

18. BÖLÜM / CHAPTER 18

MAKİNE ÖĞRENMESİ VE YAPAY ZEKÂ

MACHINE LEARNING AND ARTIFICIAL INTELLIGENCE

Elif KARTAL*

*Dr., İstanbul Üniversitesi, Enformatik Bölümü, İstanbul, Türkiye
E-mail: elifk@istanbul.edu.tr

DOI: 10.26650/B/ET07.2021.003.18

ÖZ

Buzdolabınızda yer alan sütün son kullanma tarihi geçtiğinde bu durumu otomatik olarak algılayıp, uyarı veren ve marketten yeni bir kutu süt sipariş eden bir buzdolabınızın olması hayatınızı kolaylaştırmaz mı? Ya da tersine örnek verilecek olursa; bir bankacının yüz bin müşterinin tüm işlemlerini gözden geçirerek gelecek olan yeni bir müşteri için kolay bir biçimde kredi riski tahmini yapması ne kadar olasıdır (elbette tahminin kabul edilebilir bir sürede yapılacağı düşünülerek)? Aslında insanlar; öğrenme, çok yönlü düşünme, karar verebilme gibi birbirinden farklı pek çok özelliklerle donatılmıştır; ancak bu mükemmele yakın tasarlanan makineler de özellikle günümüz teknolojisiyle üretilen sistemlerle mukayese edildiklerinde karar alırken dış dünyadan etkilenebilme, veri depolama ve işleme kapasiteleri gibi görece olumsuz sayılabilecek özellikleri de bulunmaktadır. Yapay Zekâ (*Artificial Intelligence*) ve yapay zekânın bir alt çalışma alanı olan Makine Öğrenmesi (*Machine Learning*) temelde, başta öğrenme olmak üzere insana özgü olan ayırt edici birtakım özelliklerin makinelere ya da insan hayatını kolaylaştıracak insan yapımı şeylere (*artifacts*) aktarılabilmesine dayanmaktadır. Bu alandaki çalışmalar, kimi zaman matematiksel problemleri çözebilme, kimi zaman uzmanlık gerektiren görevleri yerine getirme, kimi zaman insan beyni ve çalışma prensibinden ilham alma vb. farklı odaklara yönelmiş olsa da, benzeri amaçlarla geliştirilen sistemlerin daimi hedefi bir görevi insanların yaptığından da daha iyisini yerine getirebilmek olmuştur. Günümüzde finans, spor, eğitim gibi birçok alanda yapay zekâ ve makine öğrenmesi uygulamalarına rastlamak mümkündür. Tıp da özellikle hastalık teşhisi ve tedavisi ele alındığında yapay zekâ ve makine öğrenmesinden faydalanılan bu alanların başında gelmektedir. Teknolojinin ilerlemesiyle daha hassas görüntüleme imkânı, daha detaylı ve hassas ölçümlerin gerçekleştirilebilmesi gibi donanımsal avantajları kazanırken; sağlık personeline karar almada yardımcı olacak, hastane yönetimi ve hastalar için hastane süreçlerinde rahatlama sağlayacak teşhis ve tedavi sistemlerinin geliştirilmesi yapay zekâ ve makine öğrenmesi uygulamalarıyla mümkün olabilmektedir. Bu haliyle yapay zekâ ve makine öğrenmesinin tıp bilimi içinde önemli bir yeri bulunmaktadır. Bu sebeple, bu çalışmada; öncelikle yapay zekânın kısa tarihine yer verilmiş, yapay zekânın tarihinde yer alan mihenk taşı sayılabilecek bazı temel olay ve uygulamalardan bahsedilmiştir. Ardından, yapay zekânın bir alt çalışma alanı olan makine öğrenmesi tanımlanarak, makine öğrenmesi süreci ve makine öğrenmesinde kullanılan öğrenme stratejilerine yer verilmiştir.

Anahtar Kelimeler: Danışmanlı öğrenme, danışmansız öğrenme, makine öğrenmesi, pekiştirmeli öğrenme, yapay zekâ

ABSTRACT

Wouldn't our lives be easier if our refrigerator would automatically detect and warn us when the expiry date of the milk in the refrigerator is approaching, or it is over, and order a new box of milk from the market? Or if the opposite example is given; how likely is it for a banker to review all transactions of a hundred thousand customers and easily estimate their credit risk for an upcoming new customer (of course, assuming that the forecast will be made in an acceptable time)? People are equipped with many different features such as learning, multi-dimensional thinking, decision-making, and others. However, these almost perfectly designed machines also have features that can be considered relatively negative, such as being influenced by the outside world while making decisions, and their data storage and processing capacities are affected, especially when compared to systems produced with today's technology. Artificial intelligence and machine learning, which is a sub-field of artificial intelligence, are basically based on the ability to transfer some distinctive features specific to humans, especially learning to machines or artifacts that will facilitate human life. Studies in this area sometimes include solving mathematical problems, performing tasks requiring expertise, and being inspired by the human brain and its working principles. Although they have focused on different things, the permanent goal of systems developed for similar purposes has been to perform a task better than people do. Today, it is possible to come across artificial intelligence and machine learning applications in many fields such as finance, sports, education, and others. Medicine is one of these areas where artificial intelligence and machine learning are used, especially while considering the diagnosis and treatment of a disease. With the advancement of technology, it gains hardware advantages such as more precise imaging along with more detailed and precise measurements. Additionally, it is possible to develop diagnosis and treatment systems that will help health care personnel in making decisions and providing relief in hospital processes for hospital management and patients, with artificial intelligence and machine learning applications. As such, artificial intelligence and machine learning have an important place in medical informatics. For this reason, this study, first, presents a short history of artificial intelligence and mentions some basic events and applications that can be considered as a milestone in the history of artificial intelligence. Then, by defining machine learning, which is a sub-field of artificial intelligence, this study explores machine learning process and learning strategies used in machine learning.

