.

Bir not olarak, rasgele orman algoritması, ilintisiz bir karar ağaçları ormanı oluşturmak için hem çuvallamayı hem de özellik rasgeleliğini kullanan, torbalama yönteminin bir uzantısı olarak kabul edilir.

Topluluk öğrenimi, makine öğreniminin bir alt kümesidir. Birden fazla modelin çıktılarını entegre ederek (bütünleştirerek) bir modelin performansını optimize etmek (en iyileme) için kullanılır. Topluluk öğrenimi aynı zamanda modelin doğruluğunu da artırır. Makine öğreniminde yığınlama, verimli çıktılar alabildiğimiz tahmin modelleri için kullanılan bir topluluk algoritmasıdır. Bu nedenle İstiflemenin önemli avantajlarından bazıları gelişmiş doğruluk ve çeşitlendirilmiş eğilimlere sahip katmanlı modellerdir.

Q8. Tahmin ediciler ve sonucunuz arasındaki ilişkiyi belirlemede hangi algoritma kullanılır.

- **Regression analysis**
- K-means clustering
- Big data
- Unsupervised learning

Sayısal verileri tahmin etmek için hangi algoritma kullanılır?

Regresyon analizi, iki ya da daha çok nicel değişken arasındaki ilişkiyi ölçmek için kullanılan analiz metodudur.

K-araç kümeleme, n gözlemden her gözlemin en yakın ortalamaya sahip kümeye (küme merkezleri veya küme merkezi) ait olduğu k kümeye bölmeyi amaçlayan bir vektör niceleme yöntemidir.

Denetimsiz öğrenme, gözetimli öğrenmeden farklı olarak, verileri sebep-sonuç ya da giriş-çıkış şeklinde etiketlemeden, veri içerisinde var olan ilişkilerin ve yapıların öğrenilmesidir.

Q9.

Bir makine öğrenimi sistemi için ticari bir uygulama örneği nedir?

bir veri giriş sistemi

bir veri ambarı sistemi

devasa bir veri deposu (büyük bir veri deposu)

ürün tavsiye sistemi


Q10. What does this image illustrate?

a decision tree

reinforcement learning

K-nearest neighbor

a clear trendline



Q11.

Yüz binlerce elektrik aboneliği sahip bir elektrik şirketinde çalışıyorsunuz. Anonelerin sayaçları internete bağlıdır (Haberleşme: GSM, wifi, elektrik telleri üzerinden) ve enerji kullanım verilerini gerçek zamanlı olarak iletir. Yöneticiniz, bu kullanım verilerini analiz etmek için makine öğrenimini kullanmak üzere projeyi yönlendirmenizi ister. Bu senaryoda makine öğrenimi algoritmaları neden idealdir?

- Algoritmalar, sayaçların internete erişmesine yardımcı olacaktır.
- Algoritmalar kablosuz bağlantıyı geliştirecektir.
- **Algoritmalar, kuruluşunuzun veri kalıplarını görmesine yardımcı olur.**
- Makine öğrenimi algoritmalarını kullanarak bir IoT cihazı oluşturuyorsunuz.

Q12. To predict a quantity value. use ____.

- **regression**
- clustering
- classification
- dimensionality reduction

Makine Öğrenmesinde bir sayısal değeri tahmin etmek için ne kullanılır?

Q13. Why is naive Bayes called naive?

- It naively assumes that you will have no data.
- It does not even try to create accurate predictions.
- **It naively assumes that the predictors are independent from one another.**
- It naively assumes that all the predictors depend on one another.

Naive Bayes'e naive nedir?

- Saf bir şekilde hiçbir veriye sahip olmayacağını varsayar.
- Doğru tahminler oluşturmaya bile çalışmaz.
- **Tahmin edicilerin birbirinden bağımsız olduğunu saf bir şekilde varsayar.**
- Saf bir şekilde tüm tahmin edicilerin birbirine bağlı olduğunu varsayar.

Bayes: İki ve daha fazla makine üretim yapıyor. Her bir makinede üretilen ürünlerin bir kısmı hatalı olsun. Tüm hatalı ürünlerden bir küme oluşturulursa kesişim kümesi elde edilir.

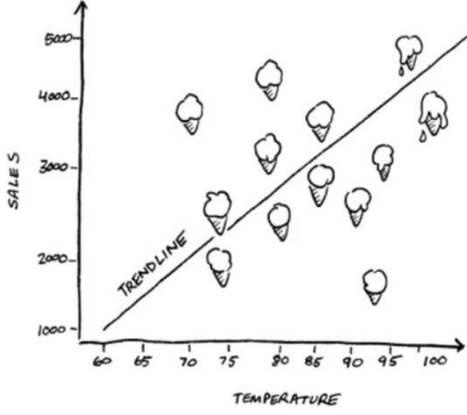
Tüm makinelerden üretilen toplam hatalı olma olasılığı= hatalı ürün sayısı/Toplam ürün sayısı
Bir makinedeki üretilen ürünün hatalı olma olasılığı= bu makine üretene hatalı ürün sayısı/Bu makinede üretilen toplam ürün sayısı

Hatalı kümesinden alınan bir ürünün hangi makineden geldiğini veren olasılık hesaplanabilir mi, evet. Bayes ...

Açıklama: Naive Bayes, her bir girdi değişkeninin bağımsız olduğunu varsaydığı için saf olarak adlandırılır. Bu güçlü bir varsayımdır ve gerçek veriler için gerçekçi değildir; bununla birlikte, teknik çok çeşitli karmaşık problemler üzerinde çok etkilidir.

Q14. You work for an ice cream shop and created the chart below, which shows the relationship between the outside temperature and ice cream sales. What is the best description of this chart?

- **It is a linear regression chart.**
- It is a supervised trendline chart.
- It is a decision tree.
- It is a clustering trend chart.



Bir dondurma dükkanında çalışıyorsunuz ve dış hava sıcaklığı ile dondurma satışları arasındaki ilişkiyi gösteren yukardaki grafiği oluşturduunuz. Bu grafiğin en iyi açıklaması nedir?

- **Doğrusal bir regresyon tablosudur.**
- Denetimli bir trend çizgisi grafiğidir.
- Bir karar ağacıdır.
- Bir kümelenme trend grafiğidir.

Her gün başı sıcaklık kayıt edilmektedir. Bu değerlerden saat başı sıcaklık derecesi bulunmak istenmektedir. Hangi algoritma kullanılır?

Q15.

Yapay zeka ile makine öğrenimi arasında nasıl bir ilişki var?

