

## Endüstri 4.0 Kapsamında Büyük Veri ve Yapay Zekânın Muhasebe Süreçlerine Etkisi

Anıl Eralp<sup>1</sup>

### Özet

Endüstri 4.0, dijital teknolojilerin endüstriyel süreçlere entegrasyonunu ifade eden sanayi devrimlerinin dördüncü aşamasıdır ve yapay zekâ, büyük veri, nesnelerin interneti gibi yeniliklerle öne çıkmaktadır. Bu teknolojiler, muhasebe uygulamalarında da önemli dönüşümlere yol açmıştır. Tarihsel olarak manuel işlemlere dayalı olan muhasebe süreçleri, dijitalleşme ile otomasyon ve veri analitiği gibi yeniliklere adapte olmaktadır. Yapay zekâ ve büyük veri, muhasebede karar destek sistemlerinin geliştirilmesine, finansal risklerin tahmin edilmesine ve mali tabloların daha şeffaf raporlanmasına imkân tanımaktadır. Ayrıca, otomasyon sayesinde insan kaynaklı hatalar azalırken, çalışanların stratejik görevlere odaklanması sağlanmaktadır. Bununla birlikte, veri gizliliği, etik sorunlar ve yasal uyumluluk gibi yeni zorluklar da ortaya çıkmaktadır. Bu çalışma, Endüstri 4.0 kapsamında büyük veri ve yapay zekâ teknolojilerinin muhasebe uygulamalarına etkilerini literatür taraması yoluyla incelemeyi amaçlamaktadır. Sonuç olarak, Endüstri 4.0'ın sunduğu yenilikler, muhasebe süreçlerini sadece otomasyonla sınırlı kalmayıp, stratejik karar alma ve risk yönetiminde çok boyutlu gelişmeleri desteklemektedir. Bu teknolojilerin gelecekte finansal sistemleri daha entegre, şeffaf ve şirketlerin rekabet avantajlarını arttıracığı düşünülmektedir.

### 1. Giriş

Endüstri 4.0, sanayi devrimlerinin dördüncü aşamasını temsil etmekte ve dijital teknolojilerin endüstriyel süreçlere entegrasyonunu ifade etmektedir. Bu devrim; yapay zekâ, büyük veri, nesnelerin interneti ve robotik sistemler gibi yeniliklerle öne çıkmaktadır. Bu teknolojiler, sadece üretim ve lojistik alanlarında değil, aynı zamanda finansal sistemler ve muhasebe alanlarında da büyük etkiler yaratmıştır.

1 Doç. Dr., Bolu Abant İzzet Baysal Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü, anil.eralp@ibu.edu.tr, ORCID: 0000-0002-4630-2114

Muhasebe süreçleri, tarihsel olarak belge kayıtları ve elle hesaplama üzerine kurulu iken; dijitalleşme ile otomasyon ve veri analitiği gibi yeniliklere adapte olmaktadır. Bu kapsamda yapay zekâ ve büyük veri, muhasebe süreçlerinde karar destek sistemlerinin geliştirilmesine, finansal risklerin tahmin edilmesine ve mali tabloların daha şeffaf bir şekilde raporlanmasına olanak tanımaktadır.

Endüstri 4.0'ın merkezinde yer alan yapay zekâ algoritmaları, muhasebe uygulamalarının çok yönlülüğünü artırmakta ve finansal verilerin daha iyi analiz edilmesine katkı sağlamaktadır. Örneğin, gerçek zamanlı veri analitiği ile finansal işlemler daha hızlı izlenebilmekte ve çözüm yolları daha etkili bir şekilde tasarlanabilmektedir. Bunun yanı sıra, muhasebe yazılımlarının otomasyonu, insan kaynaklı hataların azaltılmasına ve çalışanların daha stratejik görevlere odaklanmasına olanak tanımaktadır. Bununla birlikte bu teknolojiler, sadece faydalarla sınırlı kalmamış, veri gizliliği, etik sorunlar ve yasal uyumluluk gibi yeni zorlukları da beraberinde getirmiştir.

Bu çalışmada, Endüstri 4.0 kapsamında büyük veri bulut teknolojilerinin muhasebe uygulamaları üzerindeki etkileri ile yapay zekânın bu alandaki rolü, literatür taraması çerçevesinde detaylı bir şekilde incelenerek değerlendirilmesi amaçlanmıştır. Çalışma, dijital dönüşümün muhasebe süreçlerine sağladığı yenilikleri, büyük veri ve yapay zekâ entegrasyonunun getirdiği fırsatlar ve olası zorluklar bağlamında ele almayı hedeflemektedir.