Keywords: Supervised learning, unsupervised learning, machine learning, reinforcement learning, artificial intelligence

1. Giriş

Yapay zekâ, insan eliyle yapılmış şeylerdeki (*artifacts*) algılama, sorgulama, öğrenme, iletişim kurma ve karmaşık ortamlarda hareket etme gibi zeki davranışla ilgili olup, uzun vadedeki hedeflerinden biri, verilen bu zeki davranış örneklerini insanlar kadar iyi - hatta insanlardan daha iyi - yapabilecek makinelerin geliştirilmesi; diğeri ise ister makinelerde, ister insanlarda ya da diğeri canlılarda olsun bu tür davranışları anlayabilmektir (Nilsson ve Nilsson, 1998). Makine öğrenmesi ise; yapay zekâ ile ilgili tanıma, teşhis, planlama, robot kontrolü, tahmin vb. görevleri yerine getiren sistemlerdeki değişikliğe atıfta bulunmaktadır (Nilsson, 1998). Yapay zekâ denildiğinde her ne kadar ilk akla gelen “dünyayı ele geçiren robotlar” figürü olsa da, bugün yapay zekânın gündelik hayattaki uygulamaları çok geniş bir yelpazede sunulmaktadır. Çoğu zaman bir bankanın çağrı merkezini aradığınızda sizi yönlendiren otomatik sesli yanıt asistanları, daha önce alış-veriş yaptığımız bir web sitesini tekrar ziyaret ettiğinizde web sitesinin sizin için

önerdiği ilgi alanınıza giren ürünler veya size gösterdiği reklamlar, sürekli uğradığınız süpermarketten (belki de) tam da ihtiyacınız olduğu bir anda ihtiyacınız olan ya da ilginizi çeken bir ya da birkaç ürünle ilgili telefonunuza gelen indirim mesajı, arkadaşınızla kahve içerken çektiğiniz fotoğrafı akıllı telefonunuzla sosyal medyada paylaştığınızda uygulamada arkadaşınızın (adının) otomatik olarak etiketlenmesi, araç plakanızı otomatik tanıyan sistemler gibi sayabileceğimiz birçok örnek aslında günlük hayatta yapay zekâ ile ne kadar içiçe olduğumuzun kanıtıdır. Yapay zekâ ve çalışma alanlarıyla ilgili gündelik hayattan verilen bu örneklerin sektörel açıdan ele alınarak, problem tanımlarının genelleştirilmesi de mümkündür. Finans ve sigortacılıkta müşteri risk analizi, pazarlamada müşteri segmentasyonu, sağlıkta çeşitli hastalıkların tanı ve tedavisi için geliştirilen karar destek sistemleri, eğitimde kişiselleştirilmiş eğitim ortamları, otomobil sektöründe sürücüsüz araçlar gibi uygulamalarla da sektörel örnekleri artırılabilir.

Yapay zekâ, geçmişten günümüze matematik ve istatistik başta olmak üzere bilişsel bilimler (*cognitive science*), psikoloji gibi pek çok farklı disiplinin katkısıyla gelişmektedir. Yapay zekâ ve makine öğrenmesi uygulamalarının günümüzde popüler hale gelmesindeki sebeplerden birisi olarak “büyük veri” gösterilebilir. Sağlıktan spora, finanstan eğitime hemen hemen her alanda büyük verinin varlığından söz edilmektedir. Literatürde büyük veriyi tanımlamada kullanılan ve genellikle V harfiyle tanımlanan temel unsurlardan bahsedilmektedir. Veri hacmi (*volume*), çeşitliliği (*variety*) ve hızı (*velocity*) büyük verinin 3V’si olarak anılmaktadır (Özen, Kartal ve Emre, 2017; Zikopoulos, Eaton, deRoos, Deutsch ve Lapis, 2011). İlk olarak mevcut veri hacminin incelenmesi için Domo (2019) tarafından bir günün her dakikasında ortaya çıkan veri miktarı grafiği ele alınsın. Bu grafiğe göre; 188.000.000 adet e-posta gönderilmekte, 18.100.000 metin gönderilmekte, Google 4.497.420 aramaya ev sahipliği yapmakta, YouTube’da kullanıcılar tarafından 4.500.000 adet video izlenmekte, Twitter üzerinden 511.200 tweet atılmaktadır. İkinci özellik olarak ise veri çeşitliliğinden bahsedilmiştir. Büyük veriyi ise sadece klasik bir veritabanı yapısında saklanan fazla miktardaki veri biçiminde düşünmemek gerekir. Sosyal medyadaki her türlü sesli, görüntülü ve yazılı içerikler, süpermarketlerde barkod okuyucuların kayıt altına aldığı işlemler, hastanelerde MRI (manyetik rezonans görüntüleme), fMRI (işlevsel manyetik rezonans görüntüleme) gibi çeşitli cihazlarından gelen her türlü görüntü ya da sensörler aracılığıyla elde edilmiş olan veri vb. bugün büyük veri analizi kapsamında veri bilimcilerin ilgi alanına girmektedir. Büyük veri hacmi ve çeşitliliğinin yanı sıra son olarak büyük verinin hızının da incelenmesi gerekir. Özellikle geleceği öngörme, tahminde bulunma ve karar verme gibi konularda elektronik ortamda saklanan verinin miktarı ve çeşitliliği kadar büyük verinin işlenmesi, işe yarar hale getirilmesi ve büyük veri içindeki örüntülerin keşfi süreci de önem kazanmıştır.

Yapay zekâ ve makine öğrenmesi uygulamalarının artmasında diğer bir sebep olarak; büyük verinin saklanabilmesi ve işlenebilmesi için bulut bilişim gibi yeni teknolojilerin ortaya çıkması, bu süreç için gereken teknolojilerin ucuzlaması, kullanımının yaygınlaşması ve güçlü işlemcilerle daha kolay hale getirilmiş olması gösterilebilir. Çünkü hızla akan verinin arkasında kalmamak, karar verme süreçlerini daha doğru, daha rasyonel ve daha hızlı hale getirebilmek hedeflenmektedir. Bu durumun, hem uygulayıcı kuruma hem de verilen hizmetin kalitesini artırarak bireylere katkı sağlayacağı düşünülmektedir. Başka bir sebep olarak ise; yapay zekâ ve makine öğrenmesi konusunda araştırmacılar tarafından literatüre yapılan katkılar, algoritmaların görev performansındaki ilerlemeler gösterilebilir. Uzun yıllar boyunca kimi zaman artık durma noktasına geldiği düşünülen yapay zekâ çalışmalarının sürekliliği, araştırmacıların bu alana bitmeyen ilgisiyle sağlanmıştır.