- Yapay zeka sınıflandırmaya odaklanırken, makine öğrenimi verileri kümeleme ile ilgilidir.
- **Makine öğrenimi, veriler yoluyla öğrenmeye dayanan bir tür yapay zekadır.**
- Yapay zeka, denetimsiz makine öğrenimi biçimidir.
- Makine öğrenimi ve yapay zeka aynı şeydir.

Q16.

Makine öğrenimi algoritmaları nasıl daha kesin tahminler yapar?

- Algoritmalar genellikle daha güçlü sunucularda çalıştırılır.
- **Algoritmalar, verilerdeki kalıpları görmede daha iyidir.**
- Makine öğrenimi sunucuları daha büyük veritabanlarını barındırabilir.
- Algoritmalar yapılandırılmamış veriler üzerinde çalışabilir.

Q17.

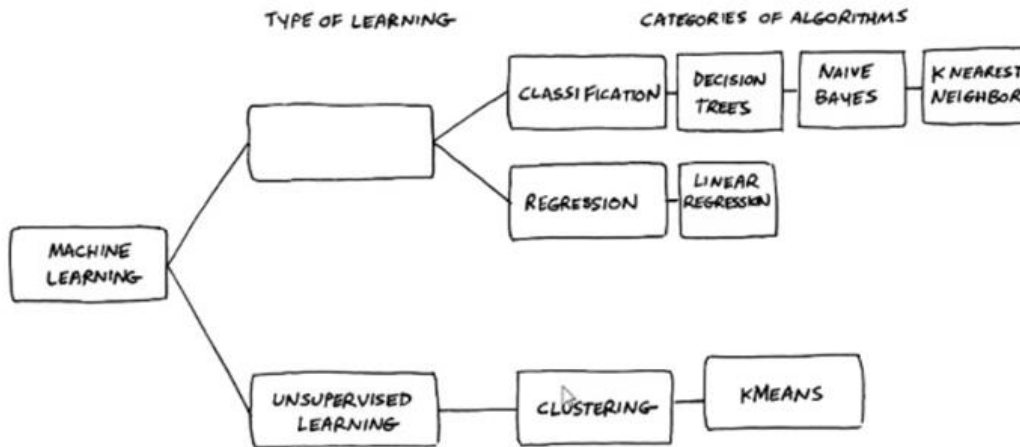
Bir sigorta şirketinde çalışıyorsun. Hangi makine öğrenimi projesi şirket için en fazla değeri katacak!

- Şirket dizinini barındıracak bir yapay sinir ağı oluşturulur.
- **Riski daha iyi tahmin etmek için makine öğrenimini kullanılır.**
- Tüm Excel elektronik tablolarınızı tek bir veri gölünde birleştiren bir algoritma oluşturulur.
- Maaş gereksinimlerini araştırmak için makine öğrenimini ve büyük verileri kullanılır.

Q18.

What is the missing information in this diagram?

- Training Set
- Unsupervised Data
- **Supervised Learning**
- Binary Classification



Q19.

Hem eğitim setiniz hem de test setiniz için aynı verileri kullanmamanın bir nedeni nedir?

- Neredeyse kesinlikle modele uyacaksınız.
- Yanlış algoritmayı seçeceksin.
- Her ikisi için de yeterli veriniz olmayabilir.
- **Neredeyse kesinlikle modele fazla uyacaksınız (aşırı Uyum).**

Q20.

Üniversiteniz, gelen öğrenci uygulamalarını sıralamaya yardımcı olması için makine öğrenimi algoritmalarını kullanmak istiyor. Bir yönetici, kabul kararlarının kadınlar gibi belirli bir gruba karşı yanlı olup olmadığını sorar. En iyi cevap ne olurdu?

- Makine öğrenimi algoritmaları matematik ve istatistiğe dayalıdır ve bu nedenle tanım gereği tarafsız olacaktır.
- Verilerdeki yanlılığı tanımlamanın bir yolu yoktur.
- Makine öğrenimi algoritmaları, verilerdeki yanlılığı ortadan kaldıracak kadar güçlüdür.
- **İnsan tarafından yaratılan tüm veriler yanlıdır ve veri bilimcilerinin bunu hesaba katması gerekir.**

Açıklama: Makine öğrenimi algoritmalarında yanlılık bulunmasa da verilerde yanlılık olabilir.

Q21.

Yığınlama nedir?

- **Bir modelin tahminleri değerinin girdileri haline gelir.**
- Makine öğrenimi algoritmalarının farklı sürümlerini kullanıyorsunuz.
- Sonuçlarınızı artırmak için birkaç makine öğrenimi algoritması kullanırsınız.
- Eğitim setinizi ve test setinizi bir araya toplarsınız.

Q22.

Sosyal medyadaki yavru kedi resimlerini tanımlayan denetimli bir makine öğrenimi sistemi oluşturmak istiyorsunuz. Bunu yapmak için 100.000'den fazla yavru kedi resmi topladınız. Bu resim koleksiyonuna ne ad verilir?

- **Eğitim verileri**
- doğrusal regresyon
- Büyük veri
- test verisi

Q23.

Farklı köpeklerin görüntülerini bir araya getirmeyi içeren bir proje üzerinde çalışıyorsunuz. Görüntüyü çeker ve onu diğer görüntülerin benzerliğine göre ölçeklendirmek amacıyla merkez görüntünüz olarak tanımlarsınız. Ne tür makine öğrenme algoritması kullanıyorsunuz?

- ağırlık merkezi takviyesi
- K-en yakın komşu
- ikili sınıflandırma
- **K-kümeleme anlamına gelir**

Açıklama: Sorun açıkça "kümeleme"yi belirtiyor. Açıkça K-Kümeleme algoritmasını tanımlamaktadır.

K-ortalama kümeleme ya da K-means kümeleme (K-means clustering) yöntemi N adet veri nesnesinden oluşan bir veri kümesini giriş parametresi olarak verilen K adet kümeye bölümlenektir. Amaç, gerçekleştirilen bölümlenme işlemi sonunda elde edilen kümelerin, küme içi benzerliklerinin maksimum ve kümeler arası benzerliklerinin ise minimum olmasını sağlamaktır.

Q24.

Şirketiniz, çalışanların e-posta yazmak için harcadıkları zamanı hızlandırmak için dahili bir e-posta metni tahmin modeli oluşturmanızı istiyor. Ne yapmalısınız?

