



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI
NÖROBİLİM YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

NÖROBİLİMDE MAKİNE ÖĞRENMESİ VE GELECEĞİ

Mustafa ACUNGİL

Tez Danışmanı
Prof. Dr. Sinan CANAN

İSTANBUL-2020

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI
NÖROBİLİM YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

NÖROBİLİMDE MAKİNE ÖĞRENMESİ VE GELECEĞİ

Mustafa ACUNGİL

Tez Danışmanı
Prof. Dr. Sinan CANAN

İSTANBUL-2020

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

Anabilim Dalı : NÖROBİLİM
Program : NÖROBİLİM
Öğrenci No : 184202053
Öğrenci Adı Soyadı : Mustafa ACUNGİL

“Nörobilimde Makine Öğrenmesi ve Geleceği” isimli çalışma aşağıdaki jüri tarafından 15.01.2020 tarihinde yapılan sınavda Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir.

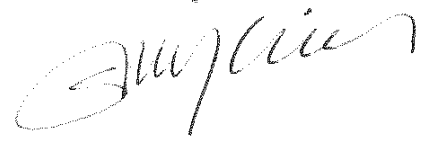
Jüri Başkanı : Doç. Dr. Korkut ULUCAN
(Marmara Üniversitesi)

İmza



Danışman : Prof. Dr. Sinan CANAN
(Üsküdar Üniversitesi)

İmza



Üye : Dr. Öğr. Üyesi Hüseyin ÜNÜBOL
(Üsküdar Üniversitesi)

İmza



ONAY

Bu tez, yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun tarih ve sayılı kararıyla kabul edilmiştir.

Doç.Dr. Türker Tekin ERGÜZEL
Enstitü Müdür V.

ÖZET

NÖROBİLİMDE MAKİNE ÖĞRENMESİ VE GELECEĞİ

Yapay zeka ve nörobilim, gelişim süreci olarak benzer dönemlerde hızlanan bir ivme yakalamışlardır. Yapay zekanın temelini oluşturan makine öğrenmesinin beyin bilimlerini yakından takip edip oradan beslendiğini gözlemliyoruz. Gerek hayvanların öğrenme yöntemleriyle ilgili gözlemler, gerek insanların öğrenme yöntemleriyle ilgili gözlemler, gerekse nörobilim alanında öğrenmenin nöron seviyesindeki bileşenlerine ilişkin bulgular, makine öğrenmesinde çeşitli yöntemlerin geliştirilmelerini sağlamıştır. Bu çalışmanın amacı, makine öğrenmesi yaklaşımının özetlenmesi ve bu yaklaşımların nörobilim alanında ne kadar ve nasıl kullanıldığının incelenmesi, iş dünyasında başta olmak üzere makine öğrenmesinin mevcut kullanıma eğilimlerinin ve biçimlerinin değerlendirilip bir karşılaştırma yapılarak ileride nörobilimde makine öğrenmesinin nasıl ve ne amaçlarla kullanılabileceğine ilişkin çıkarımlar yapılmasıdır. Bu amaçla makine öğrenmesine ilişkin kaynaklar taranarak ana yaklaşımlar aktarılmış, nörobilimde mevcut durumda makine öğrenmesine ilişkin ne gibi kullanımlar bulunduğu araştırılıp örneklendirilmiş, iş dünyasında özellikle büyük veri ile birlikte makine öğrenmesinin nasıl kullanıldığı incelenerek karşılaştırma yapılmış ve nörobilim alanında makine öğrenmesi kullanımının nasıl yaygınlaşabileceği ve değişebileceği sorgulanmıştır.

Anahtar kelimeler: Derin öğrenme, makine öğrenmesi, nörobilim, yapay zeka

ABSTRACT

MACHINE LEARNING AND ITS FUTURE IN NEUROSCIENCE

Artificial intelligence and neuroscience development processes have gained acceleration in similar periods. We observe that machine learning, which forms the basis of artificial intelligence, follows the brain sciences closely and feeds from there. Both observations of animals' learning methods, observations of people's learning methods, and findings of neuron-level components of learning in the field of neuroscience have led to the development of various methods in machine learning. It is aimed in this study to summarize the machine learning approach and to examine how deep and wide these approaches are used in the field of neuroscience; based on that it will be possible to evaluate the current trends and forms of machine learning, especially in the business world, and to make inferences about how and for what purposes machine learning can be used in neuroscience in the future. For this purpose, the main approaches have been summarized by searching the resources about machine learning, the uses of machine learning in neuroscience have been investigated and exemplified, how the machine learning has been used together with big data in the business world has been compared to the use of machine learning in neuroscience today and the issue of how machine learning usage can be spread and changed in the field of neuroscience has been questioned.

Keywords: Artificial intelligence, deep learning, machine learning, neuroscience

TEŐEKKÖR

Makine öğrenmesinin veri bilimi üzerinden bilimsel yaklaşıma giderek daha fazla etki ettiđi bir sürecin içindeyiz. Bu tezin nörobilim alanında bilimsel çalışma yapan ve yapacak olan kişilerin makine öğrenmesinin sağlayacağı katkıları fark etmelerinde bir ağırlığı olması dileđiyle...

Bu süreç içerisinde bana hep destek olan sevgili aileme, zihin açıcı yaklaşımları ve farklı disiplinler arası çalışmaları teşvik edici tavrıyla sevgili hocam Sinan Canan'a, nörobilim ve makine öğrenmesi sürecinde öncül birleştirici çalışmaları ve yaklaşımlarıyla sağladığı destekle sevgili hocam Türker Tekin Ergüzel'e teşekkür ederim.



BEYAN FORMU

Bu alıřmadaki bütn bilgi ve belgeleri akademik kurallar erevesinde elde ettiđimi, grsel, iřitsel ve yazılı tm bilgi ve sonuları bilimsel ahlak kurallarına uygun olarak sunduđumu, kullandıđım verilerde herhangi bir tahrifat yapmadıđımı, yararlandıđım kaynaklara bilimsel normlara uygun olarak atıfta bulunduđumu, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, tarafımdan retildiđini ve skdar niversitesi Sađlık Bilimleri Enstits Tez Yazım Kılavuzuna gre yazıldıđını beyan ederim

15 Ocak 2020

Mustafa ACUNGİL

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
BEYAN FORMU	iv
ŞEKİLLER DİZİNİ	vii
1. GİRİŞ	1
1.1. Araştırmanın Amacı	1
1.2. Araştırmanın Problemleri	1
1.3. Araştırmanın Sınırlılıkları	2
2. GENEL BİLGİLER	3
2.1.Nörobilim ve Yapay Zekanın Gelişim Süreci.....	3
2.2.İnsan Nasıl Öğrenir?.....	4
2.2.1.Psikolojik öğrenme yaklaşımları.....	4
2.2.2.Algoritmik öğrenme	4
2.2.3.Nörolojide Öğrenme	5
2.3.Makine Öğrenmesi (Machine Learning).....	5
2.3.1.Makine Öğrenmesi Problem Tipleri Nelerdir?.....	6
2.3.2.Makine Öğrenmesi Metodolojisi	7
2.3.3. Makine Öğrenmesi Algoritma Yaklaşımlarına Örnekler	11
2.3.3.1.Uzman Sistemler (Expert Systems)	11
2.3.3.2. Bulanık/Saçaklı Mantık (Fuzzy Logic)	11
2.3.3.3.Doğrusal Modeller (Linear Models)	12
2.3.3.4.Karar Ağaçları (Decision Trees)	13
2.3.3.5.Kümeleme (Clustering)	15
2.3.3.6.Yapay Sinir Ağları (Artificial Neural Networks).....	20
2.3.3.8. Genetik/Evrimsel Algoritma (Genetic/Evolutionary Algorithms)	25
2.3.3.9.Karınca Kolonisi Algoritması (Ant Colony Algorithm)	26
3. GEREÇ VE YÖNTEM	27
3.1.Araştırmanın Evreni	27
3.2.Yöntem.....	27
4. BULGULAR	28
4.1. Nörobilimde makine öğrenmesi	29

4.2. İş dünyasında makine öğrenmesi kullanımı	36
4.3. Derin öğrenme kullanım alanları	44
4.4. Veri bilimi (Data Science).....	47
5. TARTIŞMA.....	50
5.1. Nörobilimde makine öğrenmesi ve veri biliminin olası kullanım alanları	50
5.2. Sonuç	51
6. SONUÇ ve ÖNERİLER.....	52
6.1. Sonuç ve Öneriler	52
6.2. Sonuç	52
KAYNAKLAR	53



ŞEKİLLER DİZİNİ

Şekil 1: Makine öğrenmesi modeli ve kullanımı	8
Şekil 2: Makine öğrenmesi süreci	10
Şekil 3: Uzman sistem yapısı	11
Şekil 4: Bulanık kümelerde örtüşüm	12
Şekil 5: Lineer sınıflama	13
Şekil 6: İki faktörlü bir karar ağacı	14
Şekil 7: Cep hattı terk analizi örneği	15
Şekil 8: En yakın komşu sınıflaması örneği	16
Şekil 9: Hiyerarşik kümeleme örneği	17
Şekil 10: K-ortalama kümeleme örneği, ilk adım	18
Şekil 11: K-ortalama kümeleme örneği, ikinci adım	18
Şekil 12: K-ortalama kümeleme örneği, kümeleme öncesi	19
Şekil 13: K-ortalama kümeleme örneği, algoritma çalışma izi	20
Şekil 14: Basit nöron modeli	21
Şekil 15: Yapay sinir ağı örneği	22
Şekil 16: Yapay sinir ağı ile XOR problemi çözümü	23
Şekil 17: LR ve ANN ROC eğrisi karşılaştırması	28
Şekil 18: Tekli modellerin karşılaştırması	30
Şekil 19: Hayvan izlerinden makine öğrenmesi hazırlık ve uygulama aşamaları	33
Şekil 20: Çoklu makine öğrenmesi modelinin MAS skoruna yaklaşma performansı	34
Şekil 21: Derin öğrenmenin bağlantılı alanlarla ilişkisi	45
Şekil 22: Veri bilimi ve diğer alanlarla ilişkisi	48

1. GİRİŞ

Nörobilim ve yapay zeka gelişme zamanlamaları açısından koşut bir şekilde ilerleyen ve birbirinden ilham alma potansiyeli yüksek iki alandır. Yapay zeka kapsamındaki çalışmaların farklı alanlardan yola çıkarak büyük ölçüde makine öğrenmesine dayandığını görülür ve bu makine öğrenmesi temeli tez kapsamında incelenmiş önemli bir bağlamdır. Makine öğrenmesinin detaylarına doğru indiğimizde ise özellikle sinir ağları yaklaşımının nörobilimde elde edilmiş çalışmaların üzerine kurulu olduğunu görülür. Öte yandan nörobilimde makine öğrenmesinin getirdiği imkanlardan yararlanma olgusu ortaya çıkmış olmakla birlikte yayılım alanının bir hayli geniş olduğu düşünülmektedir. Tez kapsamında makine öğrenmesinin kavramları ortaya konduktan sonra nörobilimde mevcut kullanımı ve gelecekteki kullanma potansiyeli incelenmiştir.

1.1. Araştırmanın Amacı

Araştırmanın amacı, makine öğrenmesi kavramını ve unsurlarını anlamak, makine öğrenmesi tekniklerinin nörobilimde mevcut kullanımını belirlemek ve makine öğrenmesinin nörobilimde olası kullanım potansiyelleri üzerine incelemeler yapmaktır.

1.2. Araştırmanın Problemleri

- Makine öğrenmesi teknikleri nelerdir ve temel çalışma mekanizması nasıldır?
- Makine öğrenmesi günümüzde nörobilimde nasıl kullanılmaktadır?
- Makine öğrenmesinin gelecekte nörobilim alanında kullanımını ne yönlere ve nasıl yaygınlaşabilir?

1.3. Arařtırmanın Sınırlılıkları

Nörobilim alanında makine öğrenmesi kullanımı henüz erken aşamalarda bulunmaktadır. Kullanım alanlarıyla ilgili mevcut kısıtlılık, geleceęe yönelik öngörülerde başka alanlarda makine öğrenmesinin kullanılmasıyla karşılaştırarak genişletilmiştir.



2. GENEL BİLGİLER

2.1.Nörobilim ve Yapay Zekanın Gelişim Süreci

Beyinle ilgili MÖ 4000'e kadar giden çalışma bulguları olmakla birlikte modern nörobilimin ortaya çıkması 1800'lerin ikinci yarısındaki gelişmelerle mümkün olmuştur. Bu alandaki asıl büyük ilerlemeler ise beyin görüntüleme tekniklerinin gelişmesiyle 1900'lü yıllarda sözkonusu olur. Erken bazı tekniklerin dışında asıl gelişmeler 1970-80 aralığı ve sonrasında gelişmiştir. (Carter ve ark., 2013, s:8-9)

Yapay zeka çalışmalarına baktığımızda ilk gelişmelerin 1960'ların ortasında olduğu görülür. 1970'lerde artan hareketlilik zaman zaman duraklamalar yaşanmakla birlikte 1980'lerden itibaren artarak devam etmiştir. Ve günümüzde artık yapay zeka pek çok alanda yaygın şekilde kullanılmaktadır. (Nilsson, 2018)

Yapay zekanın nörobilimden en belirgin bir şekilde yararlanması yapay sinir ağları kavramında görebiliriz. Beynin çalışma sistemini bilgisayar ortamında taklit eden yapay sinir ağlarındaki gelişmelerin ilk uygulamaları 1950'lerde ortaya çıkmış ama özellikle XOR probleminin çözülememesi ile 1970'lerde sekteye uğramış, yeni yaklaşımlarla bu problemin aşılmasının ardından asıl gelişmeler 1980'lerden itibaren ortaya çıkmıştır. (Öztemel, 2006, s: 37-42)

Yapay zekanın gelişim süreci boyunca üzerinde durduğu konuları şöyle sıralayabiliriz: Örüntü tanıma, sezgisel problem çözme, sezgisel programlar, mantıksal programlama, bulanık mantık, doğal dil işleme, bilgisayarla görme, hareket etme, robot bilim, oyunlar, konuşma tanıma ve işleme, uzman sistemler, sinyal işleme, anlamsal ağlar, yapay öğrenme, makine öğrenmesi, akıllı aletler. Yapay zekanın gelişmeye devam etmesiyle bu alanlara yenilerinin eklenmesi de beklenebilir. (Nabiyev, 2016, s: 8-10; Nilsson, 2018, s: vii-xi)

Yapay zekadaki tüm bu çalışma alanlarının temeline inildiğinde makine öğrenmesinin önemli bir rol oynadığı görülür. Bilgisayar sistemlerinin zeka benzeri davranışlar gösterebilmesi makine öğrenmesi teknikleriyle sağlanan öğrenme sayesinde olmaktadır. (Nabiyev, 2016, s: 563-573)

2.2.İnsan Nasıl Öğrenir?

İnsanın nasıl öğrendiğine ilişkin farklı disiplinlerde çalışmalar yapılmıştır. Bunlar psikolojik, algoritmik ve nörolojik yaklaşımlar olarak gruplandırılabilir.

2.2.1.Psikolojik öğrenme yaklaşımları

Psikoloji biliminde öğrenmeye ilişkin çalışmalarda öne çıkan yaklaşımlar alışma, klasik şartlandırma, araçsal şartlandırma ve karmaşık öğrenme olarak tanımlanabilir. Alışmada, bildik ve sıradanlaşan bir nesnenin yok sayılması öğrenilir. Klasik şartlanmada bir uyararla takip eden uyarar arasındaki ilişki öğrenilmiş olur. Araçsal şartlandırmada organizma, girdinin sonuçla ilişkisini öğrenir. Karmaşık öğrenme ise bağlantıların kurulmasından fazlasını içerir ve öğrenilen yapı bir model haline gelip benzer başka dış ortamlara taşınır. (Atkinson ve ark., 2015; s:232-265) Makine öğrenmesinde modellerin öğrenmesinde ödül mekanizmalarının kullanılması, öğrenmiş bir modelin daha genel durumlar için tahminler oluşturması gibi unsurlar psikolojik öğrenme yaklaşımlarından bileşenler içerir. (Alpaydın, 2013; s: 28-31, 426-438)

2.2.2.Algoritmik öğrenme

Öğrenmenin algoritması üzerine çalışmalar, psikolojik yaklaşımlardan matematiksel ve istatistiksel modellemelere çok daha yoğun başvurularıyla farklılaşırlar. Bilgisayarlar öncesinde de algoritmalar kullanılmakla birlikte bilgisayarların ve yazılım sektörünün gelişmesiyle algoritmik yaklaşımlar çok daha fazla yaygınlaşmışlardır. Mesela eldeli çıkarmayı nasıl yapacağımızı algoritmik olarak öğreniriz. Yazılımlar ise bilgisayarlara iş yapmayı öğreten yönergelerden yani algoritmalarından oluşturulurlar. Önce sadece aktarılan kurallar serisi olan algoritmalar, yani matematik tabanlı algoritmalar varken algoritmik öğrenmeye yönelik çalışmalarla istatistik tabanlı algoritmik yaklaşımlar yaygınlaşmıştır. Bunlar sabit kurallar yerine veriden öğrenen, değişebilen, dinamik öğrenici algoritmalarlardır. (Domingos, 2015; s:27-37) Çok sayıda farklı algoritmadan oluşan bu yaklaşımlar makine öğrenmesi ana çatısı altında çeşitli uygulama ortamlarında ve uygulama kütüphanelerinde kullanılmaktadırlar.

Algoritmik öğrenme, insanın davranış olarak dışarıdan gözlenebilen öğrenmesini bilgisayar ortamına taşıyan önemli bir alan sağlamıştır.

2.2.3.Nörolojide Öğrenme

Nörobilimin giderek gelişmesi ve canlı sinir hücreleriyle uygulamalı deneylerin artması, öğrenmenin moleküler temellerine ilişkin çıkarımlar yapılabilmesini mümkün kılmıştır.