Büyük verinin sağlık sektöründeki yeri de yadsınamazdır. Sağlık hizmetindeki veri genel anlamda hasta verisi ve temel bilgileri, klinik veri ve doktor verisinden oluşurken, günümüzde kullanılan yakalama cihazları, sensörler, elektronik sağlık kayıtları ve mobil bilgisayar vb. ile genişlemiştir (Siddique, Mirza, Ahmad, Chaudhry ve Islam, 2018). Bu alandaki veri; biyometrik veri, genetik, kan basıncı, elektronik tıbbi kayıtlar, uzaktan algılayıcı verileri ve sosyal medya verisi gibi iç ve dış kaynaklardan üretilmektedir (Siddique ve diğerleri, 2018). Sağlık hizmetlerindeki büyük veri; sağlık hizmeti alan ve sağlayıcı verisi (elektronik tıbbi kayıtlar, eczane reçetesi ve sigorta kayıtları gibi) ile birlikte genomik güdümlü deneyleri (genotipleme, gen ekspresyon verileri gibi) ve nesnelerin interneti (*Internet of Things - IoT*) ile edinilen diğer verileri içermektedir (Dash, Shakyawar, Sharma ve Kaushik, 2019). Tıpkı diğer sektörlerde olduğu gibi sağlık sektörünün de bireylere daha iyi hizmet sunabilmek için teknolojik ilerlemelere dayalı olarak her geçen gün biraz daha değişim ve gelişim göstermekte olduğu görülebilir. Kullanılan ekipmanlardaki donanımsal yeniliğin yanı sıra aslında arka planda güçlü ilerlemeleri beraberinde getiren yapay zekâ ve makine öğrenmesi uygulamalarının olduğunu söylemek yanlış olmayacaktır. Tıp alanında, teknolojinin ilerlemesiyle daha hassas görüntüleme imkânı, daha detaylı ve hassas ölçümlerin gerçekleştirilebilmesi gibi donanımsal avantajlar kazanılırken; sağlık personeline karar almada yardımcı olacak, hastane yönetimi ve hastalar için hastane süreçlerinde rahatlama sağlayacak teşhis ve tedavi sistemlerinin geliştirilmesi yapay zekâ ve makine öğrenmesi uygulamalarıyla mümkün olabilmektedir. Bu haliyle yapay zekâ ve makine öğrenmesinin tıp bilişimi içinde önemli bir yeri bulunmaktadır. Bu sebeple, bu çalışmada; öncelikle yapay zekâ kavramına ve kısa tarihine yer verilmiş, yapay zekâ tarihinde yer alan mihenk taşı sayılabilecek bazı temel olay ve uygulamalardan bahsedilmiştir. Ardından, yapay zekânın bir alt çalışma alanı olan makine öğrenmesi tanımlanarak, makine öğrenmesi süreci ve makine öğrenmesinde kullanılan öğrenme stratejilerine yer verilmiştir.

2. Yapay Zekânın Kısa Tarihi

İnsan gibi düşünen ve insan gibi karar verebilen sistemlerin geliştirilmesi fikri neredeyse antik çağlara kadar uzanmaktadır. Bu dönemde ortaya atılan bazı basit yapay zekâyâ sahip sistemlerin temelini, bir sofrada suyun doldurulması gibi basit bir görevin bir insan yerine otomat adı verilen insanlar tarafından geliştirilmiş olan bir yapıt tarafından yerine getirmesi oluşturmaktaydı. Bu ve benzeri ilk yapay zekâ denemelerine örnek olarak; kendi kendine hareket edebilen servis sehpaları (*Tripodes Khryseoi*) ve savaşta ateş topu ve kaya atmada kullanılan dev *Talos* gösterilebilir (Atsma, 2015; Hope, 2015; Özen, Kartal ve Gülseçen, 2017). Yapay zekâ çalışmalarının temeli insan gibi düşünen ve insan gibi karar veren sistemleri geliştirebilmek olduğundan, yapay bir zekâ ortaya koyabilmek için biyolojik beyin (yapı ve işleyişi) araştırmacılara önemli ölçüde ilham kaynağı olmuştur. Bu nedenle de yapay zekâ konusunda mihenk taşı sayılabilecek çalışmalara 1943 yılında Warren S. McCulloch ve Walter Pitts tarafından ortaya konan (**McCulloh-Pitts Nöronu** olarak da bilinen) biyolojik beyindeki nöronlardan - sinir hücrelerinden - (*neuron*) esinlenerek oluşturulmuş nöron modeli örnek verilebilir (Neapolitan ve Jiang, 2018). Geliştirilen bu nöron, yapısı gereği ve/veya gibi temel mantık fonksiyonlarını çözebilen basitçe açık ya da kapalı olma durumuna sahip ikili bir değişken olarak düşünülebilir.

Bir makinenin zeki olarak sayılıp sayılmayacağı fikri ise bilgi-işlemin babası kabul edilen Alan Turing'in 1950'de **Turing Testi** ile ortaya atılmış oldu (Skansi, 2018). Turing testinde bir insan denek; bir insan ve bir makine ile soru-cevap biçiminde iletişim kurmaktadır (elbette denek bu sırada iletişim kurduğunun insan ya da makine olup olmadığını bilmemektedir). Testin sonunda denekten ayırım yapması beklenmektedir. Eğer denek ayırımda başarısız olursa makine zeki olarak adlandırılmaktadır. Turing Testi'nin tarihi yarım asırdan fazla olsa da günümüzde hala çeşitli şekillerde makinelerin zeki olup olmadığı konusundaki değerlendirmelerde kullanılmaktadır. Turing Testi'ni geçen bir makinenin varlığı ise tartışma konusudur (Todorović, 2015).

Matematik, istatistik ve teknolojiyen büyük ölçüde beslenen yapay zekâ terimi resmi anlamda ilk kez John McCarthy tarafından ortaya konmuştur. McCarthy 1956 yılında Dartmouth University'de Marvin Minsky, Allen Newell gibi alanda ileri gelen araştırmacıların da katılımıyla on haftalık bir araştırma projesine imza atmış ve bu araştırmayı "Yapay Zekâ Çalışması" (*Study of Artificial Intelligence*) olarak adlandırmıştır (Taulli, 2019). Böylece **yapay zekâ** terimi literatürde ilk kez kullanılmıştır. 1955-1956 yılları arasında Allen Newell, Cliff Shaw ve Herbert Simon tarafından geliştirilen **Logic Theorist** geliştirilen ilk yapay zekâ programı

olarak bilinmekte olup, 1961 yılında Allen Newell ve Herbert Simon **Genel Problem Çözücü** (*General Problem Solver*) adında bir program ortaya koymuştur (Neapolitan ve Jiang, 2018). Bir makinenin tüm problemleri çözebileceği ya da verilen her türlü görevi yerine getirebileceği düşüncesi ile geliştirilen her amaca hizmet edecek zeki programlar ne yazık ki sınırlı bir alan çerçevesinde ve oldukça basit problemleri çözebilmiş, sonrasında araştırmacılar literatürde **uzman sistemler** (*expert systems*) olarak da anılan bilgiye dayalı (*knowledge-based*) DENDRAL, XCON, ACRONYM, MYCIN gibi belirli alana özgü sistemler geliştirmeye yönelmiştir (Neapolitan ve Jiang, 2018). 1990'ların ortalarında Deep Blue adlı bilgisayar satranç oyunu sırasında, karşılaşılabileceği olası birçok senaryo arasından en uygun olanını seçerek hamle yapabilme yeteneği sayesinde satranç dünya şampiyonu Garry Kasparov'u yenmiştir.