- **Tüm çalışanlardan gelen eğitim e-posta verilerini dahil edin.**
- Yeni çalışanlardan gelen eğitim e-posta verilerini ekleyin.
- Deneyimli çalışanlardan gelen eğitim e-posta verilerini ekleyin.
- Dahili e-postaların çoğunu yazan çalışanlardan gelen eğitim e-posta verilerini ekleyin.

Q25.

Kuruluşunuz, insanların çevrimiçi profesyonel profiller oluşturmasına olanak tanır. Önemli bir özellik, profesyonel olarak birbirine bağlı insan kümeleri oluşturma yeteneğidir (Aynı işte çalışanlar, aynı üniversiteyi bitirenler, aynı bölgede ya da güzergahda oturanlar, ...). Bu kümeleri oluşturmak için ne tür bir makine öğrenimi yöntemi kullanırsınız?


- **denetimsiz makine öğrenimi**
- ikili sınıflandırma
- denetimli makine öğrenimi
- pekiştirmeli öğrenme

Q26.

What is this diagram a good example of?

- K-nearest neighbor
- a decision tree
- a linear regression
- **a K-means cluster**

Note: there are centres of clusters (C0, C1, C2).



K-En Yakın Komşu(K-NN) ve K-Ortalama Kümeleme Arasındaki Fark:

K-NN, Denetimli bir makine öğrenimidir, K-ortalama ise denetimsiz bir makine öğrenimidir.

K-NN bir sınıflandırma veya regresyon makine öğrenme algoritmasıdır, K-means ise bir kümeleme makine öğrenme algoritmasıdır.

K-NN tembel bir öğrenmedir. Çünkü, sınıflandırma ve regresyon; işi kolay. K-Means ise ortak özellik kümelemesi yapacağı için istekli bir öğrenmedir. İstekli bir öğrenme, eğitim adımı anlamına gelen bir model uydurması vardır, ancak tembel bir öğrenmenin bir eğitim aşaması yoktur. K-ortalama kümelemede, ilk merkezler bazen rastgele seçilir.

Tüm veriler aynı ölçeğe sahipse K-NN çok daha iyi performans gösterir, ancak bu K-ortalamlar için doğru değildir.

Q27.

Rastgele orman, daha önceki hangi tekniğin değiştirilmiş ve geliştirilmiş versiyonudur?

- toplu ağaçlar
- güçlendirilmiş ağaçlar
- **torbalanmış ağaçlar**
- yığılmış ağaçlar

Rastgele ormanlar veya rastgele karar ormanları, eğitim zamanında çok sayıda karar ağacı oluşturarak çalışan sınıflandırma, regresyon ve diğer görevler için bir topluluk öğrenme yöntemidir. Sınıflandırma görevleri için, rastgele ormanın çıktısı, çoğu ağaç tarafından seçilen sınıftır. Regresyon görevleri için, tek tek ağaçların ortalama veya ortalama tahmini döndürülür. Rastgele karar ormanları, karar ağaçlarının eğitim setlerine fazla uyma alışkanlıklarını düzeltir. Rastgele ormanlar genellikle karar ağaçlarından daha iyi performans gösterir.

Q28.

Kendi kendini organize eden haritalar, hangi tür makine öğrenimi için özelleşmiş sinir ağlarıdır?

- **yarı denetimli öğrenme (Kendi kendini organize eden)**
- denetimli öğrenme
- pekiştirmeli öğrenme
- denetimsiz öğrenme

Q29.

K-ortalama kümelemesi ile ilgili hangi ifade doğrudur?

- **K-ortalama kümelemede, ilk merkezler bazen rastgele seçilir.**
- K-ortalama kümeleme genellikle denetimli makine öğreniminde kullanılır.
- Küme sayısı her zaman rastgele seçilir.
- Doğru olmak gerekirse, centroidlerinizin kümenin dışında olmasını istiyorsunuz.

Q30.

Çevresiyle etkileşime giren, hatalara ve ödüllere yanıt veren bir makine öğrenme sistemi yarattınız. Ne tür bir makine öğrenme sistemidir?

- denetimli öğrenme
- yarı denetimli öğrenme
- **pekiştirmeli öğrenme (Hata ve ödül)**
- denetimsiz öğrenme

Q31.

Veri bilimi ekibiniz bir ikili sınıflandırıcı oluşturmalıdır ve bir numaralı ölçüt, dağıtımda mümkün olan en hızlı puanlamadır. Hatta gerçek zamanlı olarak konuşlandırılabilir. Hangi teknik, dağıtım ekibinin yeni vakalarda kullanması için muhtemelen en hızlı olacak bir model üretecek?

- random forest
- **logistic regression (ikili)**
- KNN
- deep neural network

Q32.

Veri bilimi ekibiniz K-en yakın komşu sınıflandırma algoritmasını kullanmak istiyor. Ekibinizden biri 25 K değerini kullanmak istiyor. Bu yaklaşımın zorlukları nelerdir?

- Daha yüksek K değerleri gürültülü veriler üretecektir.
- Daha yüksek K değerleri yanlılığı azaltır ancak varyansı artırır.
- Daha yüksek K değerleri daha büyük bir eğitim setine ihtiyaç duyar.
- **Daha yüksek K değerleri varyansı düşürür ancak yanlılığı artırır.**

Varyans, Makine Öğrenimi bağlamında, bir modelin eğitim setindeki küçük dalgalanmalara duyarlılığı nedeniyle oluşan bir hata türüdür. Yüksek varyans, bir algoritmanın eğitim setindeki gürültüyü ya da hatayı modellemesine neden olur. Buna en yaygın olarak aşırı uyum denir.

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.

Bazen algoritma yanlılığı veya AI yanlılığı olarak da adlandırılan makine öğrenimi yanlılığı, bir algoritma, makine öğrenimi sürecindeki hatalı varsayımlar nedeniyle sistematik olarak yanlış sonuçlar ürettiğinde ortaya çıkan bir olgudur.

Varyans, eğitim veri setinin farklı kısımlarını kullanırken modeldeki değişiklikleri ifade eder. Basitçe ifade etmek gerekirse, varyans, model tahminindeki değişkenliktir—verilen veri kümesine bağlı olarak ML işlevinin ne kadar ayarlayabildiği.

Q33.

Makine öğrenimi sistemi, etiketlenmemiş verilerden gizli bir yapıyı tanımlamaya çalışıyor. Bu makine öğrenimi yöntemini nasıl tanımlarsınız?

- denetimli öğrenme
- **denetimsiz öğrenme**
- pekiştirmeli öğrenme
- yarı denetimsiz öğrenme

Q34.