## 2. Endüstri 4.0

Endüstriyel üretim süreçlerindeki önemli dönüşümler “Endüstri Devrimleri” olarak ifade edilmektedir. Endüstri devrimleri, endüstriyel üretim süreçlerindeki önemli dönüşümleri ifade eden dört büyük aşamalı gelişmeyi tanımlar. Bu devrimler teknolojik, ekonomik ve toplumsal değişimlere yol açmıştır. Bu çerçevede buhar makinesinin icadı ile başlayan endüstri devrimlerinden ilkinde insanoglu kas gücüne dayalı üretim yerine makine gücü ile üretime geçerek, kitlesel üretim yapabilmeye başlamıştır. Bu devrim Endüstri ya da Sanayi Devrimi olarak adlandırılmış ve ilk endüstriyel devrim olduğu için Endüstri 1.0 olarak adlandırılabilir.

Elektriğin bulunması, buhar gücüyle çalışan makinelerin elektrik gücü ile çalışan makinelere dönüşmesini sağlamıştır. Bu gelişme, makinelerin daha verimli enerji dönüşümüne olanak tanımış ve daha kolay kontrol edilmesini sağlamıştır. Ayrıca, üretim süreçlerinde çevreye verilen zararın azaltılmasına katkıda bulunmuştur. Bunun yanında içten yanmalı motorların ortaya çıkması ve montaj hattı teknolojisi gelişmeleri de dönüşümün bir parçası olmuştur.

Bu deęişim ve bunun sanayiye yansıması, yeni bir endüstri devrimine neden olmuştur, bu devrim Endüstri 2.0 olarak adlandırılmıştır (Stearns, 2013: 32).

Üçüncü endüstri devrimi, bilgisayar teknolojisinin ve otomasyonun hızlı yükselişini içermektedir. Bu dönemde bilgisayarlar ve dijital teknolojiler, üretimde yaygın olarak kullanılmaya başlamıştır. Böylece üretimde daha fazla otomasyon için elektronik bilgisayarların ve dijital teknolojilerin kullanımı, üretim ve iletişim süreçlerinde devrim yaşanmasına neden olmuştur. Bu devrim aynı zamanda mikroelektronik, telekomünikasyon ve bilişim teknolojilerindeki ilerlemeleri beraberinde getirmiş olup, bilgi ve iletişim teknolojilerinin geniş bir şekilde kullanılmasını sağlamıştır (Türkel ve Yeşilkuş, 2020: 334). Ayrıca, bu teknolojilerin endüstriyel süreçlere entegre edilmesinde bilgisayarlar, internet ve diğer dijital teknolojiler yaygın olarak kullanılmıştır. Bu dönemde yapay zekânın temelleri atılmış, dijitalleşme süreçleri derinlik kazanmıştır. Bilgi işleme ve karar verme süreçlerinde otomasyonun yanında yapay zekânın sağladığı öngörü yeteneđi, daha verimli üretim sistemlerinin kurulmasına olanak tanımıştır. Muhasebe sistemleri de bu dönemde dijitalleşmenin etkisiyle dönüşüme uğramış, elektronik tablolar ve muhasebe yazılımları finansal süreçlerin etkinliğini artırmıştır (Yıldız ve Tonga, 2022: 45).

Endüstri 4.0, yapay zekâ, üç boyutlu yazıcılar, robotik, biyoteknoloji, nano ve uzay teknolojilerindeki yaşanan gelişmelerin yanında akıllı üretim sistemlerinin ortaya çıkmasını sağlamıştır. Bu endüstri devrimi dijitalleşme, yapay zekâ, nesnelerin interneti ve büyük verinin entegrasyonunu içermektedir. Endüstriyel süreçleri daha akıllı ve bağlantılı hale getirerek üretimde daha büyük esneklik ve verimlilik sağlamaktadır (Yıldız, 2017: 550).