Önce sinapsların deneyimle değiştiğine ilişkin görüş ve bulgular ortaya çıkmıştır. Bu alandaki önemli önerilerden biri 1949'da psikolog D.O. Hebb tarafından yapılmıştır. Hebb, kısa süreli belleğin nöronların yansımali devreleri sayesinde gerçekleştiğini öne sürmüştür. (Kandel, 2016, s: 260-262) Daha sonra yapılan deneysel çalışmalar öğrenmede nöronlar arasındaki moleküler etkileşimin rolüne kadar detaylandırma sağlamıştır. Uzun süreli potansiyel artışının mekanizmasında NMDA reseptörlerinin kilit önemi, nöronlar arasında mevcut sinapsların öğrenmeye bağıli olarak güçlenmesi ve yeterince etkili durumlarda yeni sinapsların oluşumu gibi unsurlar belgelenmiştir. (Kandel, 2016; s: 366-368)

2.3.Makine Öğrenmesi (Machine Learning)

Makinenin öğrenmesinin nasıl mümkün olabileceğini görmek için basit bir örnek üzerinden değerlendirelim. Öncelikle kullanılacak algoritma, belirsizliği ve olasılığı, istatistiksel durumları dikkate almak zorundadır. Nabiyev'in (2016, s:567-573) örneğini özetleyecek olursak:

Geri beslemeli bir öğrenme modelinin kuş ve uçağı ayırt etmeyi öğrenmesi gerekiyor olsun. Bir kuşun ve uçağın kanadı ve kuyruğı olduğunu, sadece kuşun gagası ve tüyleri olduğunu, sadece uçağın motoru ve şasisi olduğunu biliyor olalım. Ama sistemimiz henüz bu bilgileri bilmemektedir. Elimizdeki bir örneğın verilerini sisteme girdiğimizde, sistem önce hiç bilmediğı için rastgele bir tahmin yapar. Bu tahminin doğru ya da yanlış olduğu geri besleme olarak sisteme verilir. Ve sistem bu geri beslemeden çıkarım yapar, hangi özelliğın hangi tipte varlıkla ya da hangi tipteki varlıkların ortak özellikleriyle çakıştığını öğrenir. Bu öğrenmenin bir kısmı yanlış, bir kısmı doğrudur. Sonraki örneklerle tahmin yapıp doğru ya da yanlış geri beslemeleri aldıkça sistemin

öğrenmesi gelişir. Böylelikle bir süre sonra doğruya bir hayli yakın tahminler yapabilir hale gelecektir. Gerçek hayatta olasılığa dayalı durumlarda aynı girdilerle farklı sonuçlar elde edilebildiği için çoğu durumda tam isabet edecek bir öğrenme gerçekleştirilemez. Ancak fayda oranı çok yüksek modeller ortaya çıkabilir. Bu sebeple makine öğrenmesi modellerinde modelin isabet oranının farklı yaklaşımlarla kontrol altında tutulması önemlidir. (Provost ve ark., 2013, s: 209-232)

Karar ağaçları ile ilgili bir başka örneği ele alalım. Siegel'in örneği (2016, s:177-182) kredi erken ödeme riski tahminleme üzerinedir. Karar ağacı yaklaşımı kullanan örnekte, kökten başlayarak bir soru sorulur ve bu sorunun cevabı evet ve hayır olan dallarındaki erken ödeme risk oranı yeniden hesaplanır. Alt dallarda tekrar sorular sorularak yeni kırılımlardaki erken ödeme risk oranı yeniden hesaplanır. Hangi soruların öncelikli olarak sorulacağı, ne derinliğe kadar soru sorulmaya devam edileceği gibi konular, kullanılan algoritmanın parametreleri aracılığıyla yönlendirilir.

Bu örneklerde görüldüğü gibi, makine, insanın öğrenmesini taklit eden bir yaklaşımla, istatistik kökenli algoritmaları kullanarak öğrenen modeller üretebilme potansiyeline sahiptir.

2.3.1.Makine Öğrenmesi Problem Tipleri Nelerdir?

Makine öğrenmesinde algoritmalar belirli tipte soruları cevaplamak üzere tasarlanmışlardır. Elimizdeki bir bilimsel problemi ya da bir iş problemini bu tipte sorulara dönüştürmemiz ya da bölmemiz gerekir. (Provost ve ark., 2013; s:19-42)

Algoritmalar çok çeşitli olmakla birlikte, ele alınan problem tipleri daha kısıtlı bir sayıda listelenebilir. Bunları şöyle sıralayabiliriz (Provost ve ark., 2013; s:20-23):

1. Sınıflama ve olasılık tahmini (Classification): Makine öğrenmesine konu olan veri kümesinin satırları için iki ya da daha fazla önceden belirlenmiş olası çıktıdan hangisinin geçerli olduğunu tahmin etmeye dayanır.

2. Regresyon / değer tahmini (Regression): Makine öğrenmesine konu olan veri kümesinin satırları için sayısal bir büyüklük çıktısı vardır ve model bu değeri tahmin etmeye çalışır.

3. Benzerlik (Similarity): Birbirine benzer unsurları bulmayı hedefler. Örnek olarak seçtikleri ürünlere göre benzer müşterilerin kimler olduğunu belirlemeyi gösterebiliriz.

4. Kümeleme (Clustering): Elimizdeki veri kümesinde anlamlı alt kümelerin neler olduğunu ve bunların arasındaki sınırları belirlemek için kullanılır.

5. Birliktelik (Association): Bir arada tercih edilen ya da gerçekleşen kümeleri ve bunların olasılıklarını belirlemeye yarar. Örnek olarak bir 30-40 yaşları arasındaki insanlarda nörobilimsel anomalilerin hangilerinin birlikte görülme olasılığının ne olduğunu incelemeyi gösterebiliriz.

6. Profilleme (Profiling): Belirli bir kümenin betimsel olarak analiz edilmesi için kullanılır.

7. Bağlantı tahmini (Recommendation): İki varlık arasında ilişki olasılığına odaklanır. Örnek olarak sosyal medya ortamındaki belirli kişiler arasında ilişki önerilmesi durumunda kabul görmesinin olasılığının tahminlenmesini verebiliriz.

8. Veri indirgemesi (Dimensionality Reduction): Çok miktarda özellik içeren bir veri kümesinde, kümenin içindeki örüntülerde büyük bir kayıp yaşamadan daha az özelliklerle kümeyi temsil etmeyi hedefler.

9. Sebep analizi (Causation): A/B testi gibi çeşitli yöntemlerle eylemlerdeki birlikteliğin ötesinde sebep sonuç analizlerine odaklanır.

Ayrıca bu problem tiplerini sınıflarken öğrenmenin gözetimli olup olmadığı şeklinde bir üst grup da düşünebiliriz (Provost ve ark., 2013; s:24-25). Gözetimli öğrenmede öğrenmeye konu olan veri kümesinde sonuçlar da bulunmaktadır. Zaten bilinen sonuçlar üzerinden örüntüleri yakalamak esastır. Sınıflama ve regresyon gibi problem tipleri gözetimli öğrenmenin konusudur. Gözetimsiz öğrenmede ise öğrenmeye konu olan veri kümesinde bir çıktı bulunmamaktadır. Kümeleme problemi gözetimsiz öğrenmeye örnek olarak verilebilir.

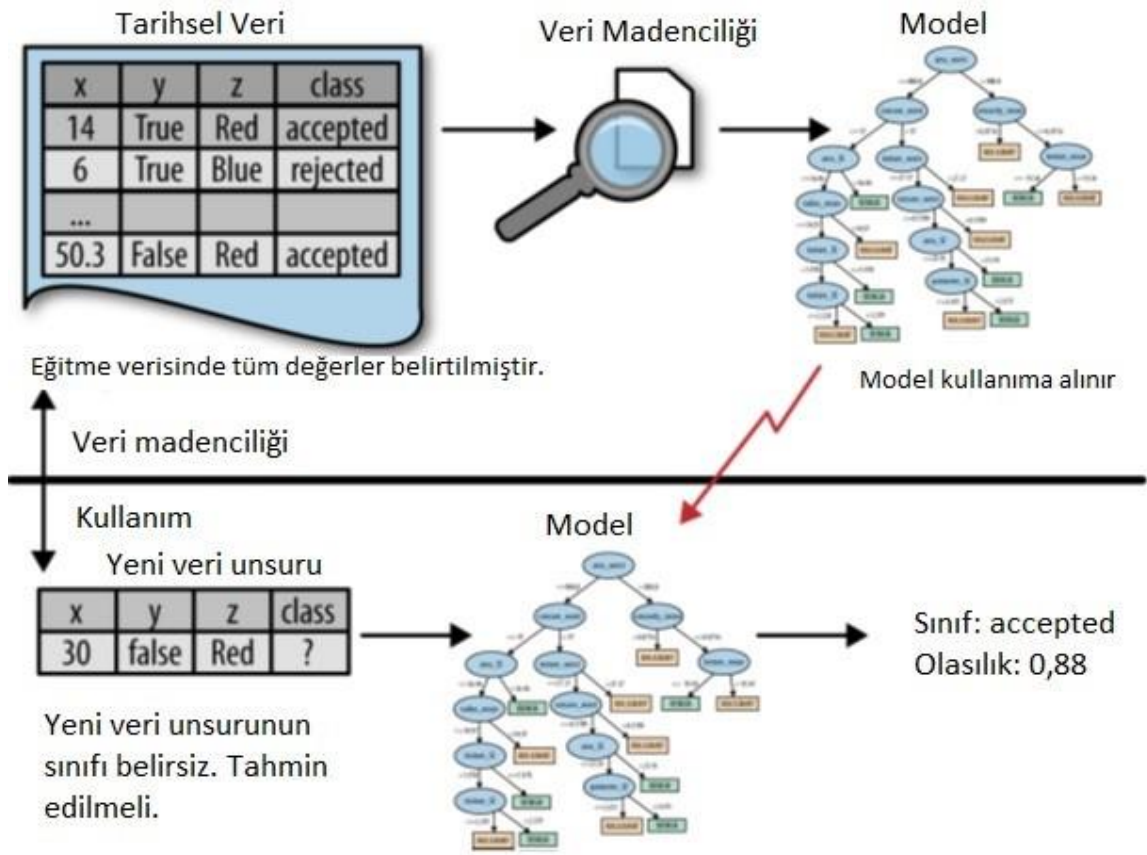
2.3.2. Makine Öğrenmesi Metodolojisi

Şekil 1'de veri madenciliği ya da makine öğrenmesinde model oluşturma ve kullanma yapısı anlatılmıştır. (Provost ve ark., 2013; s:26)

Öğrenme verisinde veri kümesinin tüm satırlarında gerekli girdi bilgileri bulunmaktadır. Gözetimli öğrenme tipinde olan sınıflama örneği olduğu için sınıfın da veride bulunduğunu görmekteyiz. Makine öğrenmesi teknikleri kullanılarak bu veriden öğrenilir ve bir model oluşturulur.

Sonrasında sonucu henüz bilinmeyen veri satırları bu modele sorularak sınıfları tahmin edilir. Model en yüksek olasılıklı sınıfı çıktı olarak verdiği gibi o sınıfa ait olma olasılığını da belirtir. Çoklu sınıf olan uygulamalarda her bir sınıf için tahmin edilen olasılığı modelden edinmek de mümkündür.

Modelin kullanımı böyle olmakla birlikte modelin oluşturulması süreciyle ilgili de benimsenmiş yaklaşımlar mevcuttur. Bunlardan en bilinen ve yaygın olarak kullanılanı CRISP sürecidir. Sürecin ismi Cross Industry Standard Process for Data Mining'in kısaltmasından gelmektedir. (Provost ve ark., 2013; s:26-34)



Şekil 1: Makine öğrenmesi modeli ve kullanımı (Provost ve ark., 2013; s:26)

Şekil 2'de gördüğümüz CRISP sürecinde ilk dikkat çeken unsur, adımlama ve sürekliliğin sürecin doğasında olduğudur. Şeklin etrafındaki sürekli döngü, makine öğrenmesindeki sürekliliği ifade eder. Modelin öğrenmesi ve geliştirilmesi belirli aralıklarla ele alınıp sürdürülmelidir.

Sürecin adımlarını inceleyecek olursak...

Konuyu Anlamak (Business Understanding): Modeli oluşturabilmek için modelin ele aldığı konuyu iyi anlamak gereklidir. Problemin doğru ifade edilmesi, hangi makine öğrenmesi problem tipine ya da tiplerine karşılık geldiğinin doğru anlaşılması gibi önemli başarımlar bu aşamanın sağlıklı gerçekleştirilmesiyle yakından ilişkilidir.

Veriyi Anlamak (Data Understanding): Makine öğrenmesi verinin içindeki örüntülere odaklıdır. Sonuçla bağlantısı yüksek olan bir veriyi girdi olarak vermediyseniz bu verinin ilişkisinin ortaya çıkması mümkün değildir. Etkili olabilecek veriler, bunların hangi kaynaklardan nasıl temin edilebileceği, veri kirliliği sorunları, verinin güvenilirliği gibi pek çok konunun bu aşamada ele alınması gerekir.


Şekildeki geri oklara dikkat edilirse, veri anlayışında fark edilen unsurların konuyu anlamaya yeniden ışık tutması gibi bazı aşamalarda geri dönüşler doğaldır.

Veri Hazırlığı (Data Preparation): Ele alınan konunun hangi makine öğrenmesi problem tipine adresleneceğini de dikkate alarak, sonucu elde etmeye yönelik veriye ilişkin anlayışımızı kullanarak veri hazırlığı yapmamız gerekir. Veri kirliliği ile ilgili sorunlar ya da modelin daha iyi çalışması için bazı verilerin zenginleştirilmesi gibi unsurlar bu aşama ve modelin oluşturulmasının ardından bu aşamaya geri dönüşlerde ele alınır. Özellikle geleceğe yönelik tahminlerde giriş verileri içinde, tahmin yapılıyorken henüz bilinmeyecek olan veri kolonlarının bulunmamasına dikkat etmek önemlidir.

Modelleme (Modeling): Bu aşamada var olan makine öğrenmesi algoritmalarından konuya ilişkin uygun olanları kullanılarak modeller oluşturulur. Bir sonraki aşama olan değerlendirmeyle modelleme iç içe düşünülebilir. Modelin başarımlarını değerlendirilerek algoritma parametrelerinde değişiklikler, farklı algoritmaların denenmesi, veri zenginleştirme, verideki tespit edilen hataların giderilmesi gibi pek çok çalışma gerçekleştirilerek modelin daha iyileştirilmesi sağlanır.

Değerlendirme (Evaluation): Makine öğrenmesi modelleri matematik kesinliğe değil, istatistik belirsizliğe dayanır. Test edilmeleri, doğru konumlanmaları son derece önemli bir adımdır. Verinin üçe ayrılıp birinci kısmıyla modelin eğitilmesi, ikinci kısmıyla eğitim sırasında testlerin yapılması ve model yeterince olgun haline geldiğinde henüz hiç görmediği üçüncü kısımın doğrulanması, yaygın uygulamalardandır. Bir başka yaklaşım verinin kendi içinde yatay olarak mesela 10 kısma bölünmesi ve her aşamada kısımlardan dokuzunun eğitim sıradaki kısmın da doğrulama için kullanılmasıdır. Böylece verilerin tamamı sıralı olarak hem eğitim için hem test için kullanılmış olur. Pilot çalışmalarını da değerlendirme aşamasının bir yaklaşımı olarak belirtmek gerekir. Eldeki

verilerle yapılan doğrulamalardan başarıyla geçen bir model, yaygın kullanıma alınmadan önce sahada pilot çalışmalarıyla yeniden doğrulanmalıdır.



Şekil 2: Makine öğrenmesi süreci (Provost ve ark., 2013; s:27)

Yayma (Deployment): Makine öğrenmesini yapay zekaya çeviren aşama yaymadır. Model kullanılacağı yerde gerekli veri ve çıktı entegrasyonları yapılarak yaygın kullanıma alınır. Bu aşamada modelin gelişen ortama uyum sağlaması için yeniden öğrenme otomasyonunun da ele alınması gerekir.

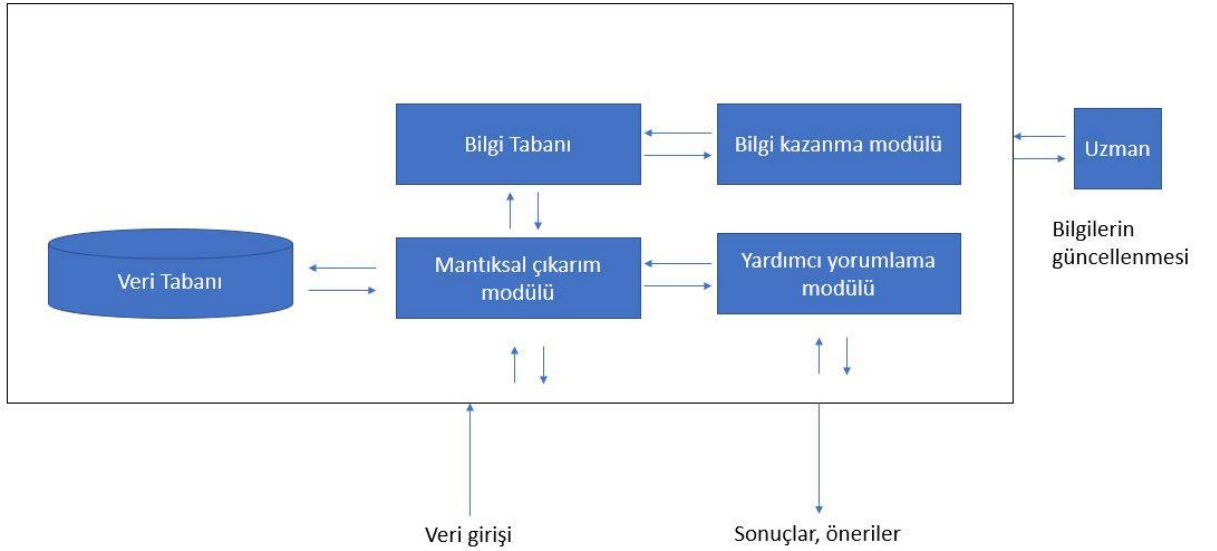
2.3.3. Makine Öğrenmesi Algoritma Yaklaşımlarına Örnekler

Yapay zekanın erken aşamalarında uzman sistemler ve bulanık mantığın etkin olduğu görülür. Bunlar tam olarak makine öğrenmesi yaklaşımı olmasa da öncüller olarak önemlidirler.

2.3.3.1. Uzman Sistemler (Expert Systems)

Uzman sistemlerde Şekil 3'te de görüldüğü gibi, bir bilgi tabanı geliştirilerek kullanılır. Karar vermede kullanılan kurallar bütünü insan eliyle toplanır. Ancak bu kurallar bütünü oluşmasında ve kullanılmasında yazılım yöntemleri kullanılabilir. Bilgi kazanımı makine öğrenmesinin geleneksel yaklaşımlarındaki kadar algoritmik değildir.