Müşterileri için hedefli promosyonlar oluşturmak isteyen büyük bir kredi kartı işleme şirketi için çalışıyorsunuz. Veri bilimi ekibi, benzer satın alma işlemleri yapan müşterileri gruplandırır ve bu müşterileri müşteri sadakatine göre bölen bir makine öğrenimi sistemi oluşturdu. Bu makine öğrenimi yaklaşımını nasıl tanımlarsınız?

- **İşlemleri bir araya getirmek için denetimsiz öğrenmeyi ve müşterileri sınıflandırmak için denetimsiz öğrenmeyi kullanır.**
- Yalnızca denetimsiz makine öğrenimini kullanır.
- Kümeler oluşturmak için denetimli öğrenmeyi ve sınıflandırma için denetimsiz öğrenmeyi kullanır.
- Müşterileri sınıflandırmak için pekiştirmeli öğrenmeyi kullanır.

Denetimsiz Öğrenme, kullanıcıların modeli denetlemesi gerekmeyen bir makine öğrenimi tekniğidir. Bunun yerine, modelin daha önce tespit edilmemiş olan kalıpları ve bilgileri keşfetmek için kendi başına çalışmasına izin verir. Esas olarak etiketlenmemiş verilerle ilgilenir.

Q35.

K -en yakın komşuyu kullanıyorsunuz ve K 'niz 1'dir. Modeli eğittiğinizde muhtemelen ne göreceksiniz?

- **yüksek varyans ve düşük yanlılık**
- düşük yanlılık ve düşük varyans
- düşük varyans ve yüksek yanlılık
- yüksek yanlılık ve yüksek varyans

$K=1$ seçildiğinde gürültü artacak, duyarlılık artacak o halde yüksek varyans oluşacak. Yanlılık azalacaktır.

Bazen algoritma yanlılığı veya AI yanlılığı olarak da adlandırılan makine öğrenimi yanlılığı, bir algoritma, makine öğrenimi sürecindeki hatalı varsayımlar nedeniyle sistematik olarak yanlı sonuçlar ürettiğinde ortaya çıkan bir olgudur.

Varyans, eğitim veri setinin farklı kısımlarını kullanırken modeldeki değişiklikleri ifade eder. Basitçe ifade etmek gerekirse, varyans, model tahminindeki değişkenliktir—verilen veri kümesine bağlı olarak ML işlevinin ne kadar ayarlayabildiği.

Q36.

Veri modeli yanlılığı ve varyansı, denetimsiz öğrenmeyle ilgili bir zorluk mudur?

- Hayır, veri modeli yanlılığı ve varyansı, pekiştirmeli öğrenmede yalnızca bir zorluktur.
- **Evet, makine kümeler oluşturduğunda veri modeli sapması bir zorluktur.**
- Evet, veri modeli varyansı denetimsiz makine öğrenimi algoritmasını eğitir.
- Hayır, veri modeli yanlılığı ve varyansı denetimli öğrenmeyi içerir.

Q37.

Which choice is best for binary classification?

- K-means
- **Logistic regression**
- Linear regression
- Principal Component Analysis (PCA)

Açıklama: Lojistik regresyon, ikili sınıflandırmada lineer regresyondan çok daha iyidir, çünkü sonucu bir uçtan diğerine doğru saptırır. K-ortalama kümeleme sınıflandırma için kullanılabilir ancak çoğu senaryoda o kadar doğru değildir.

Q38.

Geleneksel programlama ile programcı tipik olarak komutları girer. Makine öğrenimi ile programcı girdileri

- denetimli öğrenme
- **veri**
- denetimsiz öğrenme
- algoritmalar

Açıklama : Bu oldukça basit ve temel bir kavram.

Q39.

Makine öğrenimi algoritmalarının yüksek kaliteli verilere erişmesi neden önemlidir?

- Programcıların zayıf verileri temizlemesi çok uzun sürecektir.
- Veriler yüksek kalitede ise, algoritmaların geliştirilmesi daha kolay olacaktır.
- Düşük kaliteli veriler, yüksek kaliteli verilerden çok daha fazla işlem gücü gerektirir.
- **Verilerin kalitesi düşükse, hatalı sonuçlar alırsınız.**

Veri kalitesi yüksek ise doğru sonuçlar elde etme ihtimali yükselir.

Q40.

K-en yakın komşuda, komşuya ne kadar yakınsanız, ... olasılığınız o kadar yüksektir.

- **ortak özelliklere sahip olmak**
- kök düğümün parçası olma
- Öklid bağlantısına sahip olma
- aynı kümenin parçası olma

Q41.

HBO dizisi Silicon Valley'de karakterlerden biri Not Hot Dog adlı bir mobil uygulama yaratıyor. Kullanıcının mobil cihazıyla yemeğin fotoğrafını çekmesini sağlayarak çalışır. Ardından uygulama, yemeğin sosisli sandviç olup olmadığını söylüyor. Uygulamayı oluşturmak için yazılım geliştiricisi yüz binlerce sosisli sandviç resmi yükledi. Bu tür bir makine öğrenimini nasıl tanımlarsınız?

- Güçlendirme makine öğrenimi
- denetimsiz makine öğrenimi
- **denetimli makine öğrenimi**
- yarı denetimli makine öğrenimi

Q42.

Veri bilimi ekibi, yeni ilaçların keşfedilmesine yardımcı olmak için denetimsiz öğrenme makinesi algoritmalarını kullanmak isteyen büyük bir ilaç şirketinde çalışıyorsunuz. Bu yaklaşımın avantajı nedir?

- Antibiyotikler gibi farklı ilaç sınıflarına öncelik verebileceksiniz.
- Keşfetmek istediğiniz ilaçlardan oluşan bir eğitim seti oluşturabilirsiniz.
- **Algoritmalar, benzer özelliklere sahip ilaçları bir araya toplayacaktır.**
- Uzmanlar, keşfi yönlendirmeye yardımcı olacak ilaç sınıfları oluşturabilir.

Q43.

2015 yılında Google, Go oyununda bir insanı yenebilecek bir makine öğrenimi sistemi oluşturdu. Bu son derece karmaşık oyunun, evrendeki atomlardan daha fazla oynanış olanağına sahip olduğu düşünülüyor. Sistemin ilk versiyonu, yüz binlerce saatlik insan oyunları nasıl oynadığını gözlemleyerek kazandı; ikinci versiyon ise kendisine karşı oynarken ödüller alarak oynamayı öğrendi. Farklı makine öğrenimi yaklaşımlarına geçişi nasıl tanımlarsınız?