Yapay zekânın altın çağı olarak bilinen dönemde yapay zekâ ile ilgili iki temel görüşün mevcudiyetinden bahsedilmektedir (Taulli, 2019). Bunlardan ilki; Marvin Minsky'nin de çalışmalarını bu yönde yürüttüğü yapay zekâ sistemlerinin klasik bilgisayar programlamada olduğu gibi eğer-ise (*if-then-else*) yapısına dayalı sembolik sistemler olması düşüncesi, ikincisi ise; Frank Rosenblatt'ın çalışmalarını yürüttüğü yapay zekânın sinir ağları gibi biyolojik beyinin çalışma prensibine dayalı benzer sistemler kullanması gerektiği ile ilişkilidir. Nitekim; Rosenblatt yapay sinir ağlarında (McCulloch-Pitts nöronunda) kullanılan ağırlıkların nasıl güncelleneceğini gösteren **algılayıcı** (*perceptron*) **öğrenme kuralını** ortaya koymuş (Skansi, 2018), **Mark I Perceptron** adını verdiği ilk bilgisayar programını geliştirmiştir (Taulli, 2019).

Yapay zekâ tarihinde, çalışmaların durakladığı ya da gerilediği dönemler “yapay zekâ kışı”, önemli gelişmelerin yaşandığı, yapay zekânın popüler hale geldiği dönemler ise “yapay zekâ yazı” şeklinde anılabilmektedir. 1980'lere kadar sürecek olan “yapay zekâ kışı”na girilmesindeki etkenlerden biri; Marvin Minsky ve Seymour Papert'in 1969 yılında yayınladıkları “Perceptrons” kitabında XOR fonksiyonunda olduğu gibi doğrusal olarak ayrılamayan verinin sınıflandırılmasında, ara katmana sahip olmayan lineer modellerin (Rosenblatt'ın perceptron modelinin) çok sınırlı olduğunu göstermeleridir (Murphy, 2012; Taulli, 2019). Sonrasında; her ne kadar daha önce birbirinden bağımsız olarak geliştirilmiş olsa da (Bryson ve Y.-C. Ho, 1969; Werbos, 1974), Rumelhart, Hinton ve Williams (1986), ara katmanlar yardımıyla modelleme imkânı sunan **geri-yayılım algoritmasına** (*backpropagation algorithm*) araştırmacıların dikkatini çekmiştir (Murphy, 2012).

Genetik algoritmalar, robotik gibi alanlara ek olarak günümüzde **derin öğrenme** (*deep learning*) konusunda yapılan çalışmaların yeni bir yapay zekâ yazı yaşattığı söylenebilir. Derin öğrenmenin özünü yapay sinir ağları oluşturmaktadır; ancak bu yaklaşımda adından da anlaşılacağı üzere daha fazla katmanın kullanılması düşüncesi ön plandadır. Derin öğrenme,

çoklu işleme katmanlarından oluşan hesaplama modellerinin, birden fazla soyutlama seviyesine sahip verilerin temsillerini öğrenmesini sağlar (LeCun, Bengio ve Hinton, 2015). Bu yöntemler; başta konuşma tanıma (*speech recognition*), görsel nesne tanıma (*visual object recognition*), nesne algılama (*object detection*) olmak üzere, ilaç keşfi ve genomik gibi diğer birçok alanda yer alan son teknolojiyi önemli ölçüde geliştirmiştir (LeCun ve diğerleri, 2015).

3. Makine Öğrenmesi

Tıpkı zekâ gibi öğrenme de içerisinde pek çok süreci barındırdığından öğrenmeyi tam olarak tanımlamak zordur; ancak verilen sözlük tanımına göre öğrenme; “çalışma, eğitim ya da deneyimle bilgi, anlayış ya da yetenek kazanmak” ve “deneyimle davranışsal eğilimdeki değişiklik” anlamına gelmektedir (Nilsson, 1998). İnsanlar ve hayvanlar deneyimlerinden öğrenerek zeki davranış sergiler, öğrenme sayesinde karşılaşabilecekleri yeni durumlara kendilerini ayarlama ve adapte olma esneklikleri bulunur ve bu noktada özellikle önemli olan hatırlama, uyum sağlama ve genelleştirme yetenekleridir (Marsland, 2015): Daha önce yaşanan bir durum karşısında belirli bir eylemin gerçekleştirildiği varsayalım. Eğer söz edilen durum için gerçekleştirilen bu eylem işe yaradıysa aynı hareket yeniden denenebilir, aksi halde farklı bir çözüm yolunun aranması, yani farklı bir hareketin gerçekleştirilmesi gerekecektir. Örneğin; daha önce karşılaşmadığınız bir matematik problemi ele alalım. Bu problemi nasıl çözebilir hale gelebilirsiniz? Önce sınıfta öğretmeniniz size bu problemi nasıl çözebileceğinizi gösterebilir, sınıf arkadaşlarınızdan yardım isteyebilirsiniz. Kendiniz benzer problemleri çözebilir, araştırma yapabilirsiniz. Böylece aynı türde size sorulabilecek farklı bir problemi bir sonraki sefer çözebilir hale gelebilirsiniz. Bir başka deyişle problemin çözümünü öğrenmiş olursunuz. Benzer mantıkla, bir makine için öğrenme tanımlanmak istenirse, şu ana kadar geliştirilen teknolojiyle insan ya da hayvanlardakine benzer ileri seviye bir öğrenme sürecinin tanımlanması mümkün olmayacaktır; ancak bir benzetim söz konusudur. Makine öğrenmesinde öğrenme işini gerçekleştiren bilgisayar programları, bilgisayar programlarının da temelini oluşturan algoritmalarıdır. Makine (bilgisayar programı da denilebilir) bir görevi yerine getirmek için deneyim olarak “veri”den faydalanmaktadır. Bir makinenin “öğrenmesi”nden beklenti; aynı veya benzer bir görevi ikinci kez yapması istendiğinde, görevi daha iyi (daha verimli, daha etkili) gerçekleştirmesini sağlayan sistemdeki herhangi bir değişiklik olabilir (Simon, 1984). Örneğin; bir ses tanıma sisteminin performansı insana ait birkaç ses örneğini dinledikten sonra artmasında olduğu gibi eğer bir makine, yapısını, programını ya da verisini, gelecekte beklenen performansını artıracak şekilde değiştirirse öğrenmiş olur (Nilsson, 1998).