Özellikle yapay zekâ algoritmaları ve büyük veri analitiđi sayesinde gerçek zamanlı karar alma mekanizmaları geliştirilmiş, operasyonel süreçlerde verimlilik artışı sağlanmıştır. Muhasebe uygulamaları açısından Endüstri 4.0, finansal süreçlerin otomasyonunu, denetim süreçlerinde yapay zekâ algoritmalarının kullanılmasını ve büyük veri analitiđi sayesinde stratejik finansal kararların alınmasını sağlamaktadır. Yapay zekâ destekli muhasebe yazılımları tahminleme ve risk analizi gibi konularda insan hatasını minimize ederek, şirketlerin daha sürdürülebilir bir mali yapı oluşturmalarına katkıda bulunmaktadır.

### 3. Büyük Veri

Büyük Veri, geleneksel veri işleme araçları kullanılarak verimli bir şekilde yönetilemeyen, işlenemeyen ya da analiz edilemeyen son derece büyük

veri kümelerini ifade etmektedir. Büyük veri temel olarak yapılandırılmış (structured), yarı-yapılandırılmış (semi-structured) ve yapılandırılmamış (unstructured) veriler içermektedir. Yapılandırılmış veriler modellenmesi, girilmesi, depolanması, sorgulanması, işlenmesi ve görselleştirilmesi kolay olan verilere kapsamaktadır. Yarı yapılandırılmış veri, yapılandırılmış verinin bir türü olmakla beraber tam olarak yapılandırılmış veri kategorisine uymayan, ancak belirli bir düzen ve hiyerarşi barındıran bir veri türüdür. Yarı yapılandırılmış veri, genellikle farklı veri öğelerini tanımlamak ve ilişkilendirmek için etiketler ya da işaretleyiciler içermektedir. Yapılandırılmamış veri, önceden tanımlanmış bir format olmadan sunulan ve depolanan bir kayıt türüdür. Genellikle kitaplar, makaleler, belgeler, e-postalar ve resim dosyaları, ses dosyaları ve videolar gibi medya dosyaları gibi serbest biçimli metinlerden oluşur. Bu tür verileri katı bir biçimde temsil etmenin zor olması, işlenmesini zorlaştırmaktadır (Gahi vd., 2016: 2).

İşletmelerin 1990'larla birlikte dijitalleşme sürecinde verilerini dijitalleştirilmesi ve ilerleyen yıllarda gerçekleşen bilgi işleme gücü ile veri depolama kapasitelerindeki gelişmeler büyük veri kavramını ortaya çıkarmıştır. İlk olarak büyük veri kavramı Cox ve Ellsworth (1997) tarafından ortaya atılmış, hatta veri hacminden dolayı bilgisayar donanımlarının kapasite yetersizliği büyük veri problemi olarak adlandırılmıştır (Aktan, 2018: 3).

Büyük veri hacim (volume), hız (velocity), çeşitlilik (variety), doğruluk (veracity) ve değer (value) özelliklerine göre değerlendirilmektedir. Hacim, büyük verinin devasa miktarını ifade etmektedir. Burada veri miktarı exabyte'lar ile ölçülmektedir. Dolayısıyla bu veri hacmini işlemek, arşivlemek ve saklamak için organizasyonlar gelişmiş teknolojilere ihtiyaç duymaktadırlar. Hız, verinin gerçek zamanlı olarak oluşturulma, işleme ve analiz edilme hızını ifade etmektedir. Çeşitlilik yapılandırılmış, yarı yapılandırılmış ve yapılandırılmamış formatlar dahil olmak üzere veri türlerinin farklılığını ifade etmektedir. Doğruluk, büyük veri kapsamındaki verinin kalitesini ve doğruluğunu ifade etmektedir. Değer ise büyük verinin karar vermede kullanımını (Demirtaş ve Argan, 2015: 7-8), yani ortaya çıkardığı katma değeri ifade etmektedir.

Üretilen toplam verinin büyük bir çoğunluğunun yapılandırılmamış veri olması, fiziki depolamalarının yanında bulut belleklerin kullanılmasına neden olmaktadır. Bunun yanında kullanılan bu yeni teknolojiler ile verinin hacmi ve çeşitliliği; bu verilerden anlamlı bilgi çıkarılmasında geleneksel matematiksel ve istatistiksel yöntemlerin yetersiz kalmasına neden olmaktadır. Dolayısıyla bu verilerin işlenmesinde yapay zekâ yöntemlerine başvurulmaktadır. Aynı zamanda, özellikle, derin öğrenme yöntemleri için büyük veriler bir eğitim

verisi görevi görmektedir. Bu bağlamda büyük veri ile yapay zekâ arasında bir ortak yaşam söz konusudur.