- **Sistem denetimli öğrenmeden pekiştirmeli öğrenmeye geçti.**
- Sistem, denetimli öğrenmeden denetimsiz öğrenmeye dönüştü.
- Sistem, denetimsiz öğrenmeden denetimli öğrenmeye dönüştü.
- Sistem, pekiştirmeli öğrenmeden denetimsiz öğrenmeye dönüştü.

Q44.

Çalıştığınız güvenlik şirketi, bilgisayar ağı tehdit algılama araçlarına makine öğrenimi algoritmaları eklemeyi düşünüyor. Makine öğrenimini kullanmanın avantajlarından biri nedir?

- **Keşfedilmemiş tehditlere karşı daha iyi koruma sağlayabilir.**
- Donanım gereksinimlerini büyük olasılıkla düşürür.
- Geliştirme sürenizi önemli ölçüde kısaltır.
- Cihazın hızını artıracaktır.

Q45.

Bir virüsün topluluk yayılımını izleyen bir hastane için çalışıyorsunuz. Hastane, yüz binlerce katılımcıdan vücut ısısı verilerini yükleyen bir akıllı saat uygulaması oluşturdu. Verileri analiz etmek için en iyi teknik nedir?

- Yeni bir kişi katıldığında sistemi ödüllendirmek için pekiştirmeli öğrenmeyi kullanılır.
- İnsanları makinenin keşfettiği kalıplara göre bir araya getirmek için denetimsiz makine öğrenimini kullanılır.
- İnsanları demografik verilere göre sıralamak için Denetimli makine öğrenimini kullanılır.
- **İnsanları vücut ısısına göre sınıflandırmak için Denetimli makine öğrenimini kullanılır.**


Q46.

Makine öğrenimindeki ilerlemelerin çoğu, geliştirilmiş nelerden gelmiştir?

- statistics
- structured data
- availability
- **algorithms**

Q47. What is this diagram a good example of?

- unsupervised learning
- complex cluster
- multiclass classification
- **k-nearest neighbour**



Q48.

Naive Bayes, her _ tahmin edicisine bakar ve her sınıfa ait bir olasılık yaratır.

- koşullu
- çok sınıflı
- **bağımsız**
- ikili

Q49.

Veri bilimi ekibinizden biri, karar ağaçlarını, Naive Bayes'i ve en yakın komşuyu aynı anda, aynı eğitim verilerinde kullanmanızı ve ardından sonuçların ortalamasını almanızı önerir. Bu neyin örneği?

- regresyon analizi
- denetimsiz öğrenme
- yüksek varyanslı modelleme
- **topluluk modelleme**

Q50.

Veri bilimi ekibiniz, istenmeyen iletileri daha iyi filtrelemek için makine öğrenimini kullanmak istiyor. Ekip, spam olarak tanımlanan veya spam olmayan 100.000 iletiden oluşan bir veritabanı topladı. Denetimli makine öğrenimi kullanıyorsanız, bu veri kümesine ne ad verirsiniz?

- Makine öğrenimi algoritması
- **Eğitim seti**
- Büyük veri test seti
- Veri kümesi

Q51.

Müşterilerin tek bir fotoğraf yükleyerek internette kendilerine ait tüm görüntüleri görmelerini sağlayan bir web sitesi için çalışıyorsunuz. Veri modeliniz, insanları fotoğraflarıyla eşleştirmek için 5 özellik kullanır: renk, göz, cinsiyet, gözlük ve sakal, kafanın fiziksel özellikleri, bakış açısı biçimleri. Müşterileriniz on binlerce fotoğrafın kendilerine benzemediğinden şikayet ediyor. Sorun nedir?

- Modeli verilere fazla uyduruyorsun
- Daha küçük bir eğitim setine ihtiyacınız var
- **Modeli verilere yetersiz uyduruyorsunuz**
- Daha büyük bir eğitim setine ihtiyacınız var

Q52.

Yöneticiniz, insan kaynakları departmanınızın işe başvuruları iyi tanımlanmış gruplara ayırmasına yardımcı olacak bir makine öğrenimi sistemi oluşturmanızı istiyor. Daha çok ne tür bir sistem önerirsiniz?

- en iyi adayları bir araya getiren denetimsiz bir makine öğrenimi sistemi.
- bu tür bir proje için bir makine öğrenimi sistemi önermezsiniz.
- petabaytlarca istihdam verisine dayanan derin öğrenen bir yapay sinir ağı.
- **Başvuru sahiplerini mevcut gruplara ayıran denetimli bir makine öğrenimi sistemi.**

Q53.

Siz ve veri bilimi ekibiniz 1 TB örnek veriye sahipsiniz. Bu verilerle genellikle ne yaparsınız?

- eğitim setiniz olarak kullanıyorsunuz.
- **Büyük veri olarak etiketlersiniz.**
- Onu bir eğitim seti ve test seti olarak ayırdınız.
- Test setiniz olarak kullanıyorsunuz.

Büyük veriden belirli bir ölçekte eğitim seti ve test seti elde edilir. Dikkat edilecek hususlar;

- Eğitim seti, Test setine benzemeyecek.
- Eğitim seti hatalı ya da duyarlı olmayacak
- Her iki veri setinin ağırlık ortalaması ve varyansı büyük verinin ağırlık ortalaması ve varyansı ile ilgili hipotezleri sağlamış olacak.

Q54.

Veri bilimi ekibiniz, video oyunlarında yapay bir rakip olarak işlev görebilecek bir makine öğrenimi ürünü üzerinde çalışıyor. Ekip, ödüllere odaklanan bir makine öğrenimi algoritması kullanıyor: Makine bazı şeyleri iyi yaparsa, sonucun kalitesini artırır. Bu tür bir makine öğrenimi algoritmasını nasıl tanımlarsınız?

- yarı denetimli makine öğrenimi
- denetimli makine öğrenimi
- denetimsiz makine öğrenimi
- **pekiştirmeli öğrenme**

Q55.

Model, verilerle eğitilecek tek bir toplu iş olarak bilinir mi?

- toplu öğrenme
- Çevrimdışı öğrenme
- **Hem A hem B**
- Yukarıdakilerin hiçbiri

Q56. Which of the following is NOT supervised learning?

- Decision Tree
- Linear Regression
- **PCA**
- Naive Bayesian

Q57.