Makine öğrenmesi için literatürde yapılmış olan en iyi sayılabilecek tanımlardan biri “Eğer bir bilgisayar programının G görevlerinde P ile ölçülen performansı, deneyim D ile

artıyorsa, o bilgisayar programının bazı *G* görevlerinin sınıflarına ve performans ölçüsü *P*'ye göre deneyim *D*'den öğrendiği söylenmektedir” şeklindedir (Balaban ve Kartal, 2018; Mitchell, 1997). Verilen tanım dikkatlice incelenecek olursa, makine için öncelikle bir *G* görevinin belirlenmiş olması gerekmektedir. Bu görev kimi zaman bir kişinin şeker hastası olup olmadığının belirlenebilmesi olabileceği gibi kimi zaman bir e-postanın istenmeyen (*spam*) bir e-posta olup olmadığının tespiti, bir süpermarkete ait müşterilerin belirli özelliklerine göre gruplandırılması, vb. olabilir. Makineden yapması istenen görev belirlendikten sonra, deneyim olarak faydalanacağı “veri”nin sunulması gereklidir. Eğer makine için görev bir hastanın şeker hastası olup olmadığını belirlemek şeklinde seçilmişse, makineye şeker hastalığının tespitine yönelik değişkenleri içeren veri sunulabilir. Ya da bir süpermarkete ait müşteriler gruplandırılacaksa bu kez de süpermarket müşterilerinin geçmişte yaptığı işlemlere ait veri dikkate alınacaktır. Süreç sonunda elbette belirli bir kritere göre makinenin öğrenip öğrenmediği bilgisinin ortaya konması, yani performansının ölçülmesi gerekecektir.

Makine öğrenmesi, verideki örüntüleri otomatik biçimde belirleyebilen, belirlenen bu örüntüleri geleceği öngörmeye veya belirsizlik altında karar vermede kullanan bir dizi yöntemdir (Murphy, 2012). Gelecekle ilgili tahminde bulunmak, çıkarım yapmak, karar vermek ya da strateji belirlemek gibi durumlarda mevcut veriyi dikkate alarak gelecek için değer yaratacak önemli örüntülerin makine öğrenmesi teknikleri sayesinde veriden çıkarılabilir. Özellikle büyük veri kavramı düşünüldüğünde bu veriyi artık işe yarar bilgi haline getirecek avantajları sıralarken daha somut bir örnek ele alınsın. Örneğin; makineye deneyim olarak sunulan veri, klasik bir veritabanı yapısı yerine hastaların beyin MRI taramasına ilişkin görüntülerden oluşan bir veri seti olabilir. Makine öğrenmesi tekniklerinden faydalanarak bir hastanede bu görüntüleri otomatik biçimde yorumlayan bir sistemin geliştirilmesi, hem hastalar hem de sağlık çalışanları için fayda sağlayacaktır. Görüntüde yer alan farklılıklar insan gözünden çok daha hassas biçimde tespit edilebilecek, doktorların karar verme sürecine yardımcı olacak ve karar sürecinin daha hızlı ve rasyonel şekilde işlemesi sağlanabilecektir.

4. Makine Öğrenmesi Süreci

Makine öğrenmesi sürecini en genel anlamda beş adımda özetlemek mümkündür (Brownlee, 2019):

- Sürecin ilk adımı olarak makineye verilecek **görevin iyi tanımlanmış olması**, diğer bir ifade ile makine öğrenmesi probleminin tanımlanması gerektiği söylenebilir. Bu aşamada problemin ne olduğu, problemin çözülmesi için ne gerektiği ve problemin nasıl çözülebileceği konusunda araştırmalar bu adım kapsamında gerçekleştirilebilir.

- İkinci adımda, **verinin makine öğrenmesi analizlerine hazırlanması** gerekmektedir. Bu aşama sürecin belki de en kritik aşamalarından biridir. Çünkü; ne kadar çok veriyle en iyi algoritmalar kullanılarak analizler yapılmış olursa olsun ya da analizler ne kadar uzun sürerse sürsün kullanılacak veri seti anlaşılmadığı, analizlere uygun biçimde hazırlanmadığı takdirde elde edilen sonuçların bir anlamı olmayacaktır. Elbette öncelikle deneyimden öğrenen makinelerle (ya da algoritmalarla) çalışabilmek için elbette bir önceki adımda tanımlanan probleme uygun veri setinin mevcut olması gerekir. Sonrasında; veri setindeki niteliklerin tanınması/anlaşılması ile işe başlanabilir. Bu aşamada yapılabilecek işlemlerden bazıları şu şekilde sıralanabilir: Kategorik ve nümerik verinin ayrımı, birbirleri arasındaki ilişkinin incelenmesi, aykırı değerlerin (*outliers*) analizi, kayıp değerlerin (*missing values*) kontrolü ve gerektiği durumlarda tamamlanması işlemi, kategorik niteliklerin dummy coding yöntemi ile matris biçiminde kodlanması, nümerik bir niteliğin kategorik hale getirilmesi, bazı niteliklerin veri setinden çıkarılması, niteliklerin normalizasyonu, nitelik seçimi, veri setindeki dengesizlik durumunun giderilmesi vb.
- Tanımlanmış olan makine öğrenmesi problemi ve öğrenme stratejisiyle de ilişkili olarak bugüne kadar araştırmacılar tarafından geliştirilmiş ve geliştirilmeye devam eden pek çok makine öğrenmesi algoritması bulunmaktadır (k-En Yakın Komşu Algoritması (*k-Nearest Neighbour Algorithm*), Naive Bayes Sınıflandırıcı (*Naive Bayes Classifier*), Yapay Sinir Ağları (*Artificial Neural Networks*), k-Ortalamalar Algoritması (*k-Means Algorithm*), vb.). Problemin tanımlanıp, verinin hazırlanmasından sonra artık bu aşamada makine öğrenmesi algoritmaları veri setine uygulanarak makine öğrenmesi analizlerine, yani **modellemeye** geçilebilir. Modelleme aşamasında kullanılan algoritmanın seçiminde makineye verilen görev kadar detayları bir sonraki bölümde verilen makine öğrenmesi yöntemlerinin de dikkate alınması gerekecektir. Belirli bir performans değerlendirme kriterine göre problemin algoritma tarafından üretilen çözümünün değerlendirilmesi sağlanmış olur. Bu performans değerlendirme ölçülerini hesaplarken de çeşitli performans değerlendirme yöntemleri kullanılmaktadır. Birden fazla algoritmanın aynı problemin çözümü için kullanılması da özellikle hangi algoritmanın çözüme daha iyi gittiği konusunda bilgi vermesi açısından oldukça önemlidir. Kimi zaman aynı algoritmanın sahip olduğu parametreler değiştirilerek de algoritmanın performansı incelenmektedir.
- **Elde edilen performansın geliştirilmesi/iyileştirilmesi** için çeşitli yöntemlerden faydalanılmaktadır. Algoritmaya ait parametrelerin ayarlanması, bagging, boosting ve blending gibi yöntemlerden faydalanma, vb.

- Sürecin son adımı olarak, makine öğrenmesi **analiz sonuçlarının raporlanması/sunulması** yer almaktadır. Ayrıca elde edilen ve performansı tatmin edici modelin, problemin çözümünde uygulanabilir hale getirilmesi çok önemlidir.

5. Makine Öğrenmesinde Kullanılan Öğrenme Yöntemleri

Makine öğrenmesinde uygulanan öğrenme yöntemleri **danışmanlı öğrenme** (*supervised learning*), **danışmansız öğrenme** (*unsupervised learning*) ve **pekiştirmeli öğrenme** (*reinforcement learning*) olmak üzere üç ana başlıkta incelenebilir (Balaban ve Kartal, 2018; Kartal ve Özen, 2017; Murphy, 2012).