Büyük veri, günümüzde tüm sektörlerde üretilmektedir. Bu sektörden biri de muhasebe ve finans alanı olup, işletmelerin finansal kararlarından bireylerin yatırım kararlarına kadar oldukça geniş bir kapsamda finansal tablolar ve finansal raporlar kullanılmaktadır. Bu mali bilginin hacmindeki artışla işleme zorlukları dijitalleşen muhasebe işlemleriyle beraber yapay zekâ yöntemlerinin kullanımının önemini gün geçtikçe arttırmaktadır. Bu bağlamda Warren vd. (2015), büyük verinin muhasebe bilgi kalitesini artırarak şeffaflığı ve paydaşların karar alma süreçlerini geliştireceğini ifade etmektedir. Ayrıca, büyük veri teknolojilerinin, bilanço kalemlerinin gerçeğe uygun değerlemesi konusunda küresel çözümler sunabileceği belirtilmektedir. Krahel ve Titera (2015) ise büyük verinin muhasebe ve finansal raporlama standartlarında değişikliklere yol açacağını savunmaktadır. Büyük veri sayesinde, standartların yalnızca sunuma odaklanmak yerine, veri analitiğine önem vererek bilgi kullanıcılarına daha fazla fayda sağlaması beklenmektedir (Kablan, 2018: 1565).

#### 4. Yapay Zekâ ve Yapay Zekâ Yöntemleri

Yapay zekâ, insan zekasını taklit ederek öğrenme, problem çözme, karar verme ve dil işleme gibi bilişsel süreçleri gerçekleştirebilen sistemlerin geliştirilmesini amaçlayan bir teknolojidir. Tarihsel olarak insan düşüncesini ve davranışlarını anlamaya yönelik felsefi ve bilimsel çabalarla şekillenen yapay zekâ, günümüzde veri analitiği, otomasyon ve tahmin sistemleri gibi çok çeşitli alanlarda kullanılmaktadır. Yapay zekâ yöntemleri, makine öğrenimi, derin öğrenme, doğal dil işleme, uzman sistemler ve bulanık mantık gibi farklı yaklaşımları içermekte ve bu yöntemler, farklı problemlerin çözümünde özelleştirilmiş çözümler sunmaktadır. Bu çeşitlilik, yapay zekâyı birçok disiplin için vazgeçilmez bir araç haline getirmektedir. Bu alt başlıkta bu konular ele alınmıştır.

##### 4.1. Yapay Zekâ

Yapay zekâ (artificial intelligence), insan zekasını taklit eden sistemler ya da makineler anlamına gelen kapsamlı bir terimdir (Oracle, 2024). Bununla beraber yapay zekâ kavramının tanımı literatürdeki gelişmelere paralel olarak değişim göstermekle birlikte yapay zekâ, bir bilgisayarın ya da bilgisayar kontrollü robotun, genellikle akıllı varlıklarla ilişkili görevleri yerine getirme yeteneği olarak tanımlanabilir. Bu bağlamda yapay zekâ; akıl yürütme, anlam keşfetme, genelleme ya da geçmiş deneyimlerden öğrenme gibi insanlara özgü entelektüel süreçlerle donatılmış sistemler geliştirmek amacıyla

kullanılmaktadır (DDO, 2024). Bu çerçevede yapay zekâ, bilgisayarların düşünme, öğrenme, anlama, problem çözme ve karar verme gibi zekasal görevleri gerçekleştirebilmesini sağlamayı amaçlamaktadır.