Evlerin geometrik konumları gibi konumsal veriler üzerinde kümeleme yapmak istediğimizi varsayalım. Birçok farklı boyut ve şekilde kümeler üretmek istiyoruz. Aşağıdaki yöntemlerden hangisi en uygundur?

- Karar ağaçları
- K-kümeleme anlamına gelir
- **Yoğunluğa dayalı kümeleme**
- Model tabanlı kümeleme

Q58.

Lojistik regresyon kullanan gradyan inişi için en uygun hata fonksiyonu şudur:

- Entropi işlevi.
- Kare hatası.
- **Çapraz entropi işlevi.**
- Hataların sayısı.

Q59.

MAP, sonsal dağılımın en yüksek zirvesini arar, MLE ise parametreyi yalnızca verilerin olabilirlik fonksiyonuna bakarak tahmin eder.


- Higher
- same
- **Lower**
- it could be any of the above

Q60.

... ne eğitim verilerini modelleyebilen ne de yeni verilere genelleyemeyen bir modeli ifade eder.

- iyi uydurma
- aşırı uyum
- **yetersiz uydurma**
- Yukarıdakilerin hepsi

Q61.



Bu tür bir sınıflandırma sorununu nasıl tanımlarsınız?

- **Bu, çok sınıflı bir sınıflandırma zorluğudur.**
- Bu, çoklu ikili sınıflandırma sorunudur.
- Bu bir ikili sınıflandırma zorluğudur.
- Bu bir pekiştirme sınıflandırma zorluğudur.

Açıklama: Verilerin ikiden fazla kategoriye veya sınıfa ayrıldığını gösterir. Bu nedenle, bu çok sınıflı bir sınıflandırma zorluğudur.

Q62.

Veri modelinizin altından kalkmak ne anlama geliyor?

- Eğitim setinizde çok az veri var.
- Eğitim setinizde çok fazla veri var.
- **Çok fazla varyans yok ama yüksek bir önyargı var.**
- Modelinizin önyargısı düşük ancak varyansı yüksek.

Yeterli donanıma sahip olmayan veri modelleri genellikle yüksek yanlılığa ve düşük varyansa sahiptir. Fazla donatılmış veri modelleri, düşük yanlılığa ve yüksek varyansa sahiptir.

Q63.

Asyalı bir müşteri, şirketinizin yüz tanıma modelinin yüz ifadelerini doğru şekilde tanımlamadığından şikayet ediyor. Ne yapmalısın?

- Asya yüzlerini test verilerinize dahil edin ve modelinizi yeniden eğitin.
- Güncellenmiş hiperparametre değerleriyle modelinizi yeniden eğitin.
- Modelinizi daha küçük parti boyutlarıyla yeniden eğitin.
- **Eğitim verilerinize Asyalı yüzleri dahil edin ve modelinizi yeniden eğitin.**

Cevap kendiliğinden açıklayıcıdır: Şikayette bulunan tek grup Asyalı kullanıcılar, eğitim verileri daha fazla Asyalı yüze sahip olmalıdır.

Q64.

İnsanları öğle yemeği randevuları için eşleştirmeye yardımcı olan bir web sitesi için çalışıyorsunuz. Web sitesi, müşterilere mükemmel randevuyu bulmak için 500'den fazla tahmin aracı kullanmasıyla övünüyor, ancak birçok müşteri çok az eşleşme olduğundan şikayet ediyor. Modelinizle ilgili olası bir sorun nedir?

- Eğitim setiniz çok büyük.
- Modeli verilere yetersiz uyduruyorsunuz.
- **Modeli verilere fazla uyduruyorsunuz.**
- Makineniz hatalı kümeler oluşturuyor.

Açıklama: Bu soru S49'a çok benzer ancak tam tersi bir senaryo içeriyor. Bu cevap biraz belirsiz ve kararsız. Az sayıda eşleşme, özellikle 500 (!) bağımsız değişken verildiğinde, modelin fazla uyduğu anlamına gelmez. Bana göre, eşik (eşleşme) kriterinin çok sıkı olması ve dolayısıyla sadece az sayıda eşleşmenin gerçekleşmesine izin vermesi daha mantıklı geliyor. Dolayısıyla bir çözüm, eşik kriterini yumuşatmak veya aday sayısını artırmak olabilir.

Q65.

(Çoğunlukla) çevrimiçi olarak çekirdek görselleştirmelerini (veya başka bir referansı) gördüğümüzde aslında şunu görüyoruz:

- Hangi çekirdekleri çıkarır
- Özellik Haritaları
- **Çekirdekler Nasıl Görünür?**

Q66.

A, B ve C sınıfı için softmax'tan önceki aktivasyonlar 10, 8 ve 3'tür. A sınıfı ve B sınıfı için softmax değerlerindeki fark şöyle olacaktır:

- **%76**
- %88
- %12
- %0.0008

$$\text{Softmax} := \sigma(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}} = \frac{e^{z_i}}{e^3 + e^8 + e^{10}}$$

$$\sigma(10) - \sigma(8) = \frac{e^{10} - e^8}{e^3 + e^8 + e^{10}} \approx 0.761$$

Q67.

Az önce kazıdığınız yeni veri kümesi birçok eksik değer sergiliyor gibi görünüyor. Hangi eylem bu sorunu en aza indirmenize yardımcı olacak?

- Kontrollü rastgele değerlerin akıllıca doldurulması
- Eksik değerleri tüm örneklerde ortalama olarak değiştirin
- Arızalı numuneleri çıkarın
- **Atama**

Q68.

Aşağıdaki yöntemlerden hangisi denetimsiz öğrenme veya boyut azaltma tekniği olarak kullanılabilir?

Açıklama: Temel Bileşen Analizi (Principal Component Analysis - PCA), çeşitli uygulamalarda en sık kullanılan denetimsiz makine öğrenimi algoritmalarından biridir: keşifsel veri analizi, boyutsallık azaltma, bilgi sıkıştırma, veri gürültüsüzleştirme ve çok daha fazlası!

Q69.

YSA'da (Yapay Sinir Ağları) aktivasyon fonksiyonlarını kullanmanın ana motivasyonu nedir?


- **Karmaşık doğrusal olmayan desenleri yakalama**
- Sürekli değerlerin "AÇIK" (1) veya "KAPALI" (0) değerlerine dönüştürülmesi
- Kaybolan/patlayan gradyan probleminden kaçınmaya yardımcı olun
- Her nöronu ayrı ayrı aktive etme yetenekleri.

Q70.