Uzman sistemler her ne kadar makine öğrenmesi derinliğine sahip değillerse de, bir konuyla ilgili uzmanların düşünce yapısında gizli olan kuralları belirleyip bir yazılım sistemine aktarmak ve böylece bu düşünsel yapının genel kullanıma açılmasını sağlamak konusunda bir hayli başarılıdır. (Nabiyev, 2016; s: 417-437)

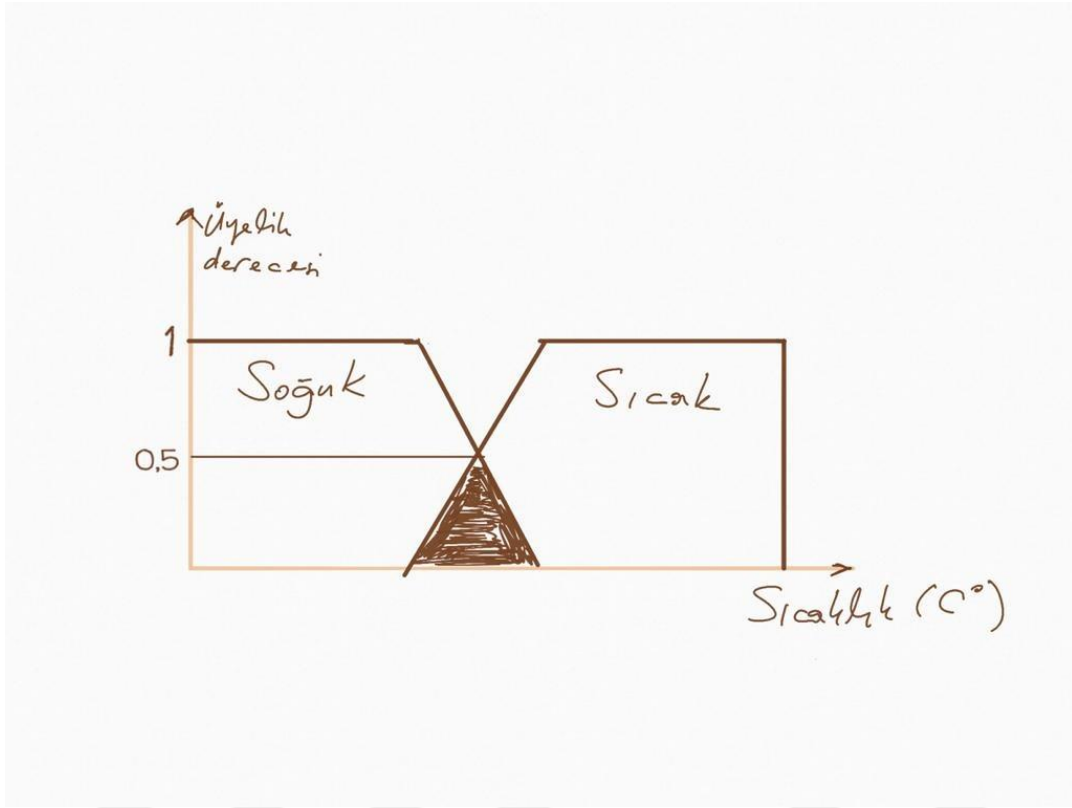


Şekil 3: Uzman sistem yapısı (Nabiyev, 2016; s:419)

2.3.3.2. Bulanık/Saçaklı Mantık (Fuzzy Logic)

Bulanık mantık öğrenmenin algoritmik olduğu bir yapı değildir. Ancak kuralların kesin ifadeler yerine üyelik olasılığı şeklinde ifade edilmesiyle, matematik çıkarım yaklaşımından istatistik çıkarım yaklaşımına geçiş açısından önemlidir. Kuralları istatistik algoritmalara dayalı olarak kesinlik değil olasılık bazında öğrenen makine öğrenmesi modellerine geçişte önemli bir aşama olmuştur. (Elmas, 2011, s: 185-374)

Bulanık mantıkta, insanların genel değerlendirme ifadelerindeki biraz soğuk, biraz sıcak, çok soğuk gibi kavramlara uyum sağlanır. Şekil 4'te görüldüğü gibi bir hali olmanın derecelerinden yararlanır.



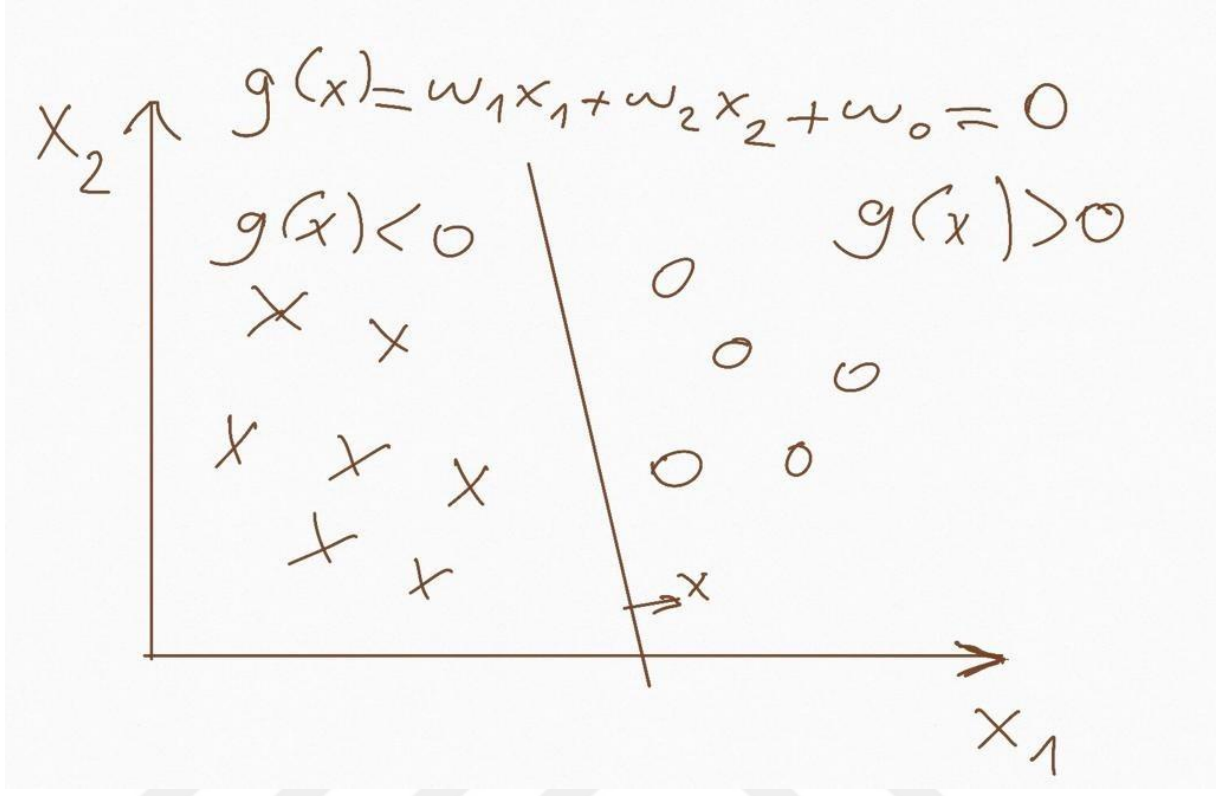
Şekil 4: Bulanık kümelerde örtüşüm (Elmas, 2011, s: 191)

2.3.3.3. Doğrusal Modeller (Linear Models)

Doğrusal modeller, veri noktalarını uzayda yerleştirip onları düzlemsel olarak sınıflara ayırma temeline dayanarak hareket eder. Aslında pek çok makine öğrenmesi algoritması veri örneklerinin girdi bilgilerini boyutlar olarak konumlayıp, örneklerin herbirini çok boyutlu bir uzayda konumlayıp onları ayıran yapıları bulmaya çalışır. Şekil 5'teki doğrusal model sadece iki boyutu ele aldığı için modellerin bu yaklaşımı gözle de rahatlıkla anlaşılabilir durumdadır. Sınıflandırma ikiden çok çıktı sınıfı üzerinden yapıldığında ya da boyutlar ikinin üstünde olduğunda çok daha karmaşık bir matematik söz konusu olduğu için insan gözüyle anlaşılır olma şansı azalır. (Alpaydın, 2013; s: 175-195)

Doğrusal modeller doğrusal yapıları sebebiyle her problem için uygun değildirler. Ancak girdilerin logaritmalarının alınması gibi yollarla üselliğinin

giderilmesi gibi ve başka pek çok yöntemle kullanım alanları bir hayli genişletilebilmektedir.



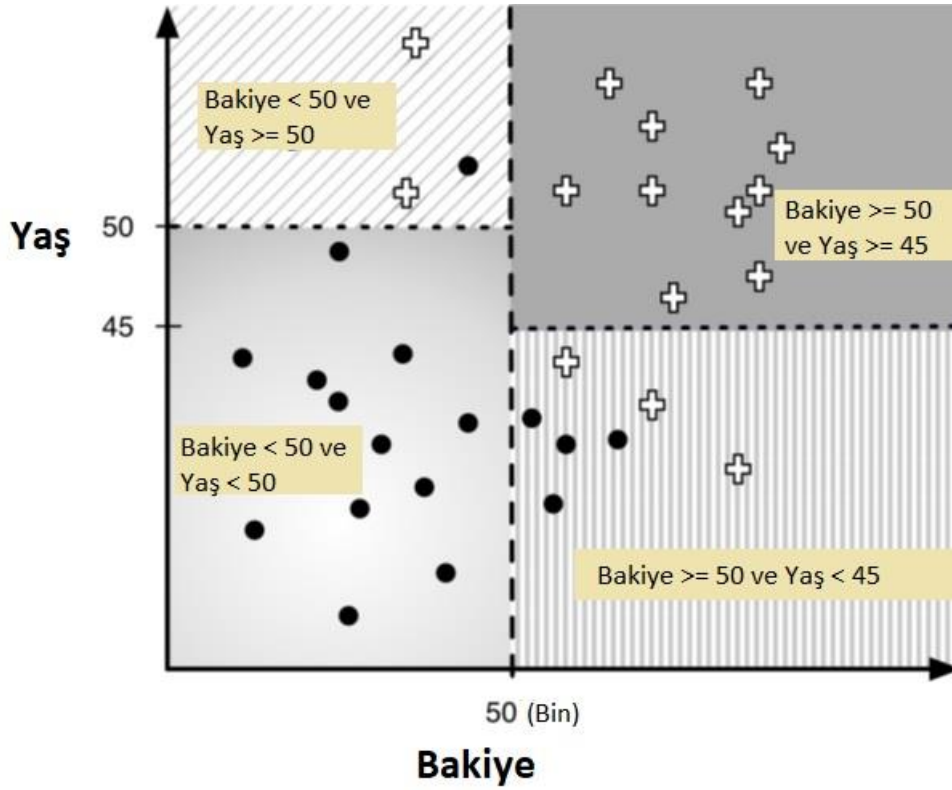
Şekil 5: Lineer sınıflama (Alpaydın, 2013; s: 178)

2.3.3.4. Karar Ağaçları (Decision Trees)

Karar ağaçları insanın bilinçli düşünce seviyesine ve bilinçli seviyede karar almada kullandığı tekniklere görece yakın bir algoritma mantığıyla çalışır. Şekil 6'daki örnek üzerinden inceleyecek olursak, yaş ve banka hesabındaki faktör değerlerinin bir ürünü tercih edip etmeme ile ilişkisi kurulmuştur.

Lineer bir modelle bu veri üzerine model kurmaya çalışıyor olsak, bir doğru geçirmeye çalışıyor olacaktık. Karar ağaçlarında ise faktörlerin değerlerine ilişkin sorular sorularak detaya doğru dallanan ters bir ağaç yapısı oluşturulur.

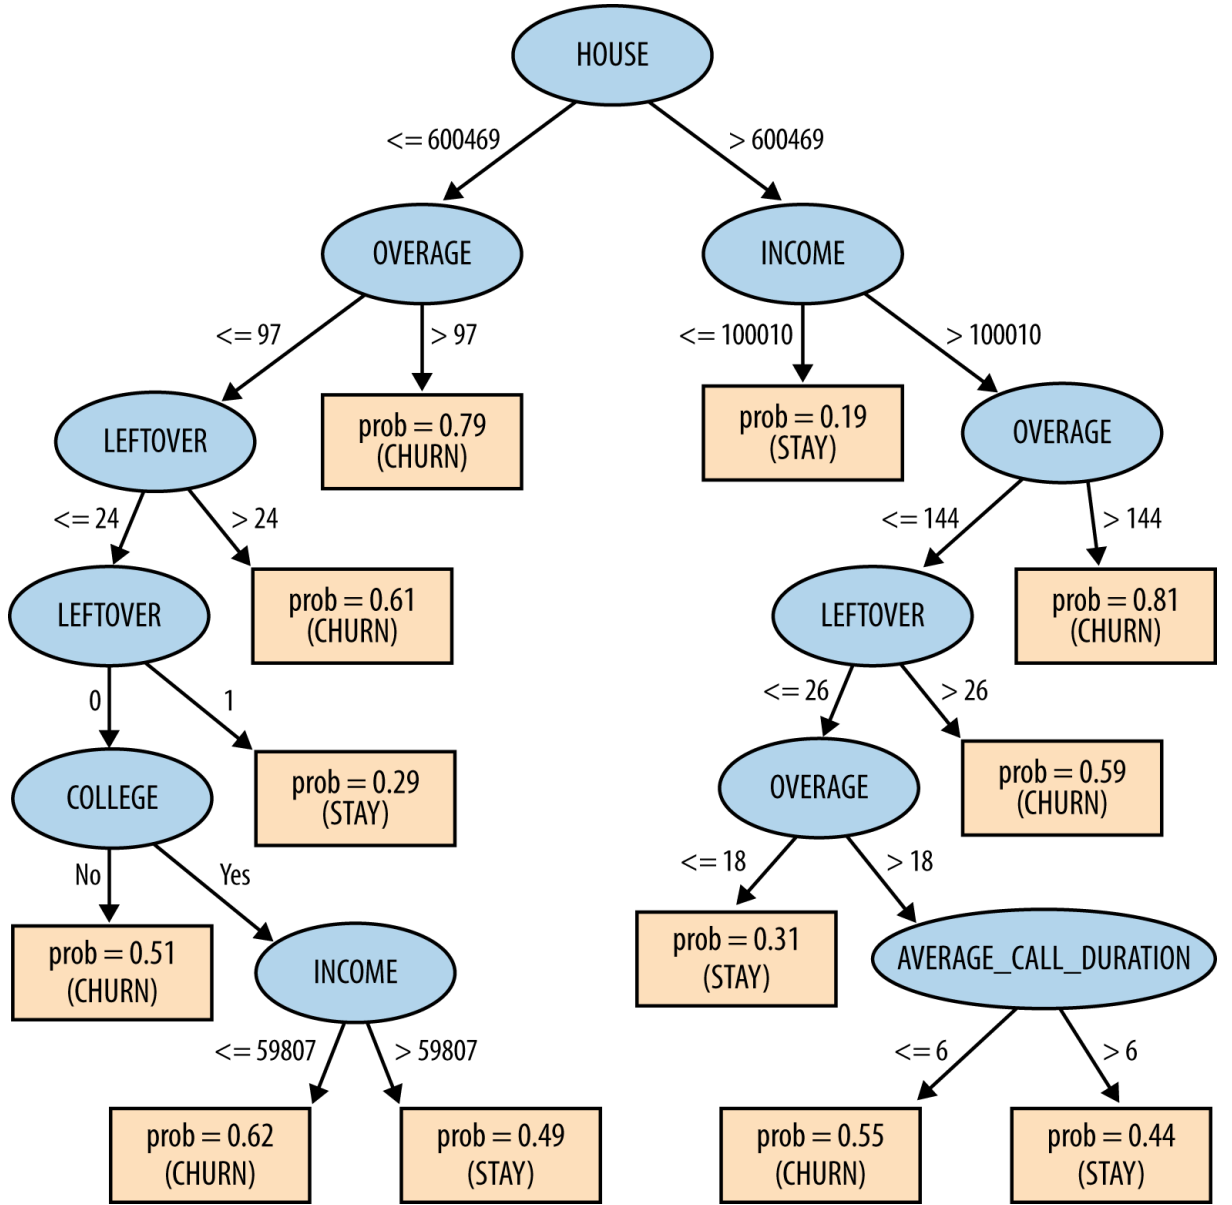
Şekil 7'de biraz daha karmaşık bir karar ağacını inceleyelim.



Şekil 6: İki faktörlü bir karar ağacı (Provost ve ark., 2013; s:83)

Elimizde takip eden belirli bir sürede aboneliğini bitirip bitirmediğini bildiğimiz bir veri kümesi bulunmakta ve bu kümeyle ilgili evinin değeri (House), yıllık gelir (Income), ortalama çağrı süresi (Average_Call_Duration), tarife aşımı var mı (Overage) gibi bilgilere de sahibiz. Bu durumda karar ağacı modelleri bizim için veriden öğrenerek Şekil 7'deki gibi ağaçlar oluşturabilirler.

Model, belirleme derecesine göre önceliklendirdiği ve sınır değerlerini belirlediği faktörlere sorular sorarak alt kırılımlara iner. Amaç entropiyi en hızlı şekilde azaltmaktır. Yani model tüm olasılıklara bakmaz, entropiyi azaltma potansiyeli yüksek olan soruları bularak o sorular üzerinden kırılımları yaparak aşağı dallara iner. Böylece verideki desenleri yakalama ihtimalini artırır ve bunu yaparken de işlem gücü gereksinimini makul seviyede tutar. (Provost ve ark., 2013; s:43-79)

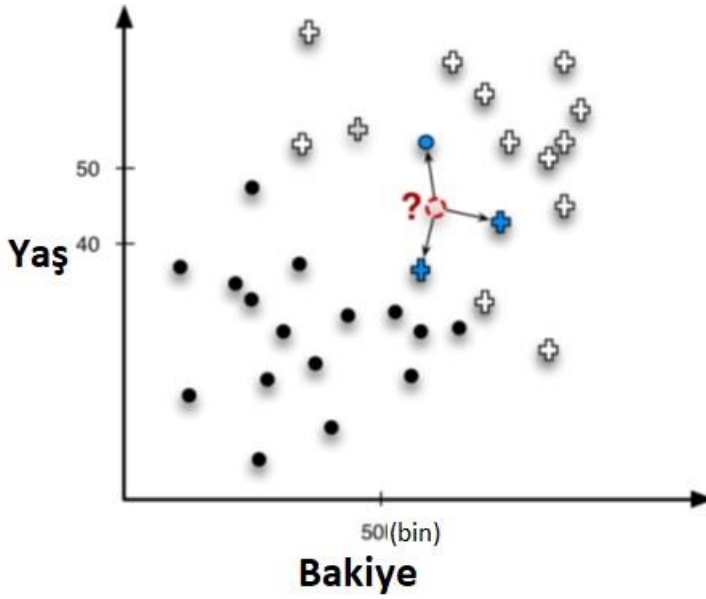


Şekil 7: Cep hattı terk analizi örneği (Provost ve ark., 2013; s:77)

2.3.3.5.Kümeleme (Clustering)

Makine öğrenmesinin pek çok yaklaşımında tahmin edilmeye çalışılan kategorik ya da sürekli sayısal bir büyüklük vardır. Ama başka bazı yaklaşımlar da bir çıktı tahmin etmekten çok girdilerin yakınlığı, nasıl anlamlı alt kümelere ayrılabilceği üzerinedir. Benzerlerini bulma, komşularını bulma, uygun kümelere bölme gibi amaçlar gözetilebilir. Bu tür problemler noktaları sayısal bir uzayda tanımlayıp aralarındaki mesafeleri ölçmek üzerinden çalışır. (Provost ve ark., 2013; s:141-186)

Şekil 8’de örneğini gördüğümüz yaklaşımda en yakın komşu yaklaşımı üzerinden yeni bir üyenin hangi sınıfa ait olduğu görülmektedir.