Yapay zekâ, kökenleri 17. yüzyıla kadar uzanan ve günümüzde birçok disiplinin merkezinde yer alan bir teknolojidir. 17. yüzyılda Descartes, insan davranışlarını mekanik sistemlere benzetmiş ve bu dönemde insan davranışlarını taklit eden otomatlar geliştirilmiştir. Daha sonra Charles Babbage, zihinsel süreçleri taklit etmeye odaklanarak hafızaya sahip ilk hesap makinesi olan “Fark Motoru”nu geliştirmiştir. Bu çalışma, modern yapay zekâ araştırmalarının temellerini atmıştır. Modern yapay zekanın yükselişi, İkinci Dünya Savaşı sırasında Alan Turing’in geliştirdiği kod kırma cihazı “Bombe” ile başlamıştır. Turing, 1950’de yayımladığı “Hesaplama Makineleri ve Zekâ” adlı makalesinde, “Makineler düşünebilir mi?” sorusunu tartışmış ve makine zekâsı kavramını Turing Testi ile somutlaştırmıştır. Yapay zekâ terimi ise 1956’da John McCarthy tarafından Dartmouth Konferansı’nda ilk kez kullanılmıştır. Bu konferans, Marvin Minsky, Claude Shannon gibi önemli isimlerin katkılarıyla yapay zekanın bir araştırma alanı olarak doğuşunu simgelemiştir. 1960’lar ve 70’ler, Logic Theorist (1955), General Problem Solver (1957), Aziz ve Eliza gibi programların geliştirilmesiyle sembolik yapay zekanın ön planda olduğu bir dönemdir. 1972’de Japonya’da insana benzeyen ilk akıllı robot WABOT-I üretilmiştir. Ancak 1974-1980 yılları arasında yapay zekâ alanındaki beklentilerin karşılanamaması ve fon kesintileri, “Yapay Zeka Kışı” olarak adlandırılan bir duraklama dönemine yol açmıştır. 1980’lerde uzman sistemler ve sinir ağlarındaki ilerlemelerle alan yeniden canlanmış, geri yayılım algoritması gibi tekniklerle yapay zekaya olan ilgi artmıştır. 1997’de IBM’in Deep Blue adlı programının dünya satranç şampiyonu Garry Kasparov’u yenmesi, yapay zekanın potansiyelini gözler önüne sermiştir (Coşkun ve Gülleroğlu, 2021: 948-950). 2000’li yıllar, derin öğrenme ve GPU teknolojilerindeki ilerlemelerin yapay zekâ araştırmalarını hızlandırdığı bir dönemi ifade etmektedir. Bu gelişmeler, insan zekasına benzer şekilde çok yönlü görevlerde öğrenme ve problem çözme kapasitesine sahip genel yapay zekâ sistemlerinin yaratılabileceği fikrini güçlendirmiştir.

Günümüzde yapay zekâ; hesaplama gücündeki artışlar, büyük verinin kullanılabilirliği ve derin öğrenme gibi alanlardaki atılımlar sayesinde otonom sistemler, doğal dil işleme ve bilgisayarlı görme gibi teknolojilerin temelini oluşturmaktadır. Yapay zekanın gelişimi, insan bilişini taklit etme ve geniş bir yelpazede dönüştürücü çözümler sunma potansiyelini her geçen gün artırmaktadır.

## 4.2. Yapay Zekâ Yöntemleri

Yapay zekanın tarihsel gelişim süreci dikkate alınarak yapay zekâ yöntemleri; makine öğrenmesi ve bunun alt dalı olarak derin öğrenme, yapay sinir ağları, uzman sistemler, bulanık mantık ve doğal dil işleme gibi başlıklar bu alt başlık altında incelenmiştir. Ayrıca, veri madenciliği, doğrudan bir yapay zekâ yöntemi olmamakla birlikte, yapay zekâ tekniklerinden faydalanarak büyük veri setlerinden anlamlı bilgiler çıkarır ve karar alma süreçlerine önemli katkılar sağlamasından dolayı burada ele alınmıştır.

### 4.2.1. Yapay Sinir Ağları

Yapay sinir ağları (Artificial Neural Networks), öğrenme ve öğrenilen bilgiyi saklama açısından insan beynine benzemektedir. Yapay sinir ağları, insan beynin bu özellikleri dikkate alınarak öğrenme sürecinin matematiksel olarak modellenmesidir (Ersoy ve Karal, 2012: 188). Yapay sinir ağları, biyolojik sinir sisteminin çalışma şekli temel alınarak, nöronların birbirlerine çeşitli şekillerde bağlanmaları gibi değişik ağırlıklar ile birbirlerine bağlı işlem elemanlarından oluşmakta (Taşar vd., 2018: 545; Ersoy ve Karal, 2012: 192) olup; ağların bilgiyi öğrenmesi, depolaması ve veriler arasındaki ilişkiyi ortaya çıkarması amaçlanmaktadır (Ersoy ve Karal, 2012: 192). Bu sistemler; öğrenme, hatırlama ve genelleme yeteneklerine sahip olmaları nedeniyle tıp, adli tıp, kalite kontrol, işletme, finans, üretim planlama, kalite kontrolü, hile ve dolandırıcılık tespiti gibi pek çok konuda ve alanda uygulanmaktadır (Keskenler ve Keskenler, 2017: 11). Yapay sinir ağları, veriler arasındaki karmaşık ilişkileri modelleyerek çıktı tahminleri yapma ve öğrenilen bilgiyi saklama yeteneğiyle dikkat çekmektedir.