Kategorik (ayrık) denetimli öğrenmeye en uygun kayıp işlevi hangisidir?

- Kullback-leibler (KL) kaybı
- **İkili Çapraz Entropi**
- Ortalama Kare Hatası (MSE)
- Herhangi bir L2 kaybı

Q71. What is the correct option?



no. Red

Blue

Green

1. Validation error Training error Test error
2. Training error Test error Validation error
3. Optimal error Validation error Test error
4. **Validation error Training error Optimal error**

Q72.

Birinin sahile gitmeye karar verip vermediğini göstermek için bir karar ağacı yaratırsınız. Bu kararda üç faktör vardır: yağmurlu, bulutlu ve güneşli. Bu üç faktöre ne ad verilir?

- Ağaç düğümleri
- **Tahmin ediciler**
- Kök düğümler
- Karar vericiler

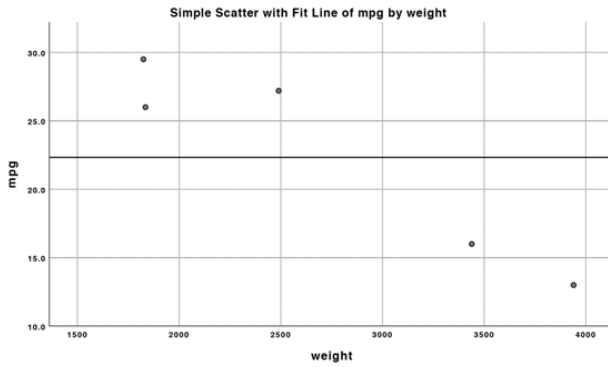
Açıklama: Bu düğümler, birinin kumsala gitmeye karar verip vermeyeceğine karar verir, örneğin, yağmurlu insanlar çoğunlukla kumsala gitmekten kaçınacaklardır.

Q73.

Bir modeli eğitmek için binlerce görüntüyü hızla etiketlemeniz gerekir. Ne yapmalısınız?

- Görüntüleri etiketlemek için bir makine kümesi kurun
- Görüntülerin bir alt kümesini oluşturun ve ardından kendinizi etiketleyin
- **Etiketleri otomatik olarak oluşturmak için Naive Bayes kullanın.**
- Görüntüleri manuel olarak etiketlemek için insanları işe alın

Q74.



Şekildeki uyum çizgisi ve veriler hangi kalıbı göstermektedir?

- düşük önyargı, yüksek varyans
- yüksek önyargı, düşük varyans
- yüksek önyargı, yüksek varyans
- **düşük önyargı, düşük varyans**

Açıklama: Veriler doğru bir şekilde sınıflandırıldığından ve veri kümesine ne fazla uyuyor ne de yetersiz uyuyor

Q75.

Makine öğrenimindeki ilerlemelerin çoğu, iyileştirmelerden mi geldi?

- yapılandırılmış veri
- **algoritmalar**
- zaman
- Bilgisayar bilimcileri

Q76.

Bir mobil uygulamada dağıtılmış bir sinir ağını çalıştırmak için bir makine öğrenimi süreci seçmeniz gerekir. Hangi seçerdiniz?

- Scikit-öğren
- PyTorch
- **Tensowflow Lite**
- tensör akışı

Q77.

Etiketlenmiş verilere en iyi örnek hangi seçimidir?

- **bir elektronik tablo**
- 20.000 kayıtlı sesli posta mesajı
- 100.000 otomobil resmi
- yüzlerce gigabayt ses dosyası

Q78.

İstatistikte, bir etki bulma hipotez testinin olasılığı olarak tanımlanır - eğer bulunacak bir etki varsa?

- Kendinden emin
- Alfa
- **Güç**
- Önem

Q79.

Web'deki yemek tariflerini tanımlamak için bir makine öğrenimi algoritması oluşturmak istiyorsunuz. Bunu yapmak için farklı koşullu olasılıklara bakan bir algoritma oluşturursunuz. Yani gönderi un kelimesini içeriyorsa, tarif olma olasılığı biraz daha yüksek. Hem un hem de şeker içeriyorsa, bir tarif olması daha olasıdır. Ne tür bir algoritma kullanıyorsunuz?

- **Naive Bayes sınıflandırıcı**
- K-en yakın komşu
- Çok sınıflı sınıflandırma
- Karar ağacı

Q80.

Tembel öğrenme nedir?

- Programlamanın çoğunu makine öğrenimi algoritmaları yaptığında
- Herhangi bir veri temizleme yapmadığınızda
- Öğrenme sürekli gerçekleştiğinde
- **Hesaplamanızı başlangıçta büyük bir örnekte çalıştırdığınızda**

Açıklama: Makine öğreniminde tembel öğrenme, sistemin sorguları almadan önce eğitim verilerini genelleştirmeye çalıştığı istekli öğrenmenin aksine, eğitim verilerinin genelleştirilmesinin teorik olarak sisteme bir sorgu yapılana kadar ertelendiği bir öğrenme yöntemidir. .

Q81.

Q-öğrenme pekiştirmeli öğrenme nedir?

- Ödüllü denetimli makine öğrenimi
- Büyük ölçüde köklü bir modele dayanan bir tür denetimsiz öğrenme
- Doğruluğun zamanla azaldığı bir tür pekiştirmeli öğrenme
- **Ödüllere odaklanan bir tür pekiştirmeli öğrenme**

Açıklama:Q-learning, modelsiz bir pekiştirmeli öğrenme algoritmasıdır.Q-learning, değerlere dayalı bir öğrenme algoritmasıdır. Değer tabanlı algoritmalar, bir denkleme (özellikle Bellman denklemi) dayalı olarak değer fonksiyonunu günceller.

Q-learning, belirli bir durumdaki bir eylemin değerini öğrenmek için modelsiz bir pekiştirmeli öğrenme algoritmasıdır. Bir çevre modeli gerektirmez (dolayısıyla "modelsiz") ve stokastik geçişler ve ödüllerle ilgili sorunları uyarlamalar gerektirmeden halledebilir.

Q82.

Modelinizdeki veriler düşük sapma ve düşük varyansa sahiptir. Veri noktalarının diyagramda birlikte gruplanmasını nasıl beklersiniz?

- **Öngörülen sonuçta birlikte sıkı bir şekilde gruplandırılacaklardı.**
- Birbirlerine sıkı sıkıya ama tahmin edilenden uzak bir şekilde gruplandırılacaklardı.
- Tahmin sonucunun etrafına dağılmış olacaklardı.
- Tahmin edilen sonuçtan çok uzaklara dağılmış olacaklardı.