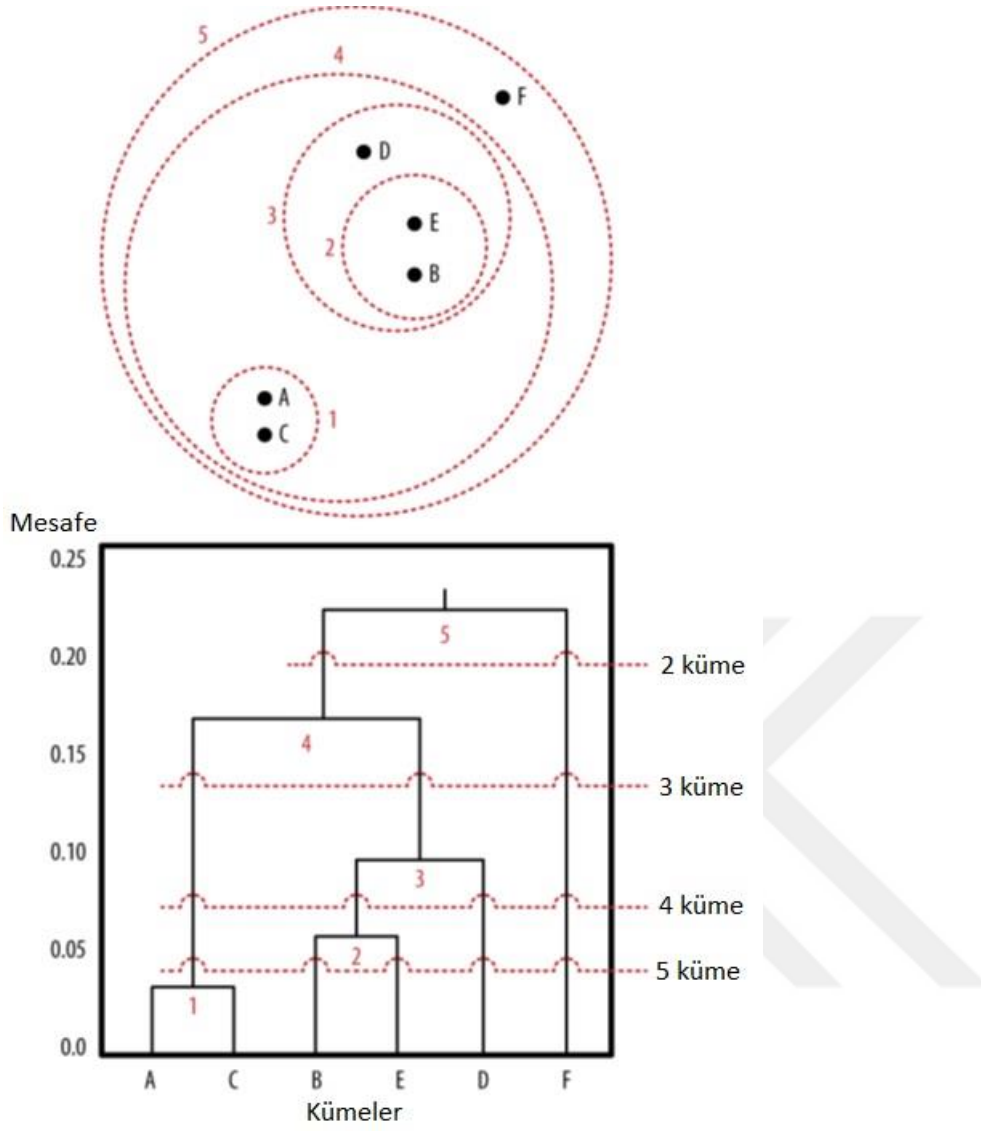
Şekil 8: En yakın komşu sınıflaması örneği (Provost ve ark., 2013; s:148)

Klasik makine öğrenmesi yaklaşımlarında önceden eğitilmiş bir modele soru sorma yaklaşımı kullanılırken en yakın komşu sınıflamasında önceden öğretilmiş bir model yoktur. Veri noktalarının kendileri kayıt altındadır ve yeni bir nokta geldiğinde en yakın belirli sayıda noktanın ölçümü yapılarak onlara ait bir ortalama ile tahmin gerçekleştirilir. Kümelemeden farklı olarak tahmin ettiğimiz bir değer bulunur.

Kümelemede kullanılan ana yaklaşımlardan birisi ise Şekil 9’da örneği görülen Hiyerarşik Kümelemedir.

Hiyerarşik kümelemenin en tepesinde tüm noktalar tek bir küme olarak kabul edilir. En dibinde ise her bir nokta kendi kümesindedir. Mesafelerin ölçümü yoluyla yukarıya doğru çıkıldıkça daha yakın noktalar aynı kümede birleştirilir. Böylece hangi yükseklikten bakmak istiyorsanız o yükseklikteki kümeleri ve kümelerin içinde birleştirilmiş noktaların neler olduğunu görmüş olursunuz.


Yaygın kullanılan bir başka kümeleme yaklaşımı ise k-ortalama kümelemedir.




Şekil 9: Hiyerarşik kümeleme örneği (Provost ve ark., 2013; s:166)

Bu algoritmik yaklaşımda kaç grup oluşturulmak istendiği bir parametredir, baştan belirtilir. Örnekte olduğu gibi 3 küme oluşturulması istenmiş olsun. Var olan noktalar için rastgele üç merkez tespit edilir. Başlangıç için her bir var olan nokta hangi rastgele seçilmiş merkeze yakınsa ona ait kabul edilir.

Sıradaki adım ise Şekil 10'da görüldüğü gibi her bir merkeze ait olarak belirlenmiş noktaların ağırlık merkezlerinin bulunması ve başlangıçta rastgele atanmış ilgili merkezin Şekil 11'de görüldüğü gibi yeni belirlenen ağırlık merkezine kaydırılmasıdır.



Şekil 10: K-ortalama kümeleme örneği, ilk adım (Provost ve ark., 2013; s:172)



Şekil 11: K-ortalama kümeleme örneği, ikinci adım (Provost ve ark., 2013; s:171)


Bu adımlar tekrarlanarak süreç devam eder.

Yani yeni merkeze göre var olan noktaların aitlik durumu yeniden tanımlanır. Yeniden kümelemede aynı merkeze bağlanmış noktaların tekrar ağırlıklı ortalaması alınır ve iki süreç yine tekrarlanır.


Tekrarlar arasında değişme belirli bir seviyenin altına düştüğünde ise kümeleme gerçekleştirilmiş olur.

Şekil 12’de görülen veri kümesini ele alalım. Bu veri kümesi henüz algoritmanın çalışmamış halidir. Şekil 13’te ise k-ortalama kümeleme algoritmasının tekrarlı adımlarla çalışma izi görülebilir.

Rassal olarak seçilen başlangıç noktaları sonucu etkileyebileceği için, k-ortalama kümelemede bir kez başlamak yerine çoklu sayıda başlangıçlar yapılabilir. Bu çoklu yaklaşımların sonuçlarına birlikte odaklanmak, iyilerini seçmek gibi iyileştirmeler söz konusudur.



Şekil 12: K-ortalama kümeleme örneği, kümeleme öncesi (Provost ve ark., 2013; s:173)




Şekil 13: K-ortalama kümeleme örneği, algoritma çalışma izi (Provost ve ark., 2013; s:173)

2.3.3.6.Yapay Sinir Ağları (Artificial Neural Networks)

Makine öğrenmesinde kullanılan algoritmik yaklaşımlar içinde yapay sinir ağları, insanın ya da diğer canlıların öğrenmesiyle ilgili dış gözlemlerin ötesinde, doğrudan beyin içinde hücresel ölçekteki çalışma mekanizmalarını örnek alarak geliştirilmiştir. Öyle ki nöronlar, aralarındaki bağlantılar ve ateşlemelere ilişkin pek çok kavramın karşılığı yapay sinir ağlarında bulunmaktadır. Mesela nörolojideki hücreye karşılık yapay sinir ağlarında birimler bulunmaktadır. Benzer şekilde sinapslara karşılık ara bağlantılar ve bunların ağırlıkları; destekleyici (excitatory) girişlere karşılık pozitif ara bağlantı ağırlıkları; yasaklayıcı (inhibitory) girişlere karşılık negatif ara bağlantı ağırlıkları; hücre fiziği ile sınırlı aktifleme aralığına karşılık işlemci karakteristiğiyle sınırlı aktifleme aralığı bulunmaktadır. (Nabiyev, 2016; s: 580-584) Şekil 14’te görüldüğü gibi basit nöron modeli, beyindeki nöronların şematik, basitleştirilmiş bir görünümünden çok da farklı değildir.


En basit haliyle bu yapıda ve bunun üzerine geliştirilmiş daha karmaşık pek çok yapay sinir ağı yaklaşımında x giriş değerleri w sinir eklemi katsayıları ile çarpılarak toplanır. Ve nöron ya da birim bu toplama dayalı olarak bir çıktı üretir.



Şekil 14: Basit nöron modeli (Nabiyev, 2016; s:585)

Şekil 15'te birimlerin bir arada nasıl çalıştıklarının bir örneği görülebilir. Nöronlara benzer şekilde bir birim birden çok birimden beslenebilmektedir. Birimler tek başlarına değil birlikte iş yaparlar. Aynı katmanda birden çok birim olduğu gibi, birden çok katman birlikte ortak bir sonuca doğru da çalışmaktadır. Bu yapılar, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi amaçlarla kullanılabilirler. Yapay sinir ağları makine öğrenmesi gerçekleştirmekle birlikte diğer yaklaşımlardan bir hayli farklıdır. Bilgi ağı kendisinde saklanır, ifade edilebilmesi, gösterilebilmesi pek kolay değildir. Ağdan soyutlanamaz. Örneklerle öğrenirler. Eğitilmelerinde ve performanslarının test edilmesinde pek çok ince ayar bulunabilmektedir. Bu ayarlarla öğrenme performansı arasındaki ilişki deneyseldir, bilinçli insan aklının anlayacağı şekilde açıklanması pek mümkün değildir. Başka bazı algoritmalarda sorun oluşturan eksik bilgi yapay sinir ağları tarafından tolere edilebilir. Benzer şekilde hata toleransı açısından da başarılıdır. Dereceli bozulma gösterirler. Sadece nümerik bilgiler ile çalışabilmektedirler ama nümerik olmayan girdiler için de girdinin değeri 0 ya da 1 olarak kodlanarak kullanılma imkanı vardır. (Öztemel, 2006; s:29-33)

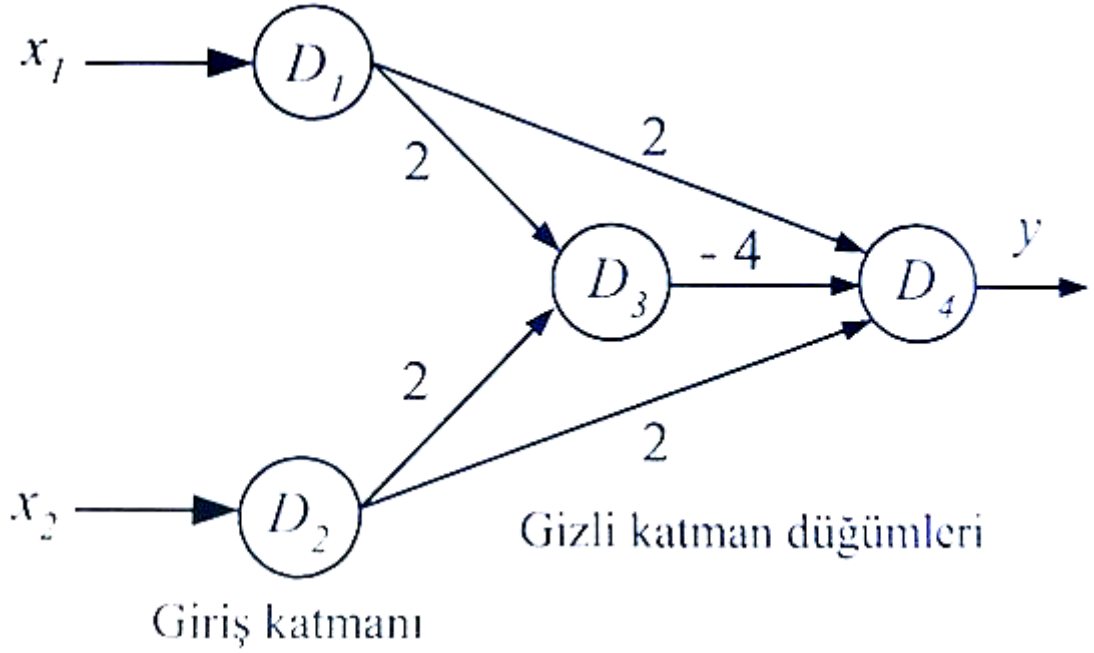
Yapay sinir ağlarının gelişim tarihinde önemli bir konu olan XOR problemini ele almamız yararlı olabilir. Birinci nesil yapay sinir ağları XOR problemini çözemedikleri için gözden düşmüşler, sonra tek katmanlı yerine çok katmanlı yapay sinir ağlarının kullanılmasıyla bu problem aşılarak yapay sinir ağlarının gelişmesi tekrar hızlanmıştır. XOR probleminin yapay sinir ağıyla bir çözümü Şekil 16'da görülmektedir. Gizli katmanın sinirlerinin eşik değerleri 3 için 2,5 ve 4 için 1 olarak ele alınmıştır. (Elmas, 2011; s: 44-47)



Şekil 15: Yapay sinir ağı örneği (Öztemel, 2006; s:29-33)

XOR probleminde her iki girdi aynı olduğunda yani her ikisi 0 ya da her ikisi 1 olduğunda sonuç 0 olmalı, iki girdi birbirinden farklı olduğunda sonuç 1 olmalıdır. Şekildeki yapay sinir ağını değerlendirecek olursak; her iki girdi sıfır olduğunda D1 ve D2'den tüm çıktılar 0 olur. Bu durumda D4'ün de tüm girdileri 0 olur ve sonuç 0'dır.

D4'ün eşik değeri 1 olduğu için ve 0 1'den küçük olduğu için genel sonuç 0'dır. Her iki girdinin 1 olduğu durumu ele alırsak; D1'den ve D2'den D3'e 2 ve 2 gelir. D3 bunların toplamı olan 4'ü alır. Eşik değerinin üzerinde olduğu için D3'ün çıktısı 1 olur. D4; D1, D2 ve D3'ten beslenir. Bunların çıktıları ile ağırlıkların çarpımlarının toplamını alır. Yani $(1*2) + (1*-4) + (1*2) = 0$. D4'ün eşik değeri 1 olduğu için ve 0 1'den küçük olduğu için genel sonuç 0'dır. Girdilerin ilkinin ya da ikincisinin 1, diğerinin de 0 olması durumu simetriktir. Birinin çözümünü göstermekle yetinelim. D1'e 1, D2'ye 0 girmiş olsun. D1'in çıktısı 1, D2'nin çıktısı 0'dır. D3'ün girdisi $(1*2) + (0*2) = 2$ olur. Eşik değer olan 2,5'tan küçük olduğu için D3'ün çıktısı 0'dır. D4 için girdi ve ağırlıkların özeti şöyledir: $(1*2) + (0*-4) + (0*2) = 2$. 2, eşik değer olan 1'den büyük olduğu için sistem doğru şekilde 1 çıktısını üretir.



Şekil 16: Yapay sinir ağı ile XOR problemi çözümü (Elmas, 2011; s:46)

Katman ve birim sayılarının artması ve katsayıların iyi eğitilmesi durumunda yapay sinir ağları çok karmaşık problemleri çözmekte kullanılabilir.

2.3.3.7. Derin Öğrenme (Deep Learning)

Derin öğrenme, temel yaklaşım olarak yapay sinir ağlarını esas almakla beraber ondan çok daha fazlasıdır. Derin kelimesinin kullanımı, yapay sinir ağlarındaki ara katman sayısının burada çok daha fazla olmasından kaynaklanır. Hem ara katman sayısı hem de ara katmanlardaki birim sayıları çok yüksektir. Ara katman sayısının ve birimlerin sayılarının böyle yüksek olması, derin öğrenmenin daha önce zorluk çekilen pek çok konuda başarılı öğrenme yapabilmesini gerçekleştirmiştir. Ama derin öğrenmeyi mümkün kılan, sadece bu teorik yaklaşım değildir. Oyun bilgisayarlarındaki gelişmeler doğrultusunda ortaya çıkan grafik işleme birimlerinin yüksek performansı ve sonrasında bulut teknolojilerinin çok yüksek işlem güçlerine erişim sağlamaları derin öğrenmenin teknik olarak yapılabilirliğini mümkün kılmıştır. Öte yandan böyle güçlü bir öğrenme için gerekli olan yüksek miktarda girdi verisi de dijital dünyanın hızla genişlemesi ve insanların çeşitli dijital ortamlarda büyük miktarda örnek veriyi gönüllü ve biraz da farkında olmadan oluşturmaları sayesinde ortaya çıkabilmiştir. Resimlerdeki nesnelere tanımlama, el yazısı örnekleri, çeviri örnekleri gibi pek çok konuda, derin öğrenmenin öğrenmesi için gerekli yüksek miktarda veri, kitlesel olarak insanların yaptıkları etiketlemelerle mümkün olmuştur. (Say, 2018; s:103-105)

Bulut sistemleri, çeşitli yönleriyle derin öğrenmeyi mümkün kılar ve daha da geniş kullanım alanlarına yayılmasını sağlar. Bulut sistemlerinde, yerel olarak yüklü miktarda işlem gücü satın alıp yapılandırmak yerine, ihtiyaç duyduğunda ihtiyacınız olan kadar bir sistemi kullanıma almanız ve ihtiyacınız giderildiğinde sistemi kaldırmanız mümkündür. Böylece sadece gereksinim duyulan zaman için bir maliyet gerçekleşir. Toplam satın alma ve yaşatma maliyetine katlanmaya gerek kalmamış olur. Böylece makul bir maliyetle derin öğrenmenin ihtiyaç duyduğu altyapı sorunu çözülmüş olur. Üstelik bu ortama insanların erişimi de pek çok insanın her an yanında bulunan akıllı telefonları üzerinden gerçekleşir. Böylece bilgisayarın işleme kısmı çok güçlü olan bir bulut sistemine çıkmışken, ara yüz kısmı da çok daha mobil bir şekilde telefon üzerinden insanların sürekli etkileşimine açık olur. (Acungil, 2018; s:62-67)

Derin öğrenmenin ihtiyaç duyduğu yüklü miktarda veri de büyük veri yapıları sayesinde gerçekleşmiş olur. Büyük veri 4 V ile ifade edilir: Volume (hacim), Velocity (hız), Variety (çeşitlilik), Veracity (belirsizlik). Buluttan da yararlanan büyük veri

yapıları büyük hacimli, büyük bir hızla oluşan, büyük çeşitlilik içeren ve belirsizliğe de dayanıklı veri yığınlarına imkan tanır. (Acungil, 2018; s:79-81)

Büyük veriyi mümkün kılan bazı gelişmeleri şöyle sıralayabiliriz:

- Barkod yerine RFID ve diğer sensörlerin kullanılması
- Sensör ağlarının yaygınlaşması
- Yenilikçi bilimsel çalışmaların küçük veri setleri yerine çok daha büyük veri setleri içinde anlam ve bağlantı aramayı gerektirmesi
- Her insanın çok düşük maliyetlerle ve kendi başına bir yayın evi, bir yapım evi, bir yayın kanalı haline gelebilmesi
- Makineler arasında yoğun etkileşim
- Sanallaştırma ve bulut teknolojilerinin işlem gücüne ihtiyaç duyduğunuzda erişmenizi mümkün kılması
- Paralel işleme yaklaşım, teknoloji ve araçlarının gelişmesi
- Makine öğrenmesi, derin öğrenme gibi yöntemlerle büyük veriyi elde edip yönetmenin anlamlı sonuçlarının ortaya çıkması. (Acungil, 2018; s:76-79)

2.3.3.8. Genetik/Evrimsel Algoritma (Genetic/Evolutionary Algorithms)

Makine öğrenmesinin ilginç ve yenilikçi yaklaşımlarından birisi, genetik algoritmadır. Evrimsel gelişim sürecini inceleyen bu algoritma yapısı, evrim sürecini bilgisayar ortamında öğrenme amacıyla simüle eder. Adımlarını şöyle sıralayabiliriz:

- Başlangıç çözüm grubu oluşturulur. Bu grup olası çözümleri kodlar. Grubun kendisine toplum, çözümlerin kodları da kromozom olarak adlandırılır. Toplumda bulunacak birey sayısı için 100 ila 300 aralığı genelde uygun görülmektedir.
- Toplumdaki her bir kromozomun hedeflenen sonuç için ne kadar iyi olduğu hesaplanır. Burada bir uygunluk fonksiyonu kullanılmaktadır ve genetik algoritmanın temel eksenini bu uygunluk fonksiyonu oluşturur. Evrimleşmenin gelişimini teyit ve kontrol eden ve başarıyı belirleyen bu uygunluk fonksiyonu olmaktadır.
- Uygunluk fonksiyonuna göre seçilen kromozomlar arasında eşleyerek yeniden kopyalama ve çeşitlilik sağlamak için değiştirme operatörleri uygulanır. Bu süreçler

doğal süreçteki üreme ve yeni nesil oluşumu ve bu sırada da mutasyon ve çaprazlamaların gerçekleşmesine denk düşmektedir.