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiş etkili bir yapay zekâ teknolojisidir. 1943 yılında McCulloch ve Pitts tarafından geliştirilen ilk matematiksel sinir ağı modeli, yapay zekâ alanındaki ilk çalışmadır. Bu model, biyolojik sinir sisteminin hesaplama yeteneklerini modellemek amacıyla ortaya çıkarılmıştır. 1957'de Frank Rosenblatt'ın "perceptron" modelini geliştirmesiyle yapay sinir ağı alanı büyük bir ivme kazanmıştır (Keskenler ve Keskenler, 2017: 11-12). 1980'lerden itibaren bilgi teknolojilerindeki gelişmeler, yapay sinir ağlarının daha karmaşık problemleri çözebilmesini sağlamıştır. Bu dönemde çok katmanlı sinir ağları ve geri beslemeli öğrenme algoritmaları gibi yenilikler, yapay sinir ağlarının öğrenme kapasitesini önemli ölçülerde artırmıştır (Akin ve Şahin, 2014: 28). Bunların yanında yapay sinir ağları özellikle makine öğrenmesi ve derin öğrenme alanlarında çok önemli bir rol oynamaktadır.



Yapay sinir ağı, birbirine bağlı düğümlerden (nöronlardan) oluşan bir hesaplama çerçevesidir. Bu düğümler, biyolojik nöronların davranışını taklit ederek giriş sinyallerini işler ve çıktıyı sonraki katmanlara iletmektedir. Bağlantıların (ağırlıkların) gücü, performansı optimize etmek için eğitim süreci sırasında ayarlanmaktadır. Bir yapay sinir ağı temel prensip olarak şu şekilde çalışmaktadır. İlk aşamada bir yapay sinir ağı rastgele ağırlıklar ve önyargılarla başlatılır. Daha sonra giriş verileri ağ üzerinden akar ve çıktılar her katmanda hesaplanır. Tahmin edilen ve gerçek değerler arasındaki fark bir kayıp fonksiyonu kullanılarak ölçülür. Hata, eğitim inişi ya da diğer optimizasyon algoritmaları kullanılarak ağırlıkları ve önyargıları ayarlamak için ağ üzerinden geriye doğru yayılır. İşlem, ağ tatmin edici bir doğruluk seviyesine ulaşana kadar birden fazla dönem boyunca tekrarlanır (Bkz. Zou vd., 2009).

Yapay sinir ağlarının avantajları olarak büyük veri kümelerinden öğrenebilmesi ve genelleme yapabilmesi; karmaşık, doğrusal olmayan ilişkileri modelleyebilmesi; çok çeşitli sorunlara ve alanlara uygulanabilmesi sayılabilir. Bununla beraber dezavantajları olarak etkili eğitim için çok miktarda etiketli veri gerektirmesi, eğitim ve dağıtım için önemli kaynaklar gerektirmesi, karar alma süreçlerinde yorumlanabilirliğinin olmaması, eğitim verilerini ezberleyebilme olasılığı nedeniyle yeni verilerde düşük performans göstermesi sayılabilir (LeCun vd., 2015: 436-439; Wu vd., 2018: 1646; Zou vd., 2009: 16-18).

#### 4.2.2. Makine Öğrenmesi

Makine öğrenmesi (Machine Learning), bilgisayarların açık bir şekilde programlanmadan, deneyim ve verilere dayalı olarak öğrenme yeteneği kazandığı bir yapay zekâ dalı olarak tanımlanmaktadır (Jordan ve Mitchell, 2015: 255). Bu disiplin istatistik, bilgi teorisi ve bilgisayar bilimleri gibi alanların kesişiminde yer almaktadır. Ayrıca, veri analitiği ile karar verme süreçleri açısından oldukça önemlidir (Dhall vd., 2020: 48). Makine öğrenmesi tıp, finans, eğitim gibi çeşitli alanlarda yaygın olarak uygulanmaktadır.