Q83.

Makine öğrenimi sisteminiz, gelecekteki verileri tahmin etmeye çalışmak, bu verileri tahmin edilen sonuçla ve ardından modelle karşılaştırmak için etiketli örnekler kullanıyor. Bu makine öğrenimi yönteminin en iyi açıklaması nedir?

- Denetimsiz öğrenme
- Yarı denetimli öğrenme
- **Denetimli öğrenme**
- Yarı pekiştirmeli öğrenme

Q84.

1983 yapımı WarGames filminde bilgisayar, kendisine karşı oynayarak satranç oyununda ustalaşmayı öğrenir. Bilgisayar hangi makine öğrenimi yöntemini kullanıyordu?

- İkili öğrenme
- Denetimli öğrenme
- Denetimsiz öğrenme
- **Pekiştirmeli öğrenme**

Q85.

You could use a naïve Bayes algorithm, to differentiate three classes of dog breeds — terrier, hound, and sport dogs. Each class has three predictors — hair length, height, and weight. The algorithm does something called class predictor probability.

Makine öğrenimi algoritmanızla, sınıf tahmin etme olasılığı denen bir şey üzerinde çalışıyorsunuz. Büyük olasılıkla hangi algoritmayı kullanıyorsunuz?

- Çok sınıflı ikili sınıflandırma
- **Naive bayes**
- Denetimsiz sınıflandırma
- Karar ağacı analizi

Terrier, tazı ve spor köpekleri olmak üzere üç köpek ırkı sınıfını ayırt etmek için saf bir Bayes algoritması kullanabilirsiniz. Her sınıfın üç belirleyicisi vardır - saç uzunluğu, boy ve ağırlık. Algoritma, sınıf tahmin etme olasılığı adı verilen bir şey yapar.

Q86.

Modelinizin verilere uymamasını düzeltmenin en etkili yollarından biri nedir?

- Eğitim kümeleri oluşturun
- Tahmin edicileri kaldır
- Takviyeli öğrenmeyi kullanın
- **Daha fazla tahminci ekleyin**

Q87.

Veri bilimi ekibiniz genellikle sıkıcı veya çok açık raporlar oluşturduğu için eleştirilir. Takımın gelişmesine yardımcı olmak için ne yapabilirsin?

- **Takımın muhtemelen modeli verilere yetersiz uydurduğunu önerin.**
- Denetimsiz öğrenmenin daha ilginç sonuçlara yol açacağını önerin.
- Doğru makine öğrenimi algoritmalarını seçtiklerinden emin olun.
- Ekibi daha ilginç sorular sormaya teşvik edin.

Q88.

Yapılandırılmamış ve yapılandırılmış veriler arasındaki fark nedir?

- Yapılandırılmamış veriler her zaman metindir.
- Yapılandırılmamış verilerin saklanması çok daha kolaydır.
- **Yapılandırılmış veriler, açıkça tanımlanmış veri türlerine sahiptir.**
- Yapılandırılmış veriler çok daha popüler.

Q89.

Belirli araçları kullanan kişilerin resimleri için interneti tarayacak bir yazılım aracı geliştirmeye çalışan bir girişim için çalışıyorsunuz. CEO, makine öğrenimi algoritmalarını kullanmakla çok ilgileniyor. Başlamak için en iyi yer olarak ne önerirsiniz?

- Tüm fotoğrafları bir araya getirmek için denetimsiz bir makine öğrenimi algoritması kullanmak.
- Denetimsiz bir makine öğrenimi algoritmasıyla bir veri gölü oluşturun.
- Makine tanımlı veri kümeleri oluşturmak için denetimsiz ve denetimli makine öğreniminin bir kombinasyonunu kullanın.
- **Fotoğrafları önceden belirlenmiş bir eğitim setine göre sınıflandırmak için denetimli makine öğrenimini kullanın.**

Q90. In supervised machine learning, data scientist often have the challenge of balancing between underfitting or overfitting their data model. They often have to adjust the training set to make better predictions. What is this balance called?

- the under/over challenge
- balance between clustering classification
- **bias-variance trade-off**
- the multiclass training set challenge

Denetimli makine öğreniminde, veri bilimcisi genellikle veri modellerini eksik veya fazla uydurma arasında denge kurma zorluğuyla karşılaşır. Daha iyi tahminler yapmak için genellikle eğitim setini ayarlamak zorunda kalırlar. Bu dengeye ne denir?

- alt/üst meydan okuma
- kümeleme sınıflandırması arasındaki denge

- **önyargı-varyans deęiş tokuşu**
- çok sınıflı eęitim seti mücadelesi

Q91.

Koşullu olasılık nedir?

- **bir şeyi yapmanın başka bir şeyi etkileme olasılığı**
- belirli koşulların karşılanma olasılığı
- Belirli koşullara baęlı olarak bir şeyin her zaman yanlış olma olasılığı
- bir şeyin doęru cevap olma olasılığı

Q92. K-means clustering is what type of machine learning algorithm?

- reinforcement
- supervised
- **unsupervised**
- classification

Q93.

Topluluk modellemesi nedir?

- eęitim ve test veri setinizin bir grubunu oluşturduğunuzda
- algoritmaları çalıştırmak için farklı sunuculardan oluşan bir topluluk oluşturduğunuzda
- topluluğunuz için en iyi algoritmayı bulduğunuzda
- **birkaç makine öğrenimi algoritması topluluęu kullandığınızda**

Toplu modelleme, ya birçok farklı modelleme algoritması kullanarak ya da farklı eęitim veri setleri kullanarak bir sonucu tahmin etmek için çok çeşitli modellerin oluşturulduğu bir süreçtir. Topluluk modeli daha sonra her bir temel modelin tahminini toplar ve görünmeyen veriler için bir kez nihai tahminle sonuçlanır.

Q94.

Veri modelinizde yanlışlık için en iyi tanım nedir?

- Yanlılık, tahmin edilen deęerlerinizin dağıldığı zamandır.
- **Yanlılık, tahmin edilen deęeriniz ile sonuç arasındaki boşluktur.**
- Yanlılık, verilerinizin farklı nedenlerle yanlış olduğu zamandır.
- Yanlılık, deęerlerinizin her zaman aynı yüzdeyle kapalı olduğu zamandır.

6. Kaynakça

- 1- <https://github.com/Ebazhanov/linkedin-skill-assessments-quizzes/blob/main/machine-learning/machine-learning-quiz.md>