- Yeni kromozomlara yer açmak için eski kromozomlar çıkarılır ve sabit büyüklükte popülasyonla ilerlenir. Bu aşamada eski kromozomlardan yüksek başarı gösteren belirli bir miktarın korunması tercih edilebilmektedir.

- Tüm kromozomlar uygunluk fonksiyonu ile yeniden değerlendirilir ve toplum ölçüğünde başarı hesaplanır.

- Buraya kadar bahsedilen süreç tekrarlı bir şekilde gerçekleştirilerek kuşaklar boyunca süren bir evrimle istenen öğrenmenin gerçekleşmesi sağlanır.

- İstenen başarı ölçüsünü sağlayan en iyi bireylerin oluşmasıyla çözüm gerçekleştirilmiş olur. (Nabiyev, 2016; s: 616-638)

2.3.3.9.Karınca Kolonisi Algoritması (Ant Colony Algorithm)

Karınca kolonisi algoritması karıncaların yiyeceklere olan yolun en optimum alternatifini bulmak için kullandıkları yöntemi taklit eder. Karıncalar, bu optimizasyonu salgıladıkları feromon aracılığıyla yaparlar. Bir yiyeceğe gidip gelen alternatif üç yol bulunduğunu düşünelim. Bu yollardan ikisi birbirine yakın uzunlukta, üçüncüsü ise diğer ikisinin yarısı kadar olsun. Bu durumda kısa yolu tercih eden bir karınca, uzun yoldan giden karıncaların bir kere gidip geldiği sürede iki kere yiyeceğe gidip oradan yuvaya dönmüş olacaktır. Dolayısıyla yakın yolu tercih eden karıncanın bıraktığı feromon, uzak yolu tercih edenlerinkine göre iki kat olur. Feromonlar bir yandan da uçup kaybolmaktadır. Böylece daha kısa olan yolda feromon hep daha güçlü olur. Diğer karıncalar feromonun daha güçlü olduğu izi takip ederek kısa yolu kullanmış olurlar. Öte yandan bazı karıncalar rastgele olarak düşünülebilecek yollar da takip ederler. Böylece çeşitliliği de sağlamış olurlar. Algoritma karıncaların feromona dayalı bu davranışını taklit ederek çalışır (Nabiyev, 2016; s:640-647).

3. GEREÇ VE YÖNTEM

3.1.Araştırmanın Evreni

Araştırma, nörobilimde makine öğrenmesinin nasıl bir kullanımı olduğu ve gelecekteki yönelimlerin nasıl gerçekleşebileceği üzerinedir.

Bu bağlamda araştırılan, tarama yapılan ve incelenen konular şunlardır:

- Nörobilimde makine öğrenmesi yaklaşımı kullanılan bilimsel araştırma örnekleri
- İş dünyasında makine öğrenmesi kullanım örnekleri
- Bilim dünyasının başka alanlarında makine öğrenmesi ve özellikle derin öğrenme kullanım örnekleri
- Makine öğrenmesi yaklaşımı ile geleneksel bilimsel yaklaşım arasındaki farklılıklar
- Makine öğrenmesinin geleneksel bilimsel yaklaşım üzerine olası etkileri
- Bilim ve iş dünyasındaki diğer kullanımlardan yola çıkarak makine öğrenmesi ve derin öğrenmenin nörobilimde nasıl etkiler yapabileceğine ilişkin çıkarımlar


3.2.Yöntem

Çalışma tekil örneklerin incelenmesi yanı sıra çok sayıda çalışmanın katalog taranmasını da içermektedir. Tekil incelemelerle yaklaşımların detaylarının anlaşılması ve gerekli durumlarda kaynaklar üzerinden konunun detaylarına erişim hedeflenmiştir. Katalog taramalar ise, uygulamaların ne tür alanlarda ne genişlikte yayılabileceğini incelemek açısından önem kazanır.

4. BULGULAR

Çeşitli makine öğrenmesi tekniklerinin nörobilim alanında bilimsel çalışmalarda aktif bir şekilde kullanılmakta olduğu görülmektedir. Ergüzel ve arkadaşlarının (2019) “Binomial Logistic Regression and Artificial Neural Network Methods to Classify Opioid-Dependent Subjects and Control Group Using Quantitative EEG Power Measures” başlıklı çalışması bu konuda örnek olarak ele alınabilir.

Ergüzel ve arkadaşlarının (2019) çalışmasında 75 eroin bağımlısı ve 59 sağlıklı kişinin EEG verileri üzerinden sınıflama gerçekleştirme amacıyla makine öğrenmesi yöntemleri sınanmıştır. EEG verileri ile ilgili ön çalışmaların ardından, ortaya çıkan yüksek miktardaki girdi özellik sayısı sorununu aşmak için genetik algoritma kullanılmıştır. Böylece girdi özellikler içinde anlamlı olanların ayrışması sağlanmış ve asıl çalışmada kullanılacak yapay sinir ağlarının daha verimli ve yüksek başarılı çalışması mümkün olmuştur. Lojistik regresyonla elde edilen sonuçların performansına göre genetik algoritma ile ön beslemesi yapılan yapay sinir ağlarının çok daha yüksek bir performans gösterdiği ve üstelik daha az sayıda girdi özellik kullandığı belirlenmiştir. Sonuçların sayısal karşılaştırması Ergüzel ve arkadaşlarının (2019) çalışmasında detaylı olarak bulunmaktadır. Şekil 17’de performansların grafik karşılaştırması görülebilir.



Şekil 17: LR ve ANN ROC eğrisi karşılaştırması (Ergüzel ve ark., 2019)

Sonuçların her ikisinin de EEG verileri üzerinden makine öğrenmesi ile eroin bağımlısı ve sağlıklı ayrımının yapılması konusunda umut verici olduğu görülmektedir.

EEG verileri üzerinden makine öğrenmesi teknikleri kullanmaksızın anlamlı çıkarımların yapılabilceđi alanlar çok daha kısıtlı kalmaktadır. Bu veriler, insan gözüyle ve deneyimiyle incelenmek için çok karmaşık bir ölçektir. Oysa bu çalışmada görüldüğü gibi, makine öğrenmesi teknikleriyle yüksek miktarda EEG verilerinin hem indirgenmesi hem de sınıflandırma gibi işlemler için kullanılabilmesi mümkün olmaktadır.

4.1. Nörobilimde makine öğrenmesi

Nörobilimin yenilikçi konularında makine öğrenmesini kullanmak neredeyse bir zorunluluktur. Mesela ampute insanların takma kol kullanmaları gibi durumlarda, beyinlerindeki hareket ifadelerini sinyallerden çözümleninin başka bir yolu mümkün görünmemektedir. Makine öğrenmesi kullanan hayvan deneylerinde denek hayvanların milisaniye bazında ne yönde ve açıda hareket etmek istedikleri tespit edilebilmektedir. (Savage, 2019)

fMRI gibi yöntemlerde neredeyse her saniyede beyinin 1-2 milimetrelık bölümlerinden sinyal alınır ve bu kayıtlar saatlerce sürebilir. Bu tür bir veri büyüklüğünü makine öğrenmesi olmadan analiz etmek mümkün değildir. (Savage, 2019)

Görme ve işitme gibi duyuların analiz ve taklit edilmesi de ancak makine öğrenmesi tekniklerini kullanarak mümkündür. Yine etik gerekçelerle yapılamayan deneysel insan beyni çalışmaları, ancak makine öğrenmesiyle üretilmiş dış simülasyonlar üzerinden gerçekleştirilebilir. (Savage, 2019)

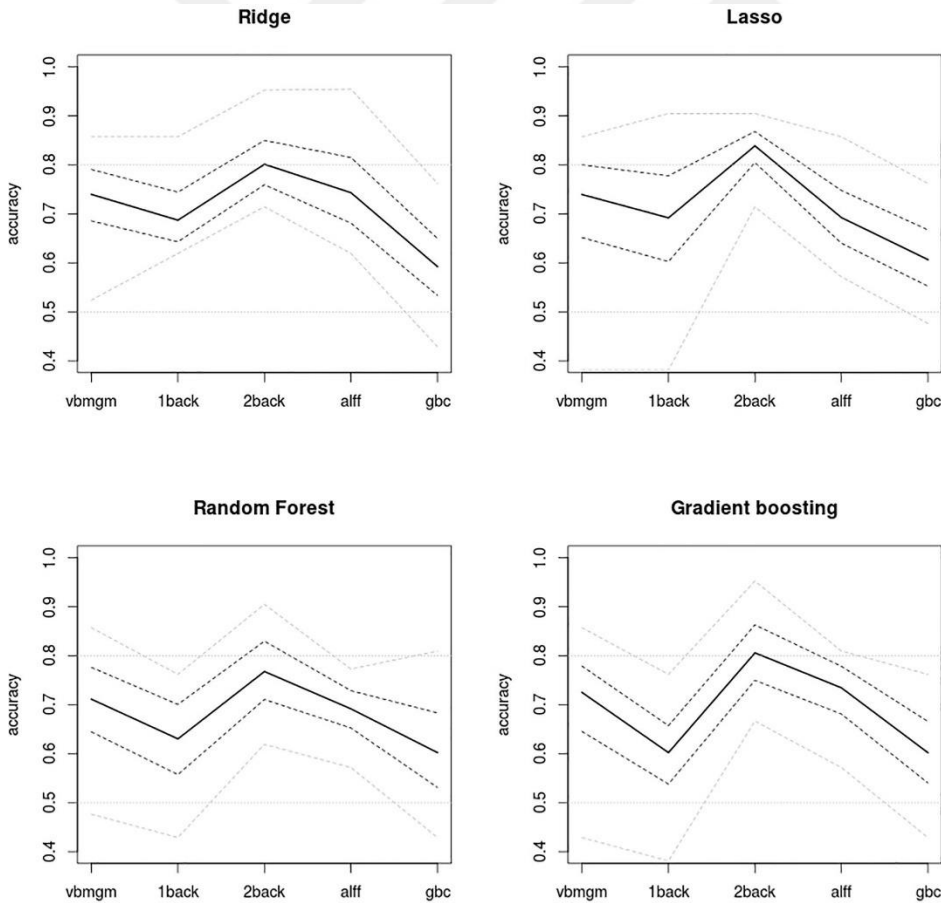
Yine de makine öğrenmesi, beyni çözmüş olduğumuz anlamına gelmez. Çünkü derin öğrenme yapılarında bile çoğu durumda örnekli öğrenme gerçekleşmektedir. Oysa insan beyni neredeyse hiç yönlendirme olmadan sürekli gözlem ve çıkarımlarla yönlendirmesiz öğrenmeyi becerebilmektedir. Derin öğrenmeye bunu yaptırmanın yolu henüz keşfedilememiştir. (Savage, 2019)

Makine öğrenmesindeki ana problem tiplerinden üçü; sınıflama, regresyon ve kümelemedir. Nöronlar seviyesindeki faaliyetleri gözlemlediğimiz her durumda dış ortamdaki tahminler için makine öğrenmesini kullanmamız mümkün olabilir. Mesela bir öneriyi beğenen ya da beğenmeyen insanın beyin sinyalleriyle öğrenilmesi için sınıflama, bir ürüne fiyat biçen bir insanın beyin sinyallerinden ne kadarlık bir fiyat biçtiğinin

regresyonla tahminlenmesi, beyin sinyallerinin kendi içinde kümelenip anomalilerin tespit edilmesi...

Tüm bunlar, makine öğrenmesi kullanmadan gerçekleştirilmesi olanaksız çalışmalardır.

Nörobilim alanında makine öğrenmesine dayalı bir başka çalışmada, Salvador ve arkadaşları (2019) şizofreni alanına yönelir. Çalışmaları, makine öğrenmesinin teşhis alanında olası kullanımlarına işaret etmektedir. Çalışmada şizofreniye sahip 96 hasta ve 115 sağlıklı kontrol üzerinde tek multimod MRI oturumu uygulanmıştır. Elde edilen beş beyin haritası üzerinde dört ayrı sınıflandırıcı makine öğrenme algoritması ile (Ridge, Lasso, Random Forests, Gradient boosting) çalışma gerçekleştirilmiştir. Farklı beyin haritalarının sağladığı ek faydalar incelenmiş ve sayısallaştırılmıştır. Ayrıca çalışmada makine öğrenme modellerinin ayrı ayrı kullanılmasının yanı sıra birlikte kullanımlarının (ensemble) getirdiği faydalar da incelenmiştir. Şekil 18’de dört modelin ayrı ayrı kullanımlarındaki başarımlarının karşılaştırılması görülmektedir.



Şekil 18: Tekli modellerin karşılaştırması (Salvador ve ark., 2019)

Ek fayda analizi, haritaların birbirlerine göre ürettikleri ek faydanın anlamlı olduğunu göstermiştir. Yani tek bir haritadan çıkarım yapmak yerine haritaların birleşik kullanımlarının başarıyı artırma olasılığı yüksektir. Çalışmada yapılan çoklu mod analizleri tekli modun en iyi başarımları civarında başarılar göstermiştir.

Bu tür çalışmaların özellikle yüksek riskli ve erken evre hastalar üzerinde çalışarak geliştirilmesi ve daha yüksek işlem güçleri kullanılarak beyin haritalarının daha yüksek çözünürlükte kullanılmalarıyla pratik faydası yüksek uygulamalar doğurması olası görülmektedir. (Salvador ve ark., 2019)

Daikoku'nun (2019) müzik sekansları üzerine olan araştırma konusu, makine öğrenmesi ile incelenebilecek önemli bir nörobilimsel alana işaret eder: İstatistiksel öğrenme. Müzikteki ton uyumluluğu ve sekansın araştırılmasına yönelik çalışmada, beyinde istatistiksel öğrenmenin söz konusu olduğu çeşitli alanlara da dikkat çekilir: Müzik becerisi edinme, dil becerisi edinme, hedefe ulaşma adımları, bilgedeki belirsizliği çözümüleme, bilgi karmaşıklığını kodlama, eylem kararları, karar alma, konuşurken ya da yazarken söz dizimi ve daha fazlası. Serebral kortekste edinilen istatistiksel bilginin serebelluma gönderiliyor olabileceğine ilişkin bulgulara da yine bu çalışmada işaret edilmektedir. Serebellumun çalışmaları, motor yetenek edinme, alışkanlık edinme, genelleme ve soyutlama becerileri açısından önem arz etmektedir ve bunların tamamında istatistiksel öğrenme önemli bir rol oynamaktadır. İstatistiksel öğrenmeye ilişkin veri çalışmaları için pek çok uygun makine öğrenmesi yaklaşımı bulunmaktadır. Zaman serileri ve Markov zincirleri bu tip yaklaşımlara örnek olarak gösterilebilir. (Daikoku, 2019)

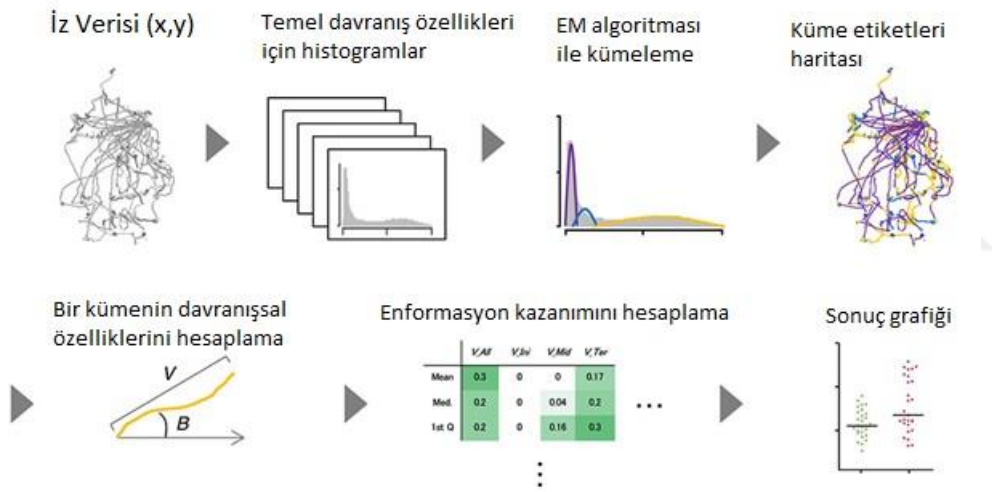
Solouki ve arkadaşlarının (2019) çalışması ise, nöronlar arası etkileşimlerde olası bozulmaların etkisinin matematik, istatistik ve makine öğrenmesi modelleriyle çok daha zengin bir şekilde incelenebileceğini gösterir. Klasik çalışmalar daha çok belirli bir sinaptik yolun belirgin bozulmasının davranış üzerindeki etkisini inceler ve karmaşık mekanizmaları hesaplayabilme şansından yoksundur. Etki ile davranış arasında doğrudan ve kesin bir ilişki yakalanabilir ama çoğu zaman nöronlar arası etkileşim çok karmaşıktır ve davranıştaki bozulmaya etki yoldaki tek bozulmayla net bir şekilde bağlanamayabilir. Bunun yerine daha karmaşık bir ilişkiler bütünü vardır ve bu ilişkiler bütünü inceleyebilmek için makine öğrenmesi yaklaşımları çok daha zengin imkanlar sunar.