5.1. Danışmanlı Öğrenme

Danışmanlı öğrenme, çoğunlukla sınıflandırma (*classification*) ve regresyon (*regression*) problemlerinin çözümünde kullanılmaktadır. Danışmanlı öğrenmede önemli olan veri setinde bir hedef niteliğin (*target attribute*) yer almasıdır. Hedef nitelik, ele alınan problemin türüne göre farklı türde veri tutabilir. Sınıflandırma problemleri için hedef nitelik sınıf etiketleri (*class labels*) olurken, regresyon problemi için nümerik bir değer olabilmektedir. Danışmanlı öğrenme yöntemini kullanan bir algoritmanın eğitim aşamasında, algoritmaya hem tahmini sağlayacak nitelikler (*predictive attributes*) hem de hedef nitelik değeri gösterilmektedir. Yani, algoritmaya verilen görev kapsamında veri setinde bu görevin sonucunda elde edilmek istenen hedef niteliğe sahip olan örnekler algoritmaya gösterilmektedir. Sonrasında, algoritmadan hedef nitelik değeri bilinmeyen bir (ya da birden fazla) örnek için tahminde bulunması istenmektedir.

Örneğin; bir hastanın kalp hastalığının tahmini görevi ele alınsın. Bu görev için Statlog (Heart) veri seti kullanılsın (Tablo 1) (Dua ve Graff, 2017; UCI Machine Learning Repository, 2020). Bir hastanın kalp hastalığının olup olmadığına karar verebilmek için; yaş, cinsiyet, göğüs ağrısı tipi, dinlenme kan basıncı vb. nitelikler tahmin edici nitelikler olarak adlandırılır. Danışmanlı öğrenme yöntemini kullanan bir algoritmanın eğitim sürecinde kullanılan veri setinde, tahmin edici niteliklerin yanı sıra kalp hastalığı sonucunun yani hedef niteliğin de algoritmaya gösterilmesi gerekmektedir: Yaşı “60”, cinsiyeti “kadın”, göğüs ağrısı tipi “4” (veri setinde kodlandığı biçimiyle), dinlenme kan basıncı “140”, ... olan bir hastanın kalp hastalığı “var”dır; yaş “60”, cinsiyeti “erkek”, göğüs ağrı tipi “3”, dinlenme kan basıncı “120”, ... olan bir hastanın kalp hastalığı “yok”tur gibi. Algoritmanın eğitim süreci tamamlandıktan sonra, yaş, cinsiyet gibi tahminde kullanılan tüm değerleri bilinen; ancak kalp hastalığı durumu bilinmeyen bir hasta için algoritmadan hastanın kalp hastalığı durumunu “var” ya da “yok” şeklinde tahmin etmesi beklenir. Yani hastalar bir bakıma kalp hastalığı olanlar/olmayanlar şeklinde

sınıflandırılır. Hedef niteliğin “var” ve “yok” kategorileri ise sınıf etiketi olarak adlandırılır.

Tablo 1. Danışmanlı öğrenme için kullanılacak veri seti örneği

Yaş	Cinsiyet	Göğüs ağrısı tipi	Dinlenme kan basıncı	...	Kalp hastalığı
60	kadın	4	140	...	var
60	erkek	3	120	...	yok
...
45	erkek	2	130	...	?

Aynı veri setinin hedef niteliği, hastanın kalp hastalığına sahip olma olasılığını gösterecek şekilde (%77, %82 gibi) yeniden düzenlenirse, bu durumda artık algoritmanın amacı da hastanın var ya da yok gibi kalp hastalığı sınıfını bulmak yerine – sınıflandırma –, belirli bir olasılık değeri ile hastalığa sahip olma durumunu tahmin etmek – regresyon – şeklinde değişecektir.

Algoritma tarafından yapılan sınıflandırma değişik biçimlerde karşımıza çıkabilir (Sokolova ve Lapalme, 2009). Bu örnekte olduğu gibi, hedef niteliğin sınıf etiketi sayısı iki tane olduğundan ikili-sınıflandırma (*binary classification*) olabileceği gibi, ikiden fazla kategori içermesi durumunda çok-sınıflı sınıflandırma (*multi-class classification*) da yapılabilmektedir.

Eğitim süreci tamamlanan bir algoritmanın gerçek hayatta bir karar destek sistemine entegre edilebilmesi için özellikle algoritmanın performansının değerlendirilmesi gerekmektedir. Bunun için çeşitli performans değerlendirme yöntemleri ve ölçütleri geliştirilmiştir. Hold-out literatürde sıklıkla kullanılan performans değerlendirme yöntemlerinden biridir. Analizler için kullanılacak veri setinin eğitim ve test veri seti olarak belirli oranlarda (%80-%20, %70-%30, vb.) ikiye ayrılması esasına dayanır. Eğitim veri seti kullanılarak algoritma eğitilirken, test veri seti üzerinde algoritmanın özellikle daha önce görmediği örnekler üzerinde performansı değerlendirilmektedir. Doğruluk (*accuracy*) ve hata oranı (*error rate*) algoritmaya ilişkin performansın değerlendirilmesinde sıklıkla tercih edilmektedir. Doğruluk, hata oranı, duyarlılık (*sensitivity*), belirleyicilik (*specificity*) gibi pek çok model performans değerlendirme ölçütü, test veri setindeki hedef niteliğe ait gerçek sonuçlar ile algoritmanın tahmin değerlerinin 2x2’lik (ya da nxn’lik) kontenjans tablosu (*contingency table*) aracılığı ile hesaplanabilir.

Tablo 2’de 2x2’lik örnek bir kontenjans tablosu verilmektedir. Yukarıdaki problemde kalp hastalığı = var durumu (kalp hastası olma) Pozitif, kalp hastalığı = yok durumu ise Negatif (sağlıklı olma) olarak ele alınsın. Bu durumda tablo aşağıdaki biçimde ele alınacaktır:

- Gerçekte kalp hastalığı olup, algoritmanın da kalp hastalığı “var” şeklinde doğru tahmin ettiği örnekler **doğru pozitifler** (*true positives - tp*).

- Gerçekte kalp hastalığı olmayıp, algoritmanın kalp hastalığı “var” şeklinde yanlış tahmin ettiği örnekler **yanlış pozitifler** (*false positives - fp*).
- Gerçekte kalp hastalığı olup, algoritmanın kalp hastalığı “yok” şeklinde yanlış tahmin ettiği örnekler **yanlış negatifler** (*false negatives - fn*).
- Gerçekte kalp hastalığı olmayıp, algoritmanın da kalp hastalığı “yok” şeklinde doğru tahmin ettiği örnekler **doğru negatifler** (*true negatives - tp*).