Makine öğrenmesi, öğrenme süreçlerine göre genellikle denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) şeklinde üç ana kategoriye ayrılmaktadır. Denetimli öğrenme, etiketlenmiş veri kullanarak giriş-çıkış ilişkilerini öğrenmeye dayanmaktadır. Bu tür algoritmalar; regresyon, sınıflandırma ve destek vektör makineleri gibi yöntemleri içermektedir (Mahesh, 2020: 381). Örneğin bir e-posta filtreleme sistemi, spam olan ve



olmayan e-postaları öğrenmek için bu algoritmaları kullanır. Denetimsiz öğrenme ise etiketlenmemiş veri kullanır ve veri içindeki gizli desenleri ortaya çıkarmayı amaçlamaktadır. Kümeleme ve boyut indirgeme yöntemleri bu kategoriye girmektedir (Dhall vd., 2020: 49). Pekiştirmeli öğrenme, özellikle robotik ve oyun teorisi uygulamalarında kullanılmakta olup, bir ajanın çevreyle etkileşim yoluyla ödülleri ve cezalar alarak öğrenmesine olanak sağlamaktadır (Jordan ve Mitchell, 2015: 257).

Makine öğrenmesi modelleri, büyük miktarda veri ve hesaplama gücü gerektirir. Ancak, bu altyapının maliyeti ve veri gizliliği gibi sorunlar önemli zorluklar yaratmaktadır. Ayrıca, algoritmalarındaki önyargılar, sonuçların doğruluğunu etkileyebilmekte ve etik kaygılara neden olabilmektedir (Delipetrev vd., 2020: 21).

Makine öğrenmesinin geleceği, özellikle derin öğrenme tekniklerinin yaygınlaşmasıyla, daha geniş bir uygulama alanına yayılmayı vaat etmektedir. Veri analitiği ve otomasyon süreçlerindeki ilerlemeler, bu teknolojinin birçok alanda devrim yaratmasını mümkün kılmaktadır (Jordan ve Mitchell, 2015: 258).

#### 4.2.3. Uzman Sistemler

Uzman sistemler (Expert Systems), belirli bir alandaki problemlere çözüm getirebilmek için uzman bilgisini, becerilerini ve karar alma yeteneklerini taklit eden bilgisayar yazılımlarıdır (İçen ve Günay, 2014: 38-39). İngiliz Bilgisayar Topluluğu Uzman Sistem Grubu tarafından yapılan tanıma göre ise bir uzman sistem, insanın uzmanlık becerisinden gelen bilgisinin, sistemin akıllı tavsiyelerde bulunabileceği ya da bir işleme işlevi hakkında akıllı bir karar alabileceği bir biçimde bir bilgisayarda somutlaşmış hali olarak tanımlanmaktadır (Vickry ve Brooks, 1987: 151). Uzman sistemler, bilginin sunulması ve çıkarım mekanizmalarının kombinasyonundan yararlanarak; uzman bilgisinin gerekli olduğu konulardaki ve alanlardaki karmaşık sorunlara çözüm sunmayı amaçlamaktadır (Kütük ve Zor, 2020: 194).

Matematiksel teoremleri kanıtlamak ve yeni ispatlar bulmak için Allen Newell, Herbert Simon ve Cliff Shaw tarafından 1955 ve 1956 yıllarında tasarlanan ve yazılan Logic Theorist programına dayanan General Problem Solver programı uzman sistemlerin başlangıcı olarak kabul edilmektedir (Canvar, 2002: 149; Karan, 2023). Erken dönem içerisinde kayda değer bir uzman sistem olan DENDRAL, bir kimyasal analiz uzman sistemi olarak, 1965 yılında kimyagerlere moleküler yapı belirlemede yardımcı olması için Stanford Üniversitesi'nden Edward Feigenbaum ve Joshua Lederberg

tarafından geliştirilmiştir (Copeland, 2024). 1980'lerde muhasebe ve finans gibi alanlarda uygulanmaya başlayan bu sistemler, zamanla daha karmaşık problemleri çözebilecek şekilde geliştirilmiştir (Kütük ve Zor, 2020). Bu bileşenler, sistemin karmaşık problemleri hızlı ve etkin bir şekilde çözmesine olanak tanımaktadır. Uzman sistemler özellikle veri analizi, hata tespiti ve öngörüler oluşturma gibi alanlarda yoğun olarak kullanılmaktadır (Kaya vd., 2004).