Makine öğrenmesi modellerinin gerçek deneylerle birlikte kullanılarak, deney simülasyonları oluşturması ve gerçek deney tasarımlarını ve başarımlarını güçlendirmesi de ilginç olabilecek kullanım alanlarından biridir. Jensen ve arkadaşları tam da bu konu

üzerine bir bilimsel çalışma gerçekleştirmişler. (2019) Ele aldıkları konu, insanların ve hayvanların geçişli durumlarda geçiş çıkarımını nasıl yaptıklarına ilişkindir. Bunlar, bir küme eleman arasındaki sıralamaları keşfetmek için kullanılan yöntemlerdir. Sosyal bir yapıda bireyler arasındaki sıralama hiyerarşisinin belirlenmesi, yiyecekler arasında tercih sıralamasının belirlenmesi gibi. Jensen ve arkadaşları konuyla ilgili çalışmalarında model kullanmayan üç ve model bazlı üç algoritma kullanırlar ve model bazlı yaklaşımların belirli bir dereceye kadar sorunu ‘çözebildiğini’ söylerler. Gerçek tahmin yapmak için kullanılmasalar bile, bu modeller hayvan deneylerinde gerçek deneyler ve modele dayalı simülasyon deneylerinin birlikte kullanılmasını sağlayabilirler. Böylece gerçek fiziksel deneylerin para ve zaman olarak maliyetleri çok daha etkin bir şekilde kullanılabilir. Şöyle bir senaryoyu düşünebiliriz: Fiziksel öncül deneyler gerçekleştirilir. Bu deneylerin sonuçlarını da dikkate alarak eğitilen makine öğrenmesi modelleri üzerinden yüksek sayıda sanal deney çok hızlı ve düşük maliyetle gerçekleştirilir. Sanal deneylerin sonuçlarına göre ikinci dalga fiziksel deneyler seçilerek gerçekleştirilir. Ve bu yeni fiziksel deneylerin sonuçlarıyla makine öğrenmesi modelleri iyileştirilir. Yeni dalga sanal deneyler daha iyi öğrenmiş bu modellerle gerçekleştirilir. İhtiyaç duyulduğu kadar fiziksel ve sanal deney çevrimleri tekrarlanabilir. Böylelikle başarımları çok yüksek olmayan modeller bile fiziksel deneylerle birlikte kullanılarak büyük parasal ve zamansal tasarruflar sağlayabilir, bilimsel çalışmaların hızını ve etkisini artırabilirler. (Jensen ve ark., 2019)

Yamazaki ve arkadaşlarının (2019) çalışması, aralarında bütünlük ve bağlantı kurulması zor alanların makine öğrenmesi sayesinde birleştirilmesinin ilginç bir öyküsüdür. Şekil 19’da görüldüğü gibi sadece hayvanların izlerinden yola çıkılarak ve gerekli veri hazırlık aşamaları ve makine öğrenme yöntemleri kullanılarak bu hareketlerin kökenindeki nörobilimsel ve genetik olgularla karşılaştırılabilir ve anlamlandırılabilir örüntüler belirlenebilmektedir. Bu tür çalışmalar makine öğrenmesi gibi ileri teknikleri kullanmadan da yapılabilen ancak sadece karmaşıklığı daha düşük hayvanlar için mümkün olmaktadır. Yamazaki ve arkadaşları, daha önce çalışması yapılmış bu tür hayvanlara ilişkin karşılaştırmalarla makine öğrenmesinde gerçekleştirdikleri modelin doğrulamasını da gerçekleştirmektedirler. Ve bu doğrulanan makine öğrenmesi yaklaşımı; geleneksel yöntemleri kullanarak incelenmesi ve yorumlanması zor olan daha karmaşık davranışlı hayvanların izlerini de yorumlayabilme imkanı getirmektedir. (Yamazaki ve ark., 2019)

Bu çalışma, geçmişte iz sürücülerin sadece izden yola çıkarak çok geniş bir çıkarımlar bütününe nasıl ulaşılabildiklerine dair de çağrışımlar yapmaktadır. İzin kendisi ve onu ortaya çıkaran davranışlar arasında bütüncül, karmaşık ve yoğun bir ilişki vardır. Makine ya da insan yeterince deneyimle bu ilişkilere ilişkin bilgileri biriktirdiğinde ve bu bilgilerden bir anlam süzecek bir yoğunluğa eriştiğinde, sadece hayvanların izlerinden bile derin anlamlara ulaşmak, çıkarımlar yapabilmek, tahminler yapıp uygulayabilmek mümkün olmaktadır. Makine öğrenmesinin insan öğrenmesinden farkı, istatistik modeline erişimimiz olması, parametrelerine hakim olmamız ve çeşitli ortamlara aktarabilmemiz gibi çarpıcı yönler içermektedir. Bu tür insan uzmanlığında öncülleri bulunan durumlarda, ilgili uzman kişilerin yaptıkları tahminler de makine öğrenmesinin doğrudan konusu olabilir. Böylelikle o kişilerin yaptıkları etiketlemelerin istatistiksel arka planı model haline getirilip taşınabilir bir yapı olarak kullanılabilir.

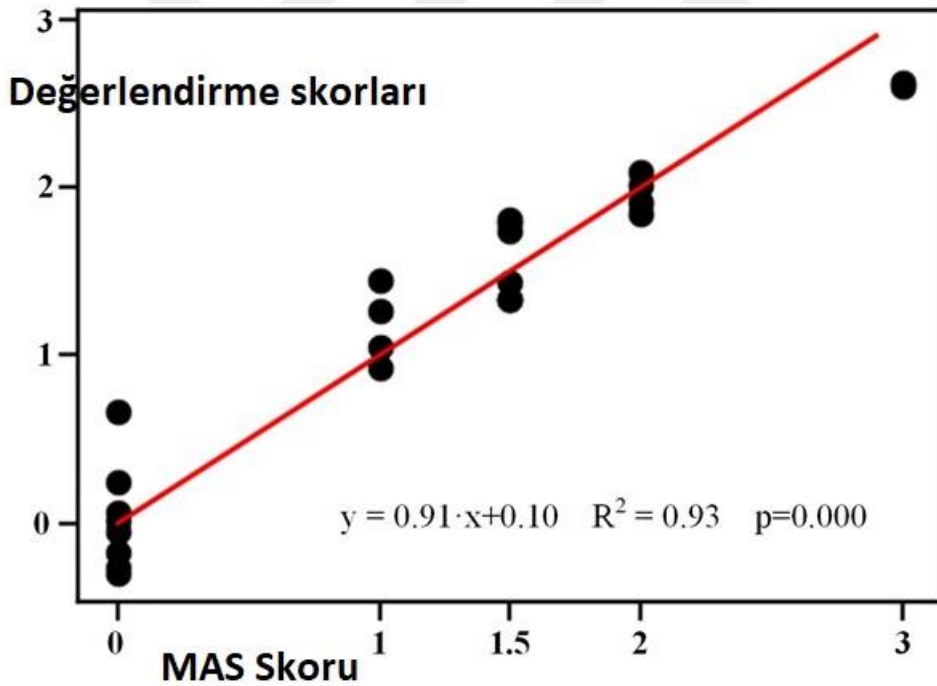


Şekil 19: Hayvan izlerinden makine öğrenmesi hazırlık ve uygulama aşamaları (Yamazaki ve ark., 2019)

Zhang ve arkadaşları (2019) kas spazitesi ölçümlerini regresyon yoluyla ele alırlar. sEMG sonuçları ve atalet durumu verilerini kullanarak yaptıkları çalışmada kas spazitesi ile ilgili klasik ölçüm yöntemlerine karşılaştırma yaparak daha etkin ve faydalı bir makine öğrenmesi yöntemi geliştirmeyi hedeflerler. Böyle bir yöntem düşük maliyetli bir ekipmanla hastanın ya da yakınlarının kendi ölçümlerini etkin bir şekilde yapabilmelerini sağlama potansiyeli taşır. Profesyonel bir insanın yardımı ya da profesyonel bir ortama ulaşma zorunluluğu ortadan kalkabilecektir. Kas spazitesi yaşam kalitesine yüksek derecede etki eden bir rahatsızlık olduğu için makine öğrenmesinin getirdiği ek yaklaşımların fayda potansiyeli yüksektir.

Çalışmada (Zhang, 2019) iki ayrı model ve bu modelleri birlikte kullanan üçüncü bir yaklaşım denenmiştir. Şekil 20’de çoklu modelin gösterdiği yüksek başarımlar görülebilir. İki modelin başarılı olduğu alt gruplar farklı olduğu için birlikte kullanımları daha geniş bir perspektifte başarı sağlayarak genel skorları da yüksek seviyelere çekmiştir. Bu tür bulgular, makine öğrenmesi sayesinde insan algısını zorlayabilecek çoklu ve karmaşık modellerin gösterebildiği başarıyı örneklemektedir. Çoklu modelin başarısının olası bir temeli, kas spastisitesinde nörojenik sebeplerin ve mekanik bileşenlerin birlikte etki etmesi olarak görülebilir. Alt modellerin biri bir tür sebebi, öbürü de diğer tür sebebi yakalamakta daha etkin olabilir.

Geliştirilen modelin daha fazla örnekle teyit edilmesi ve daha da iyileştirilip yaygın kullanıma alınmasının, kas spastisitesi olan hastaların kişisel olarak özelleştirilmiş tedaviler uygulanıp takip edilerek daha başarılı bir şekilde tedavi edilmelerinde yararlı olabileceği görülmektedir. (Zhang, 2019)



Şekil 20: Çoklu makine öğrenmesi modelinin MAS skoruna yaklaşma performansı (Zhang ve ark., 2019)

Nörobilimin gelişiminde en önemli etkenlerden başlıcaları, canlı beyinle ilgili gözlem yapabilmemizi sağlayan teknolojiler ve bunların giderek daha hassas hale gelen çıkarımları olmuştur. Ancak herhangi bir çalışma alanında etkin olan nöronların sayısı

milyonlarla ifade edilebilirken, bunlarla ilgili yapabildiğimiz ölçümler daha çok genelleme, özetleme niteliğindedir. Bu yüzden sadece ölçümleri yapmak değil, giderek büyük veri kıvamında hem mekansal çözünürlük hem de zamansal aralık olarak devasa boyutlara gelebilen bu verileri anlamlandıracak yöntemler kullanmak da son derece kritiktir. Makine öğrenmesi yöntemleri kullanılmadan bu verileri anlamlı hale getirebilmek pek olası değildir. Ancak çok belirgin bağlantıları normal insan incelemesi ile değerlendirmek mümkün olur. Oysa sadece en belirgin bağlantıları değil, yapının içinde saklı olan örüntüleri yakalayarak çok daha fazlasını elde etmek mümkün olabilir. Beyin taramalarını daha derin anlamlandırmaya yönelik bu tür sayısal çalışmalar nörobilimde makine öğrenmesi kullanımının hızla artacağı alanlardandır. Mohebian ve arkadaşlarının (2019) çalışması bu tür yaklaşımlara bir örnek olarak verilebilir.

Bu tür çalışmaların çığır açıcı etkileri olabilir. Çünkü temelde bir gözlem yapıp ondan sonuç çıkarmak değil, yüklü miktardaki sinyali daha iyi çözümleme ile ilgili yaklaşımlar geliştirmek üzerinedir bu çalışmalar. (Mohebian, 2019) Mevcut tarama yöntemlerinden daha zengin çıkarımlar ortaya koyabilecek her çalışma, kendisi ardından yapılabilecek binlerce yeni çalışma anlamına gelmektedir. Beynin çalışma mekanizmasını daha iyi kavramamız ve dijital dünya ile etkileşim gibi konularda bu çalışma mekanizmaları ile entegre yapılar kurabilmemiz, makine insan ara yüzünde devrim niteliğinde sonuçlar doğurabilir. Ve makine insan ara yüzü konusundaki gelişmeler, bu tür çalışmaların kullanılacağı alanlardan sadece biridir.

Sıradaki örneğimiz bu tür nöron aktivitelerinin incelemelerinin sağlayabileceği faydaları işaret eder. Xing ve arkadaşlarının çalışmasında (2019) insan dışı primatlar üzerinde motor korteksle ilgili dinamik sistem görünümünün makine öğrenmesi yoluyla incelenmesi ile yürüyüş, yokuş tırmanma ve kasıtlı uzanma gibi hareketlere ilişkin örüntülerin yakalanmasına odaklanılır. Makine öğrenmesinin imkanlarının nöron aktivitesi ile sonuçları arasındaki bağlamda kullanılmasının yaygınlaşması, önümüzdeki yıllarda pek çok bilimsel çalışmaya ve bunların sonucu olarak da yeni teknolojik kullanım alanlarına yol açacak gibi görünmektedir.

Nörolojik bir rahatsızlığın peşindeyseniz, mücadele etmek, iyileştirmek ya da yavaşlatmak için beyinde neler olup bittiğini iyi takip edebilmek ve sonraki aşamalarla ilgili tahmin üretebilmek çok önemli olacaktır. Bu tür rahatsızlıkların en önemlilerinden birisi Alzheimer'dır. Ömür beklentilerinin de artmasıyla Alzheimer, yaygınlığı (Pena, 2019) ve oluşturduğu etkilerle en önemli nörolojik rahatsızlıklardan birisi konumundadır.

Pena ve arkadaşlarının (2019) konuya yaklaşımı, insan emeğinin ve zamanla öğrenilmiş yöntemlerinin kalıplarından çıkıp derin öğrenmenin imkanlarını kullanmaktır. Böylece hem insan algısının kısıtlarını açmak mümkün olacak, hem de belki de düşünülmemiş yeni bağlantıların ortaya çıkmasını sağlayacak şekilde, belirli bölgelerin değil de tüm beynin hastalık boyunca izlediği seyir derin öğrenme tarafından girdi olarak ele alınabilecektir.

Makine öğrenmesinin çok daha gelişmiş bir hali olan derin öğrenmede, etkili olan bileşenleri belirlemekle ilgili ön çalışmalar da insan eliyle yapılmak yerine gelişmiş derin öğrenme yapılarına bırakılır. Böylece yanlı bakışla göz ardı edilebilecek bağlantıların da yüksek işlem gücü ve derin öğrenmenin kuşatıcı yaklaşımları ile yakalanması imkanı oluşur.

Derin öğrenmenin bu şekilde kullanılması bilimsel çalışmalarda yaygın olarak kullanılan hipotez belirleme ve test etme aşamalarını da yeniden düşünmemizi gerektirebilir. Bu çalışmada görüldüğü gibi hipotezler kurularak oluşturulmuş belirli kalıplar yerine daha genel olarak konunun derin öğrenme ile, veri bilimi ile ele alınması daha iyi sonuçlar verebilmektedir. (Pena ve ark., 2019)

4.2. İş dünyasında makine öğrenmesi kullanımı

Makine öğrenmesinin nörobilim alanında potansiyel kullanımlarını düşünmek için önemli bir öncül inceleme iş dünyasında makine öğrenmesinin kullanımının ve yaygınlığının nasıl geliştiğine bakmak olabilir.

Mesela bir süpermarket zincirinin bebek bekleyen müşterilerinin kimler olduğunu başarıyla tahmin edebilmesi, konunun iş dünyasında ne kadar yaygın bir kullanıma sahip olduğunu gösterir. (Siegel, 2016; s:74) Böyle bir tahmini nasıl yapabilmektedir? Öncelikle etiketleme verisi olarak kullanabileceği müşteri verileri bulunmaktadır. Gönüllü olarak bebek kayıt defteri kaydı oluşturan müşteriler bebek beklemediklerini, hatta hangi tarihte beklemediklerini belirtmiş oluyorlardı. Üyelik kayıtları üzerinden diğer müşteri bilgilerine ve sadakat kartı üzerinden alışveriş bilgilerine de sahip olunca, kestirim yapmak için gerekli bileşenler tamamlanmış oldu. Siegel (2016; s:74) geliştirilen bu model sayesinde ilgili marketler zincirinin hamilelikle ilgili ürünleri tanıtacağı müşteri kitlesini %30 artırdığını belirtmektedir.

Makine öğrenmesi ile ilgili geçmişte belirli bir zaman aralığına ilişkin girdi verilerine ve bu aralığın sonucundaki çıktı verisine sahipseniz, pek çok probleme çözüm getirme şansınız bulunur. Bebek bekleyen kadınları tahmin edebileceğiniz gibi, belirli bir süre sonra kimlerin istifa edeceğini iyi bir kalitede tahmin etme şansınız bulunmaktadır. (Siegel, 2016, s:87,88)

İş dünyasında bu tahminlerin yapılabilmesini sağlayan, işin giderek dijitalleşmesi ile birlikte, verilerin zaten işlemlerin kendileri sırasında, işlemler dijital ortamda gerçekleştiği için otomatik olarak veri halinde kaydedilmesidir. Bu veriler süren bir yapıya ilişkin rastgele az sayıda örnekten alınmış değildir; aksine işlerin tamamı zaten veri olarak işlenmekte ve ayrıca bir veri giriş süreci değil işin kendisinin veri olarak yürütülmesi söz konusu olmaktadır.

Makine öğrenmesinin iş dünyasında en erken ve hızlı yayıldığı alanlardan birisi bankacılıktır. Kredi riski değerlendirme alanında makine öğrenmesinin erken dönemlerinden itibaren çok öncü uygulamalar yapan bankalar olmuştur. Makine öğrenmesi modelleri otomasyon çalışmalarıyla birlikte yapay zeka olarak davranır ve kredileri mikro seviyede sürekli kontrol altında tutabilir. İnsan eliyle yapılamayacak kadar dinamik bir şekilde yeniden öğrenerek sürekli bir takip mekanizması işletme imkanı olur böylece. Sadece kredi riski değil, var olan müşterilerin hangilerinin belirli bir süre sonra kaybedileceğinin tahminlenmesi de bankaların önemli çalışmalarından olagelmıştır. (Siegel, 2016; s:167-204)

Bankacılık ve telekom gibi çok sayıda müşterinin özlük ve işlem bilgilerine sahip olan sektörlerde makine öğrenmesi büyük atılımlar gerçekleştirmiştir. Bu iki sektörde, yasal sebeplerle müşterilerin pek çok bilgilerini beyan etmeleri gerekmektedir. Yine bu iki sektörde yapılan tüm işlemler otomatik olarak veri yapıları üzerinde gerçekleştirilmekte ve kayıtları doğrudan işlemler sırasında oluşmaktadır. Her iki sektörde oluşan büyük karlar ve bu karlarda müşteri davranışını uygun yönetmenin önemi de makine öğrenmesinin bu iki sektörde gelişimini zorunlu kılmıştır.