Tablo 2. 2x2'lik örnek kontenjans tablosu			
		Gerçek (Referans) Değerler	
		Pozitif	Negatif
Tahmin Değerleri	Pozitif	Doğru pozitif (tp)	Yanlış pozitif (fp)
	Negatif	Yanlış negatif (fn)	Doğru negatif (tn)

İşte bu tablodaki bilgilerden faydalanılarak doğruluk ve hata oranı değerleri basitçe şu şekilde hesaplanır:

$$\text{Doğruluk} = \frac{tp + tn}{tp + fp + fn + tn}$$

$$\text{Hata Oranı} = 1 - \text{Doğruluk}$$

Ayrıca model performansı hesaplanırken; ROC eğrisi (*Receiver Operating Characteristics – ROC Curve*), ROC Eğrisi altında kalan alan (*Area Under the ROC Curve*), ortalama karesel hata (*mean squared error*) ya da kök ortalama karesel hata (*root mean squared error*) gibi ölçütlerden de faydalanmak mümkündür.

5.2. Danışmansız Öğrenme

Danışmansız öğrenmede, veri setinde danışmanlı öğrenmedeki gibi belirli bir hedef niteliğe ihtiyaç duyulmaz. Danışmansız öğrenme algoritmaları veri setindeki tüm niteliklerden faydalanarak örnekleri gruplandırır. Bu nedenle genellikle kümeleme (*clustering*) problemlerinin çözümünde danışmansız öğrenme algoritmalarından faydalanılır. Algoritma için önemli olan örnekler arasındaki birtakım benzerlik/benzemezlik, diğer bir ifade ile örneklerin birbirine yakınlık/uzaklık durumlarıdır. Bazı algoritmalarda veri setinin kaç kümeye ayrılacağı kullanıcı tarafından belirlenebileceği gibi bazı algoritmalarda analiz öncesinde böyle bir sayı belirlenmesine ihtiyaç duyulmaz. Mümkün olduğunca aynı kümede yer alan örnekler arasındaki uzaklıkların minimum olması beklenirken (aynı kümede yer alan örneklerin birbirine daha çok benzemesi), kümeler arasındaki uzaklığın maksimum olmasına dikkat edilir.

Örneğin; veri setinde yalnızca kalp hastalığı teşhisinde kullanılan yaş, cinsiyet, göğüs ağrısı tipi, dinlenme kan basıncı gibi niteliklerin bulunduğunu; ancak danışmanlı öğrenmede olduğu gibi hastada kalp hastalığının olup olmadığını gösteren hedef niteliğin olmadığını varsayalım. Bu seferki amaç hastanın kalp hastalığı durumunun tahmin edilmesi yerine, hastaların kalp hastalığı teşhisinde kullanılan çeşitli nitelikler çerçevesinde gruplandırılması/kümeleneceği olacaktır. Algoritma da yukarıda da bahsedilen yakınlık/uzaklık (ya da benzerlik/benzemezlik) durumlarını inceleyerek veri setindeki örnekleri belirli kümelerle atayacaktır. Dikkat edilmesi gereken nokta; bu küme adlarının A, B ya da 1, 2 gibi jenerik isimlerde olabileceğidir. Yani veri setinde bulunan ilk örnek A kümesine, beş numaralı örnek ise B kümesine, diğer örnekler de benzer şekilde atanmış olabilir. Bu noktada A ve B kümesinin adlarını analiz sonunda belirleyecek (kümelerde yer alan örneklere bakarak kümeleri kalp hastalığı “var” ya da “yok” biçiminde tespit yapacak) olan analizi yapan araştırmacı olabilecektir.

Danışmansız öğrenme algoritmalarının performansının ölçümü için de çeşitli kriterler bulunmaktadır. Örneğin; en iyi küme sayısının bulunabilmesi için Silhouette, Dunn vb. indeks değerleri hesaplanabilir (Koçoğlu ve Özcan, 2016).

5.3. Pekiştirmeli Öğrenme

Bazı uygulamalarda sistemin ürettiği çıktı bir dizi eylemden oluştuğu için, bu gibi durumlarda tek bir eylem yerine, amacı gerçekleştirmede kullanılan politika/hareket tarzı (yani bir dizi doğru eylem) önemli hale gelmektedir (Alpaydın, 2020). Herhangi bir orta düzey durum için en iyi eylem gibi bir durum geçerli değildir. Bunun yerine, eylem eğer iyi bir eylem politikasının bir parçası olduysa işte o zaman iyi olarak nitelendirilebilmektedir. Böylelikle, makine öğrenmesi programı da uyguladığı politikanın iyiliği durumunu değerlendirebilir ve geçmişteki iyi eylem dizilerinden yenilerini yaratabilmeyi öğrenir. Pekiştirmeli öğrenmeyi kullanan algoritma ortamla etkileşime girerek zamana bağlı olarak bir dizi eylem üretir, bu eylemlerin her biri ortamı etkileyerek bir bakıma bir ödül ya da ceza üretilmiş olur (Neapolitan ve Jiang, 2018). Çevrenin etkili temsilcilerini yüksek boyutlu duyuşal girdilerden çıkararak, bunları geçmiş deneyimleri yeni durumlara genelleştirmede kullanmalıdırlar (Mnih ve diğerleri, 2015). Kaelbling, Littman ve Moore (1996), pekiştirmeli öğrenme problemlerinin çözümünde iki temel stratejiden bahsetmiştir. Bunlardan ilki; genetik algoritmalar ve genetik programlamada da kullanılan ortamda en iyi performansı veren davranışın araştırılmasıdır. İkincisi ise; istatistiksel tekniklerden ve dinamik programlama yöntemlerini kullanarak eylemleri uygulamanın faydasını tahmin etmeye çalışmaktır.

Pekiştirmeli öğrenmenin daha iyi anlaşılabilmesi için küçük yaşlarda yeni bir oyunun nasıl öğrenildiği örneği ele alınsın (Taulli, 2019). Oyuna ilişkin kuralların okunması yerine, bu oyunu oynayan diğer insanlar gözlemlenir ve ne yapılması gerektiği anlaşılmaya çalışılır. Hata yapıldığında örneğin top kaybedilebilir ve takımdaki diğer oyuncular memnuniyetsizliklerini dile getirebilir; aksi durumda ise takıma puan kazandırılabilir. Bu deneme yanılma sürecinde, pozitif ve negatif pekiştirmeye dayalı olarak öğrenme geliştirilmiş, iyileştirilmiş olur. TD-Gammon, Go ve Satranç gibi oyunlar üzerinde pekiştirmeli öğrenme ile çalışılmış olup, son yıllarda robotik ve kontrol uygulamalarında da pekiştirmeli öğrenme kullanılmıştır (Kaelbling ve diğerleri, 1996).