Sonraki önemli atılımlardan bazıları dijitalleşmenin getirdiği yeniliklerle olmuştur. Netflix'in önerilerini daha da akıllı hale getirmeye yönelik açtığı 1 milyon dolarlık makine öğrenmesi yarışması bunun örneği olarak görülebilir. Öncelikle daha önce müşterilerin film ve dizi izleme alışkanlıklarına ilişkin veriler kısıtlıyken, dijital ortamda izlemenin getirdiği yenilikler, müşteri verisinin çok daha detaylı olarak elde edilebilmesini sağlamıştır. Böylece yayın izleme deneyimi de bankacılık ve telekom müşteri işlemleri gibi, tamamen çevrimiçi ortamda oluşan ve verilerinin sistemde

oluştugu bir hale gelmiştir. Netflix'in yarışmayı da online ortamda yapması, dünya çapında pek çok takımın zorlu hedef için çabaya girişmesini sağlamıştır. Yarışma sürecinde takımların başarı sınırlarından uzak kalması zamanla çok ilginç bir gelişmeye sebep olmuş ve takımlar işbirliği yapmaya, modellerini etkileşime sokmaya başlamışlardır. Bu yarışma, modellerin birlikte kullanımı ile kestirim güçlerinin artırılması yaklaşımını yaygın kullanıma sokmuştur. Derin öğrenmeye doğru giden önemli bir aşama olarak görülebilir. Ve daha iyi öneri sistemlerinin muhteşem etkisi: İzlediğiniz daha ilk birkaç yayındaki davranışınızla sistem hızla size gerçekten hoşlanacağınız yüzlerce yayın önermeye başlayabilir. (Siegel, 2016; s:205-224)

Makine öğrenmesindeki gelişmeler dar alanda tanımlı problemler konusunda yapay zeka uygulamalarını da yeni üstün seviyelere getirmiştir. Bu dar alan satranç gibi, jeopardy gibi, go gibi, insan egemenliğinin doğal görüldüğü alanlarda bile makinelerin daha üstün konuma gelmesini yaşamıştır. Jeopardy gibi tamamen metin tabanlı akıl kullanılan ve insanların gündelik kültürlerinin çok geniş alanlarında dolaşan bir yarışmada bile, büyük yatırımlar ve artan işlem güçleri, dijital ortamda birikip öğrenilen verilerin inanılmaz hacmiyle, makine öğrenmesi insana galip gelmiştir. Sonraki yıllarda derin öğrenmenin hedefleyeceği yeni zirvelerin bir başka habercisi olarak değerlendirilebilir bu gelişmeler. (Siegel, 2016; s:225-265)

Siegel'in (2016, s:305-307) makine öğrenmesi ile yakın dönemde yapılacağını düşündüğü bazı çalışmaları şöyle özetleyebiliriz:

- Arabanın, binen kişinin hırsız mı yetkili mi olduğunu anlaması
- Müzik sistemlerinin kendiliğinden seveceğimiz şarkılar seçmesi
- Navigasyon sisteminin otomatik yol önermesi ve aracın hızı gibi unsurları kontrol altında tutup müdahale etmesi
- Yolculuk esnasında mola ve yemek gibi önerilerin akıllı yapılması
- Sosyal medya uygulamalarının akıllı asistanlar haline gelmesi
- Müşterinin ihtiyacını akıllı algılayarak oluşturulan usta işi satış önerileri
- Araç kullanırken tamamen sesli iletişimle çok karmaşık işler için bile yönlenen ve yönlendiren akıllı dijital asistan
 - Sürücünün dikkatini gözeten ve akıllı uyarılar yapan araç
 - Akıllı çarpışma ve kaza riski önleyicileri
 - Aracınızın akıllı bakımı
 - Akıllı ve kişiye özel kredi kullandırma

- Akıllı ve kişiye özel sigorta
- Akıllı güvenlik sistemleri
- Akıllı yollar
- Akıllı sürücü kötü davranış takip ve yasaklama sistemleri
- Akıllı dijital hekim asistan

Siegel'in makine öğrenmesini anlatırken kullandığı kestirimsel analitik uygulamalarını özetlemek, iş dünyasındaki kullanımlar konusunda bize ışık tutacaktır: (Siegel, 2016; s: 310-314)

- Doğrudan pazarlama hedefleri
- Kestirimsel reklam hedefi belirleme
- Kara kutu alım-satım sistemi
- Kestirim metoduyla hamileliğin belirlenmesi
- Çalışan devrini azaltmak
- Suç işlenecek yerlerin belirlenmesi
- Sahtekarlık girişimlerinin tespiti
- İletişim ağına yetkisiz girişlerin tespiti
- Çöp e-postaların filtrelenmesi
- Masa oyunları
- Suçluların tekrar suç işleme ihtimali
- Şüphelilerin otomatik tespiti
- Blog yazılarında endişe duygusunun tespiti
- Müşteri kaybı konusunda model oluşturularak müşterileri elde tutmak

- Konut kredisi değer tahmini
- Film tavsiyeleri
- Açık soru cevaplama
- Öğrenme hedeflerinin başarılması sürecinde yol göstericilik
- Yayık modeli kullanılarak müşterilerin elde tutulması
- Tepki yükseltme modeliyle doğrudan hedefe özel pazarlama
- Yayık yükseltme modeliyle müşterilerin elde tutulması
- Seçmenlere yönelik siyasi kampanyaların yürütülmesi

Siegel'in (2016; s: 327-348) kestirimsel analitiğin uygulandığı alanlardan 182 tanesini ele aldığı listenin hangi alanlara ve bunların altında hangi konulara yayılmış olduğunu görmek bir hayli ufuk açıcı:

- Aile ve özel hayat
 - o Lokasyon tahmini (Nerede olacaksınız? Nereye gideceksiniz?)
 - o Fotoğrafta kim var? (Yüz tanıma)
 - o Hangi Facebook gönderisini beğeneceksiniz? (Haber akışı optimizasyonu için)
 - o Rezervasyon talebinin kabulü
 - o Arkadaşlık
 - o Aşk
 - o Hamilelik
 - o Sadakatsizlik
 - o Boşanma
 - o Ölüm
- Pazarlama, reklam ve web
 - o Satın almalar (hedef kitleyi daha iyi belirlemek – tepki modelleme)
 - o İptaller (müşterileri elde tutmak – yayık modelleme)
 - o Başarılı satışlar (satış tekliflerinin önceliklendirilmesi için)
 - o Ürün tercihleri (kişiye özel tavsiyeler için)
 - o Fare tıklamaları (gösterilecek içeriğin seçimi için)
 - o Etkisiz reklamlar (reklam verenlerin uyarılması için)
 - o Viral tweetler ve mesajlar (olabildiğince fazla kişiye ulaşmak için)
 - o Çöp epostaların filtrelenmesi
 - o Hit şarkılar, çok tutulan filmler
- Finansal riskler ve sigorta
 - o Araç kazalarında yaşanan yaralanmalar
 - o Yüksek maliyet yaratan işyeri kazaları
 - o Sigorta tazminat talepleri
 - o Ölüm
 - o Konut kredileri erken ödemeleri
 - o Ödenemeyen borçlar (risk)
 - o Ödenmeyen borçlar
 - o Hisse senedi borsası (kara kutu alım-satım için)

- Uçak bilet fiyatları
- Belli bir fiyattan konaklama rezervasyonu (dinamik fiyatlandırma için)

- Gişe yapacak filmler

- Sağlık

- Ölüm
- Ameliyathane enfeksiyonları
- Grip
- Meme kanseri
- Kan zehirlenmesi
- HIV
- İlaçların etkileri
- Prematüre doğum
- Ereksiyon bozukluğu
- Hastaneye yatışlar
- İlaçları yanlış kullanma
- Klinik test kobayları
- Faturalama hataları
- Çeşitli sağlık riskleri

- Suçla mücadele ve sahtekarlık tespiti

- Sahtekarlık
 - Vergi gelirleri
 - Kamu kurumu faturaları
 - Kamu ihaleleri
 - İşçi tazminatları
 - Medicaid ödemeleri
 - Medicare ödemeleri
 - Araç sigortası tazminat talepleri
 - Garanti talepleri
 - Çekler
- Cinayet
- Toplumsal huzursuzluk
- Sokaklarda işlenen suçlar
- Terör saldırıları

- Şehir düzenlemelerine riayet
- Tekrar suç işleme
 - Mahkumiyete karar vermek için
 - Rehabilitasyon görevlendirmeleri yapabilmek için
- Katilin yakalanması
- Güvenlik düzeyi
- Hacker ve virüsler
- Hata tespiti, güvenlik ve lojistik verimlilik
 - Sistem arızası (sorunları proaktif olarak önlemek için)
 - Uydular / nükleer reaktörler
 - Elektrik dağıtımı
 - Rögarlar
 - Tren rayları
 - Tren tekerlekleri
 - Ofis ekipmanları
 - Kredi kartı ödeme sistemleri
 - Binalar
 - Şirket iletişim ağları
 - Arızalı parçaların saptanması (montaj hattı kalite kontrolü için)
 - Petrol akış hızları (Yeraltındaki petrol yataklarının belirlenmesi için)
 - Petrol rafinerisi güvenlik olayları
 - Deniz kazaları
 - Kargo taşımacılığı (teslimat yapılacak adresleri için)
 - Taksi (yolcunun gideceği yer)
 - Müşteri ihtiyaçları (hizmetlerin daha kaliteli sunulması için)
 - Uçak kazasında ölenler
 - Uçak tehirleri
 - Trafik
 - Kesilen telefon görüşmeleri
 - Yangın ve kurşun zehirlenmeleri
 - Sürücü dikkatsizliği

- Devlet, siyaset, STK'lar ve eğitim
 - o Seçmenleri ikna etmek
 - o Bağışlar
 - o Fon dağıtımı
 - o Restoranlarda sağlık kurallarının ihlali
 - o Boya kaynaklı kurşun zehirlenmesi
 - o Yangın
 - o Enerji tüketimi
 - o Aşırı yüksek gayrimenkul kiralari
 - o Başvuru onay ve retleri
 - o Destek ihtiyacı
 - o Okuldan atılmalar
 - o Notlar
 - Bilgisayarın otomatik not verebilmesi için
 - Akademik yardımın hedefli yürütülebilmesi için
 - o Bilgi (kişiselleştirilmiş eğitim için)
- İnsan dilini anlama, düşünce, psikoloji
 - o Soruların yanıtlanması
 - o Yalanlar
 - o Hakaretler
 - o Uygunsuz yorumlar
 - o Kinaye
 - o Memnuniyetsizlik
 - o Sürücü dikkatsizliği
 - o Psikopatlık
 - o Şizofreni
 - o Güzellik
 - o Beyin faaliyetleri (görülen şeyin hareketli bir görüntüsünü oluşturmak için)
 - o Düşünceler
- İşgücü, insan kaynakları
 - o İşten ayrılma
 - o Personelin işte kalma süresi
 - o İş performansı

- ABD Özel Kuvvetler eğitimleri
- Petrol rafinerilerindeki güvenlik olayları
- Beceriler
- İş başvuruları

4.3. Derin öğrenme kullanım alanları

İş dünyasında makine öğrenmesi kullanım alanlarından bahsederken anlattıklarımız, aktardıklarımız ve örnekler neredeyse tamamıyla derin öğrenme öncesi makine öğrenmesi yöntemleriyle yapılan ya da yapılabilecek çalışmalar. Oysa derin öğrenme bir hayli gelişti ve normal makine öğrenmesi başarımlarının ötesinde uygulama alanları buluyor.

Derin öğrenmenin makine öğrenmesine göre nasıl bir fark oluşturduğunu örnekleri üzerinden daha net göreceğiz, ancak bu üstünlüğün temellerini anlayabilmek için aralarındaki farkların teorisi üzerinde durmak yararlı olacaktır. Derin öğrenmeyi çok katmanlı makine öğrenmesi olarak düşünebiliriz. Çok katmanlı yapısı, bu çoklu katman yapısını kullanan daha gelişmiş ve özel makine öğrenmesi yaklaşımlarına izin vermesi ve üzerinde çalışabileceği GPU'lu makineler ya da bulut sistemlerinin kullanılabilmesi sayesinde derin öğrenme çok daha karmaşık problemleri çözümlenmede kullanılabilir. Klasik makine öğrenmesine göre önemli bir farkı ise, etkili olabilecek girdilerin insan eliyle belirlenmesine gerek olmadan ham girdilerle sonuç arasındaki bağlantıları kurabilmesi yetkinliğidir. Derin öğrenme de makine öğrenmesidir, ancak makine öğrenmesinin çok gelişmiş bir halidir. (Sütçü ve AYTEKİN, 2018; s:175-180) Şekil 21 bu yapıların ilişkilerini göstermektedir.

Konu ile ilgili çalışmaların seyri çok ilgi çekicidir. Konuyla ilgili uzmanlar öncelikle yapay zekayı hayal etmiş ve insan zekasını dış ortamda oluşturmak hedefiyle çalışmalar yapmışlardır. Bu alandaki çalışmaların dönüp dolaşıp makine öğrenmesine bağlandığını görmüştük. (Nilsson, 2018) Bilgisayar görmesinden metinde anlam aramaya kadar yapay zeka bağlamında üzerinde durulan konuların hemen hepsinin yolu makine öğrenmesine çıkmıştır. Zeka pırıltıları görülen her konu, arka planında öğrenme gerektirmiştir. Makine öğrenmesi alanındaki çalışmaların boyut atlamasını sağlayansa derin öğrenme alanındaki gelişmeler olmuştur. İnsanın alt edilemeyeceği düşünülen zihinsel çalışma alanlarında makine öğrenmesinin ancak derin öğrenme yaklaşımları ile

büyük başarımlar elde edebildiği görülmektedir. 2016 yılında Go oyununda makinenin insan şampiyonu yenmeyi başarması, sonra da daha yenilikçi bir yapay zekanın, insanların oynadığı oyunlardan öğrenmek yerine tamamen kendi kendine oyunlar oynayıp sonuçlarından öğrenmesi yoluyla ilk yapay zekayı yenmeyi başarması, derin öğrenmenin ne kadar geniş ufuklara sahip olduğunu göstermektedir. Derin öğrenmenin yaygın kullanılmaya başlamasının ne kadar yeni olduğu düşünülecek olursa, ortaya koyabileceği başarımların çok daha geniş alanlara ve derinliklere yayılabileceğini öngörmek mümkündür.



Şekil 21: Derin öğrenmenin bağlantılı alanlarla ilişkisi (Sütçü ve Aytekin, 2018; s:176)

Klasik makine öğrenmesi yetkinliklerinin iş dünyasında ne kadar geniş kullanımları olduğunu görmüştük. Derin öğrenme ile birlikte, makine öğrenmesi bilim dünyasında da çok daha yaygın olarak kullanılmaya başlamıştır. Nörobilimde makine öğrenmesi kullanımı örnekleri üzerinde de durmuştuk. Şimdi yaşam bilimleri alanında derin öğrenme tarzı makine öğrenmesi kullanım alanları üzerinde biraz duralım.

İlginç çalışma alanlarından birisi moleküllerdir. Moleküller özellikle yaşam bilimleri alanında önemli etkilere sahip bir çalışma alanıdır. Ve genel olarak deneysel çalışmalar gerektirirler. Bu çalışmaların aldıkları süreler ve maliyetleri, yapılmak istenen çalışmaları kısıtlayıcı etkilere sahip olabilmektedir. Oysa moleküllerin tespit edilmesi daha kolay pek çok özelliklerini girdi olarak alıp belirli özelliklere sahip olup

olmadıklarını inceleyen derin öğrenme modelleri kurgulanabilir. Binlerce molekülün yüzlerce bildiğimiz özelliği olduğunu düşünelim. Bu moleküllerle ilgili incelemek istediğimiz belirli bir ek özellik olsun. Bu özelliği moleküllerin tamamı için test etmek yerine mesela beşte birinde test edip bu test sonuçlarından öğrenen bir derin öğrenme modeli tasarlanabilir. Bu modeli kullanarak kalan beşte dördün bu özelliğinin nasıl gerçekleşeceği tahminlenebilir. Böylece sonraki deneyler el yordamıyla yapılmak yerine, istediğimiz özelliği sağlama potansiyeli daha yüksek olan molekülleri hedefleyen deneyler yapılabilir. (Ramsundar ve ark., 2019; s: 41-57)

Bu tür derin öğrenme yaklaşımları moleküler biyolojiden genetiğe kadar çeşitli yaşam bilimlerinde kullanılmaktadır. Özellikle genetik alanı çok yoğun veri işleme yapıları üzerinden yürümektedir ve bu verilerdeki bağlantıların sadece çok belirgin olanları makine öğrenmesi gibi yaklaşımlar kullanılmadan incelenebilir durumdadır. Genetik ilişkiler çoğunlukla derin öğrenme yaklaşımları gerektirecek kadar yüksek karmaşıklıktadır. (Ramsundar ve ark., 2019; s:59-99)

Görüntü işlemeye yönelik yüksek başarımlara sahip olan derin öğrenme alanının yaşam bilimlerinde özellikle etkin olarak kullanılmaları düşünülebilecek bir alan ise mikroskobik görüntülerdir. (Ramsundar ve ark., 2019; s: 101-127)

Yaşam bilimlerinde derin öğrenmenin kullanımının en kritik olduğu alt alanlardan biri de tıp olarak belirtilebilir. Teşhiste derin öğrenmenin sağlayabileceği destekler, sağlık verilerinin biriktirilmesi ve bunlardaki trendler ve gizli bağlantıların keşfedilmesine yönelik çalışmalar, radyoloji görüntülerinin derin öğrenmeyle incelenmesi, tedavilerin belirlenmesi ve uygulanmasında etkinlik takibi gibi pek çok konuda derin öğrenmeden yararlanmak mümkündür. (Ramsundar ve ark., 2019; s: 129-149)

Derin öğrenmede sonuç elde ettiğiniz halde bağlantıların sebebini açıklayamamak yani aslında bağlantıyı keşfettiğiniz halde sebebini anlayamamak sık karşılaşılabilen bir durumdur. Bilimsel çıkarımlar yaparken üzerinde çokça kafa yorulması gereken yönlerden birisi bu olabilir. Bu konuda yenilikçi çalışmalar yapılmaktadır. (Ramsundar ve ark., 2019; s: 165-177)

Geleceğe doğru baktığımızda makine öğrenmesinin sıklıkla kullanılacağı bir alan olarak teşhisi görmek mümkün. Hızla gelişen ve kolaylaşan görüntüleme teknolojileri ile, hastalıkları teşhis etmek için artık eskisine göre çok daha fazla ve hızla artan verilere sahibiz. Tekil olarak bu verilerin anlamı olmakla birlikte, çok sayıda hastaya ilişkin verilerin birikmesi ve bu kişilerin takip eden dönemde hastalıklarıyla ilgili

durumlarının kesinleşmesi, etiketlenmiş büyük veri anlamına gelir. İnsanın altından kalkmakta zorlanacağı bu veri, makine öğrenmesinin ve derin öğrenmenin tam da aradığı şeydir. Bu gelişmelerin sağlanabilmesi için, kişiye özel verilerin güvenliğinin sağlanması ve paylaşılmamaları konusu ile veriden elde edilecek genel kazanımların herkese sağlayacağı fayda arasında bir dengenin yolunu bulmak gerekecektir. (Ramsundar ve ark., 2019; s: 203-204)