6. Sonsöz

Günümüzün en kıymetli sermayesi olan verinin yerini “büyük veri” kavramı almıştır. Büyük veriyi kullanarak geleceğe yönelik tahminler yapabilmek ve karar verme sürecini kolaylaştırmak oldukça önemlidir. Tıpta da durum benzer şekildedir. Bu nedenle de tıp alanında da özellikle hastalıkların teşhis ve tedavisinde yapay zekâ ve yapay zekânın alt çalışma alanlarından faydalanmak bir gereklilik haline gelmiştir. Bu sebeple, bu çalışmada; öncelikle yapay zekânın kısa tarihine yer verilmiş, yapay zekânın tarihinde yer alan mihenk taşı sayılabilecek bazı temel olay ve uygulamalardan bahsedilmiştir. Ardından, yapay zekânın bir alt çalışma alanı olan makine öğrenmesi tanımlanarak, makine öğrenmesi süreci ve makine öğrenmesinde kullanılan öğrenme stratejilerine yer verilmiştir.

Kaynakça / References

- Alpaydin, E. (2020). *Introduction to Machine Learning* (4. bs.). Cambridge, MA: MIT Press.
- Atsma, A. J. (2015). AUTOMATONS (Automatones)—Animate Statues of Greek Mythology. 12 Temmuz 2016 tarihinde <http://www.theoi.com/Ther/Automotones.html> adresinden erişildi.
- Balaban, M. E. ve Kartal, E. (2018). *Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları* (2. bs.). Beyoğlu, İstanbul: Çağlayan Kitabevi.
- Brownlee, J. (2019). Start Here with Machine Learning. *Machine Learning Mastery*. <https://machinelearning-mastery.com/start-here/> adresinden erişildi.
- Bryson, A. ve Y.-C. Ho. (1969). *Applied optimal control: Optimization, estimation, and control*. Blaisdell Publishing Company.
- Dash, S., Shakyawar, S. K., Sharma, M. ve Kaushik, S. (2019). Big data in healthcare: Management, analysis and future prospects. *Journal of Big Data*, 6(1), 54. doi:10.1186/s40537-019-0217-0
- Domo. (2019). Data Never Sleeps 7.0. 11 Nisan 2020 tarihinde <https://www.domo.com/learn/data-never-sleeps-7> adresinden erişildi.
- Dua, D. ve Graff, C. (2017). *UCI Machine Learning Repository*. University of California, Irvine, School of Information and Computer Sciences. <http://archive.ics.uci.edu/ml> adresinden erişildi.
- Hope, J. (2015). 7 phases of the history of Artificial intelligence. *History Extra*. 12 Temmuz 2016 tarihinde <http://www.historyextra.com/article/ancient-greece/7-phases-history-artificial-intelligence> adresinden erişildi.

- Kaelbling, L. P., Littman, M. L. ve Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237-285.
- Kartal, E. ve Özen, Z. (2017). Dengesiz Veri Setlerinde Sınıflandırma. O. Torkul, S. Gülseçen, Y. Uyaroğlu, G. Çağıl ve M. K. Uçar (Ed.), *Mühendislikte Yapay Zeka ve Uygulamaları* içinde (1. bs., ss. 109-131). Sakarya: Sakarya Üniversitesi Kütüphanesi Yayınevi.
- Koçoğlu, F. Ö. ve Özcan, T. (2016). Veri Madenciliğinde Kümeleme Algoritmaları ile Müşteri Segmentasyonu. M. E. Balaban ve E. Kartal (Ed.), *R ile Veri Madenciliği Uygulamaları* içinde (1. bs., ss. 187-220). İstanbul: Çağlayan Kitabevi.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436-444. doi:10.1038/nature14539
- Marsland, S. (2015). *Machine Learning: An Algorithmic Perspective, Second Edition*. CRC Press.
- Mitchell, T. M. (1997). *Machine Learning* (1st Edition.). McGraw-Hill Science/Engineering/Math.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533. doi:10.1038/nature14236
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. Cambridge, MA: MIT Press.
- Neapolitan, R. E. ve Jiang, X. (2018). *Artificial intelligence: With an introduction to machine learning* (2. bs.). Boca Raton, FL, USA: Chapman & Hall/CRC.
- Nilsson, N. J. (1998). *Introduction to Machine Learning An Early Draft of a Proposed Textbook*. <http://ai.stanford.edu/~nilsson/MLBOOK.pdf> adresinden erişildi.
- Nilsson, N. J. ve Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. Palo Alto, CA: Morgan Kaufmann Publishers, Inc.
- Özen, Z., Kartal, E. ve Emre, İ. E. (2017). Eğitimde Büyük Veri. H. F. Odabaşı, B. Akkoyunlu ve A. İşman (Ed.), *Eğitim Teknolojileri Okumaları 2017* içinde (1. bs., ss. 183-204). Ankara: Pegem Akademi. http://www.tojet.net/e-book/eto_2017.pdf adresinden erişildi.
- Özen, Z., Kartal, E. ve Gülseçen, S. (2017). Yapay Zekâ ve Yapay Sinir Ağları. T. R. Çölkesen ve O. Aliefendioğlu (Ed.), *Bilgisayar Bilimine Giriş* içinde (1. Baskı., ss. 523-558). İstanbul: Papatya Bilim Kitabevi.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. doi:10.1038/323533a0
- Siddique, M., Mirza, M., Ahmad, M., Chaudhry, J. ve Islam, M. R. (2018). A Survey of Big Data Security Solutions in Healthcare.
- Simon, H. A. (1984). Why should machines learn? R. S. Michalski, J. G. Carbonell ve T. M. Mitchell (Ed.), *Machine learning: An artificial intelligence approach* içinde (ss. 25-37). Springer.
- Skansi, S. (2018). *Introduction to Deep Learning: From logical calculus to artificial intelligence*. Switzerland: Springer.
- Sokolova, M. ve Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
- Taulli, T. (2019). *Artificial Intelligence Basics: A Non-Technical Introduction*. Monrovia, CA, USA: Springer.
- Todorović, A. (2015). Has The Turing Test Been Passed? 4 Mart 2020 tarihinde <https://isturingtestpassed.github.io/> adresinden erişildi.
- UCI Machine Learning Repository. (2020). UCI Machine Learning Repository: Statlog (Heart) Data Set. 10 Nisan 2020 tarihinde [http://archive.ics.uci.edu/ml/datasets/statlog+\(heart\)](http://archive.ics.uci.edu/ml/datasets/statlog+(heart)) adresinden erişildi.
- Werbos, P. (1974). Beyond regression:” new tools for prediction and analysis in the behavioral sciences. *Ph. D. dissertation, Harvard University*.
- Zikopoulos, P., Eaton, C., deRoos, D., Deutsch, T. ve Lapis, G. (2011). *Understanding big data: Analytics for enterprise class hadoop and streaming data*. New York, USA: McGraw-Hill Osborne Media.