Kişiye özel reçete, makine öğrenmesiyle ve derin öğrenmeyle sağlanabilecek bir başka gelişme gibi duruyor. Kişiye ait verilerin birikmesi, bu tür verilerle ilaç kullanımı arasındaki eşleşmelerin makine tarafından öğrenilmesi, hatta belki bazı kullanımların sanal olarak simüle edilip olası sonuçlarının araştırılması gibi yöntemlerle, genel geçer reçeteler yerine kişiye, genetiğine, yaşam şartlarına, biyolojik durumuna uygun ve dinamik olarak değişen ilaç kullanımı çok daha faydalı sonuçlar verebilir. Yeni ilaçların geliştirilmesi sürecinde de makine öğrenmesi ve derin öğrenmenin kullanılması, süreçleri kısaltıp maliyetleri düşürebilir. Hatta piyasada zaten kullanılmakta olan çeşitli ilaçların amaçlandıkları alandan farklı alanlarda faydalarının ya da zararlarının tespiti gibi konularda da bu teknolojiler çok etkili olabilir. (Ramsunder ve ark., 2019; s:205-207)

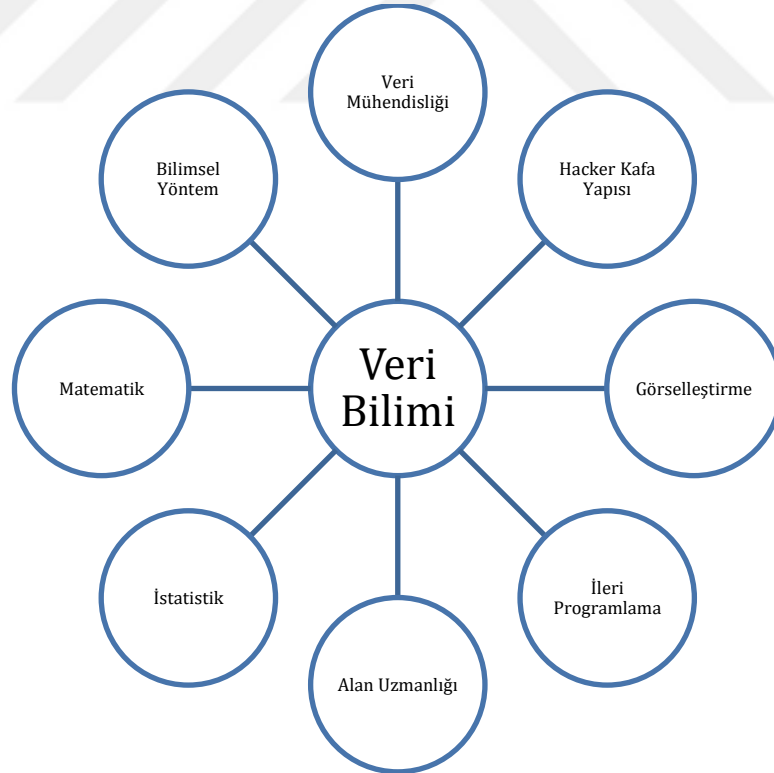
4.4. Veri bilimi (Data Science)

Tüm bu bulgularla birlikte bilim yapma şeklimiz nasıl değişiyor olgusunu da dikkate almak gerekli.

Geleneksel bilimsel metodu incelediğimizde, gözlemlerin önemini görürüz. Gözlem, bilimsel yöntemin temelidir. Mevcut teori ile gözlemlerin birbirini etkilediğini unutmamak gerekir. Çünkü gözlem yapabilmek için de belirli bir bilimsel bakışın var olması gerekir ve bu bakış gözlemi de etkiler. Gözlemlerden çıkarımlar yapılarak hipotezler kurulur. Bu aşamada bilimsel bilginin ilerlemesi için hipotezler yanlışlanabilecekleri deneyler tasarlanarak test edilirler. Kesin doğrulanma söz konusu değildir, ancak bir hipotez her doğrulandığında biraz daha güçlenir; ta ki kesin bir şekilde yanlışlanabildiği bir deney kurgulanıp gerçekleşene kadar. (Kosso, 2011; s: 7-20)

Makine öğrenmesi, derin öğrenme derken, veri alanındaki gelişmeler artık veri bilimi diye bir başlık altında toplanıyor. Şekil 22’de gördüğümüz gibi veri biliminin pek çok alanla ilişkisi var. Temelinde matematik ve istatistik olduğu kesin. Ama bu matematik ve istatistik, geleneksel yöntemlerin yanı sıra en yeni imkanların da eklenmesiyle veri

bilimine temel oluyor: Makine öğrenmesi, derin öğrenme, büyük veri analitiği gibi. Çalışılan alanla ilgili uzmanlıklar yine önemli bir tabanını oluşturuyor veri biliminin; hangi alanda çalışılıyorsa... Öte yandan yazılım ve veri görselleştirme matematik ve istatistik tabanlı veri bilimini çok ileri noktalara taşıyabiliyor. Yazılım sayesinde veri bilimi yaklaşımları otomasyonla ve yoğun entegrasyonla tanışıyor. Görselleştirme sayesinde veri biliminin karmaşık temellerine dayalı sonuçlar çok daha anlaşılır bir şekilde insanlara sunulabiliyor. Hacker kafa yapısının yaratıcılığı veri mühendisliğinin azimli çabasıyla veri bilimini destekliyor. Bizim için ilginç olan bir başka nokta ise şu: Veri bilimi bilimsel yöntemden yararlandığı gibi, veri bilimi sayesinde bilimsel yöntem de değişimlere uğruyor. Kosso'nun özetlediği şekilde bilimsel yaklaşımın temelinde, yapılması bir hayli zor olan gözlemler ve yoğun insan emeğiyle, yaratıcılığıyla ortaya konan hipotezleri test etmek için kısıtlı miktarda veri üzerinde odaklanan deneyler yatıyordu. Oysa veri bilimi tüm çevresel faktörleriyle birlikte bu yaklaşımlardaki kısıtları darmadağın ediyor. Derin öğrenmenin bilim için yoğun bir şekilde kullanıldığı örnekleri inceleyerek, geleneksel bilimsel yaklaşımlara göre önemli farklılıklar olduğunu gözlemleyebiliriz.



Şekil 22: Veri bilimi ve diğer alanlarla ilişkisi (Sütçü ve Aytekin, 2018; 85

Bu farkların en belirginleri şunlardır:

- Gözlemler artık kısıtlı değil, aksine başa çıkamayacağımız kadar çok ve yoğun gözlem verisi oluşuyor. Veri toplama araçlarının teknolojik gelişim hızı gözlem verisi zenginliğinin daha da artacağına işaret ediyor.

- Bu kadar yoğun gözlem verisinden hipotezler kurmak için artık insan zihniyle düşünmek yeterli değil. Büyük miktardaki verilerin içindeki olası bağlantıları araştırmak için derin öğrenmeyi kullanmak, hipotez kurgulamak için harcanacak yüzlerce insan senesini yüzlerce derin öğrenme günü çalışmasının üzerine yüzlerce insan zihni çalışmasıyla değiştirecek gibi duruyor.

- Kısıtlı miktarda denek üzerinden yapılan hipotez testleri yerine, derin öğrenmenin ardından kurgulanan hipotezleri ve çok daha karmaşık modelleri yine büyük veri ile test etmek de gayet olası görünen seçeneklerden.

Makine öğrenmesinin ve özellikle derin öğrenme seviyesine gelmiş makine öğrenmesinin, veri biliminin genel araç setiyle ve ilişkileriyle birleşerek, bilimsel yaklaşımda çok önemli yeni açılımlar getiriyor olduğu şimdiden görülmektedir.

5. TARTIŞMA

5.1. Nörobilimde makine öğrenmesi ve veri biliminin olası kullanım alanları

Şu ana kadarki bulgularımızdan yola çıkarak makine öğrenmesi ve derin öğrenmenin nörobilim alanında yaygınlığının giderek artacağını rahatlıkla öngörebiliriz.

Olası bazı kullanım alanlarını düşünecek olursak:

- Beynin yapısı, işleyişi ve ortaya koyduğu işlev arasındaki karmaşık ilişkilerin daha iyi kavranması için görüntüleme tekniklerinin giderek daha ince sonuçlar elde edebilmesi derin öğrenmeyle birleşerek çığır açıcı sonuçlara sebep olabilir. Çeşitli davranışların, hastalıkların gerçek temellerine derin öğrenme sayesinde yaklaşma şansımız artacaktır.

- Beyin ve sinir sistemi kaynaklı hastalıkların gelişim süreçlerinin anlaşılması, hastalıkların seyrinin önceden tahmin edilebilmesi, kullanılan tedavi yöntemlerinin etkilerinin incelenmesi ve geleceğe yönelik etkilerinin daha iyi tahminlenmesiyle kişiye özel iyileştirmeler yapılması gibi konular önemli çalışma alanları arasında görülebilir.

- Beyin ile dış ortam arasındaki bağlantı ara yüzleri yani insan makine ara yüzleri üzerine çok yenilikçi gelişmeleri derin öğrenme sağlayabilir. Burada özellikle takma organlarla ilişkiler, kişinin beyniyle doğrudan bağlantılı olarak kullanılacak “ek organlar” gibi konularda ilginç gelişmeler olabilir.

- Koruyucu bakım amaçlı olarak derin öğrenmenin kullanılmasıyla beyin sağlığı ve gelişimiyle ilgili öncül uyarıların oluşması ve ur gibi problemlerin oluşumlarının çok erken aşamalarında yakalanması mümkün olabilir.

- Sosyal olarak kabul görmeyen çeşitli davranış kalıplarına ilişkin invazif olmayan yöntemlerle ve kişinin henüz ileri aşamalara gelmeden kendi onayıyla yapılabilecek küçük müdahalelerle zihinsel sağlık kontrol altında tutulabilir.

- Kaotik ve periyodik olmayan epilepsi nöbetleri veya kardiyak fibrilasyon (kalp krizi) gibi durumların kestirimi ve önceden haber verebilecek izleme uygulamalarının kurgulanması

Yukarıda saydığımız alanların her biri umut verici olmakla birlikte, kullanım şekillerinin insan haklarına ve atipik davranış çeşitliliğine olası zararları da etik açılarından her zaman akılda tutulup sorgulanmalıdır.

5.2. Sonuç

Nörobilimde ele alınan konu, dünyada şu ana kadar karşılaştığımız en karmaşık mekanizma olan insan beynidir. İnsan beyni, yoğun bir veri işleme sürecine sahip olan, inanılmaz karmaşıklıkta ve anlamakta güçlük çektiğimiz mükemmel bir sistemdir. Bir yandan beyin görüntüleme sistemlerindeki hızlı teknolojik gelişmelerle elde ettiğimiz çok daha detaylı veriler ve bir yandan da bu veriler üzerinden makine öğrenmesi ve derin öğrenmeyle yapılabilecek çıkarımlar, nörobilim alanındaki gelişmelerin önümüzdeki yıllarda hızla artacağını ve yeni zirvelere ulaşacağını hissettirmektedir.

6. SONUÇ ve ÖNERİLER

6.1. Sonuç ve Öneriler

Nörobilimde makine öğrenmesi ve geleceği üzerine araştırma yaptığımız bu çalışmada, işe insanın öğrenme süreciyle başladık. Nörobilimle paralel dönemlerde önemli atılımlar gerçekleştiren yapay zeka da tam olarak bu konu üzerinde durmuştur. Gerek insanın gerek hayvanların öğrenme şekilleri üzerine olan dış gözlemlerle, gerekse beynin iç mekanizmasında nöronların çalışma mekanizmalarının incelenmesiyle yapay zekada makine öğrenmesi alanı büyük bir gelişme göstermiştir. Yapay zekadaki hedeflenen alanların hemen hepsinde makine öğrenmesi çok önemli bir temel olmuştur. Özellikle yakın dönemdeki gelişmelerle makine öğrenmesinin derin öğrenme kıvamına gelmesi, çok daha büyük verilerden çok daha karmaşık örüntüleri yakalamasını mümkün kılmıştır. Derin öğrenmenin girdilerle ilgili yoğun insan çalışmasına gerek bırakmadan etiketlenmiş ham veriden yola çıkarak elde ettiği başarımlar, kullanımının giderek yaygınlaşmasını sağlamıştır.

Bu bağlamda, nörobilimin neredeyse her alanında çalışmaların makine öğrenmesi ve derin öğrenme ile desteklenmesi kritik önemde gözükmektedir. Makine öğrenmesi ve derin öğrenme tekniklerinin artık sadece sayısal analizde uzmanlaşan sınırlı sayıda bilim insanı tarafından değil, neredeyse tüm bilim insanları tarafından kullanılmaları mümkün görülmektedir.

6.2. Sonuç

Nörobilimin yeni büyük atılımları büyük veri ve derin öğrenme ile gerçekleşmektedir. Bu konuya daha fazla nörobilim uzmanının ilgisinin çekilmesi ile, çığır açıcı çalışmaların sayısının hızla artmasını ummaktayız.

KAYNAKLAR

- Acungil, M. (2018). 24 Soruda Dijital Dönüşüm. İstanbul: Tuti Kitap.
- Alpaydın, E. (2013). Yapay Öğrenme. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Atkinson, R.L., Smith, E.E., Nolen-Hoeksema, S., Fredrickson, B., Bem, D.J., ve Maren, S. (2015). Psikolojiye Giriş (14. Edisyon, 3. Baskı; Ö. Öncül & D. Ferhatoglu, Çev.). Ankara.
- Carter, R., Aldridge, S., Page, M. Ve Parker, S. (2013), Beyin Kitabı, (1. Baskı), Alfa, İstanbul.
- Daikoku T (2019). Tonality Tunes the Statistical Characteristics in Music: Computational Approaches on Statistical Learning. *Frontiers in Computational Neuroscience*, 13, 70. <https://doi.org/10.3389/fncom.2019.00070>
- Domingos, P. (2015). Master Algoritma: Yapay Öğrenme Hayatımızı Nasıl Değiştirecek? (1. Baskı; T. Göbekçin, Çev.). İstanbul: Paloma Yayınevi.
- Elmas, Ç. (2011). Yapay Zeka Uygulamaları: Yapay Sinir Ağı, Bulanık Mantık, Genetik Algoritma (4. Baskı). Ankara: Seçkin Yayınevi.
- Ergüzel T.T., Noyan C.O., Eryılmaz G, Ünsalver B.Ö., Cebi M, Tas C, Tarhan N (2019). Binomial Logistic Regression and Artificial Neural Network Methods to Classify Opioid-Dependent Subjects and Control Group Using Quantitative EEG Power Measures. *Clinical EEG and Neuroscience*, 50(5), 303-310. <https://doi.org/10.1177/1550059418824450>
- Jensen G, Terrace H.S., Ferrera V.P. (2019). Discovering Implied Serial Order Through Model-Free and Model-Based Learning. *Frontiers in Neuroscience*, 13, 878. <https://doi.org/10.3389/fnins.2019.00878>
- Kandel, E.R. (2016). Belleğin Peşinde: Yeni Bir Zihin Biliminin Doğuşu (1. Baskı). İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Kosso, P. (2011). A Summary of Scientific Method (1. Baskı): Springer.
- Mohebian M.R., Marateb H.R., Karimimehr S, Mañanas M.A., Kranjec J, Holobar A (2019). Non-invasive Decoding of the Motoneurons: A Guided Source Separation Method Based on Convolution Kernel Compensation With Clustered Initial Points. *Frontiers in Computational Neuroscience*, 13, 14. <https://doi.org/10.3389/fncom.2019.00014>
- Nabiyev, V.V. (2016). Yapay Zeka: Problemler, yöntemler, algoritmalar (5. Baskı). Ankara: Seçkin Yayıncılık.
- Nilsson, N.J. (2018). Yapay Zeka Geçmişi ve Geleceği (1. Baskı). İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Öztemel, E. (2006). Yapay Sinir Ağları (2. Baskı). İstanbul: Papatya Yayıncılık.
- Pena D, Barman A, Suescun J, Jiang X, Schiess Mc, Giancardo L, The Alzheimer's Disease Neuroimaging Initiative (2019). Quantifying Neurodegenerative Progression With DeepSymNet, an End-to-End Data-Driven Approach. *Frontiers in Neuroscience*, 13, 1053. <https://doi.org/10.3389/fnins.2019.01053>
- Provost, F. Ve Fawcett, T. (2013). Data Science for Business: What you need to know about data mining and data-analytic thinking (1. ed., 2. release). Beijing: O'Reilly.

- Ramsundar, B., Eastman, P., Walters, P. Ve Pande, V. (2019). Deep Learning for the Life Sciences: Applying Deep Learning to Genomics, Microscopy, Drug Discovery and More (First edition). Sebastopol, CA: O'Reilly Media.
- Salvador R, Canales-Rodríguez E, Guerrero-Pedraza A, Sarró S, Tordesillas-Gutiérrez D, Maristany T, Pomarol-Clotet E (2019). Multimodal Integration of Brain Images for MRI-Based Diagnosis in Schizophrenia. *Frontiers in Neuroscience*, *13*, 1203. <https://doi.org/10.3389/fnins.2019.01203>
- Savage N (2019). How AI and neuroscience drive each other forwards. *Nature*, *571*(7766), S15-S17. <https://doi.org/10.1038/d41586-019-02212-4>
- Say, C. (2018). 50 Soruda Yapay Zeka (5. Baskı). İstanbul: 7 Renk Basım Yayım ve Filmcilik.
- Siegel, E. (2016). Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die (Revised and Updated Edition). Hoboken: Wiley.
- Siegel, E. (2016). Büyük Veri ve Gelecek: Nasıl Yaşayacak, Çalışacak ve Düşüneceğiz. (Türkçe baskı) Optimist Yayın Grubu.
- Solouki S, Bahrami F, Janahmadi M (2019). The Concept of Transmission Coefficient Among Different Cerebellar Layers: A Computational Tool for Analyzing Motor Learning. *Frontiers in Neural Circuits*, *13*, 54. <https://doi.org/10.3389/fncir.2019.00054>
- Sütçü, C.S., Aytekin, Ç. (2018). Veri Bilimi (1. baskı). İstanbul.
- Xing D, Aghagolzadeh M, Truccolo W, Borton D (2019). Low-Dimensional Motor Cortex Dynamics Preserve Kinematics Information During Unconstrained Locomotion in Nonhuman Primates. *Frontiers in Neuroscience*, *13*, 1046. <https://doi.org/10.3389/fnins.2019.01046>
- Yamazaki Sj, Ohara K, Ito K, Kokubun N, Kitanishi T, Takaichi D, Kimura K.D. (2019). Stefr: A Hybrid Versatile Method for State Estimation and Feature Extraction From the Trajectory of Animal Behavior. *Frontiers in Neuroscience*, *13*, 626. <https://doi.org/10.3389/fnins.2019.00626>
- Zhang X, Tang X, Zhu X, Gao X, Chen X, Chen X (2019). A Regression-Based Framework for Quantitative Assessment of Muscle Spasticity Using Combined EMG and Inertial Data From Wearable Sensors. *Frontiers in Neuroscience*, *13*, 398. <https://doi.org/10.3389/fnins.2019.00398>