Uzman sistemler bilgi tabanı, çıkarım mekanizması ve kullanıcı arayüzü bileşenlerinden meydana gelmektedir. Bilgi tabanı; sorunun alanıyla ilgili kurallar, gerçekler ve bilgileri içerir. Çıkarım mekanizması, bilgi tabanındaki verileri kullanarak ilgili problemi çözmeye çalışır. Kullanıcı arayüzü ise kullanıcının sistemle etkileşim kurmasını sağlar (Kaya vd., 2004: 88).

Uzman sistemler bazı problem barındırmaktadır. Bunlardan biri oldukça fazla bilgi gerektirmesidir. Uzman sistemler, güvenilir ve oldukça kapsamlı bir bilgi tabanına gereksinim duyar. Bu nedenle insan uzmanlardan bilgi edinmek ve bu bilgiyi bir makinenin anlayabileceği ve yorumlayabileceği hale getirmek oldukça zaman alıcı ve zor bir süreçtir. Diğer bir problem ise gerekli olan uzman bilgiden bir çıkarımda bulunmasının programlanmasının gereksinimidir. Dolayısıyla uzman sistemlerin soruna bir çözüm üretmek için yaptıkları çıkarımları, bağımsız olarak üretebilme yetenekleri bulunmamaktadır. Bunun yerine bu işlemin önceden programlanmış kurallara göre yapılması gerekmektedir.

Uzman sistemlerin belirtilen zorluklarına rağmen; Çinli araştırmacılar üretim planlama, muhasebe ve finans, envanter ve bilgi hizmetleri alt sistemleriyle birlikte karar destek sistemlerinin doğrusal programlama tabanlı bir optimizasyon modelini kural tabanlı bir yapay zekâ modeliyle birleştirerek kârın %10'a kadar artırılabilirliğini göstermişlerdir. Dolayısıyla uzman sistemler, karar destek sistemlerinin ötesine geçmiş; yöneticilerin karar alma süreçlerinin desteklenmesinin yanında analitik ve çıkarımsal görevleri yerine getirmek için de kullanabilmektedirler (Milana ve Ashta, 2021: 194-195).

#### 4.2.4. Bulanık Mantık

Bulanık mantık (Fuzzy Logic), yapay zekâ alanında yaygın olarak kullanılan bir matematiksel yaklaşımdır. Bulanık mantık, insanların karar verme sürecinde karşılaştıkları belirsizlik ve kesin olmamayla baş etme işlemini taklit etmeyi amaçlamaktadır (Sanca vd., 2022: 131-132). Bulanık mantık

kavramı, Lotfi Asker Zadeh<sup>2</sup> tarafından 1965 yılında çığır açan “Bulanık Kümeler” adlı makalesinin bir parçası olarak ortaya atılmıştır. Zadeh’in (1965) ileri sürdüğü bulanık kümeler teorisi, belirsizliğin kaynağının rastgele değişkenlerin varlığından ziyade, sınıf üyeliğinin kesin olarak tanımlanmış ölçütlerinin olmadığı durumlar için bir çözüm sunmaktadır (Zadeh, 1965: 339). Bir başka ifadeyle bulanık mantığın, klasik mantığa göre karar verme sürecini daha iyi yansıttığını belirtmektedir. Bu nedenle finans alanındaki belirsizlik durumlarında kullanılmaktadır (Karcıoğlu vd., 2020: 361). Bulanık mantık şu anda finansal analiz yazılımları, enerji yönetim sistemlerinin kontrolü, seçim süreçlerinin doğrulanması, tıbbi cihazlar ve diğer birçok uygulama gibi çok sayıda süreçte kullanılmaktadır (Hernandez ve Hidalgo, 2020: 2525).

Bulanık küme ile bir sınıfa (küme) üyelik için net ölçütlerin bulunmadığı birçok gerçek dünya sınıflandırmasında mevcut olan belirsizlik ele anılabilir. Kesin sınırları olan geleneksel matematiksel kümelerin aksine, bulanık kümeler belirsiz durumlarına sahip nesnelere barındıran bir üyelik derecesi sürekliliğine izin vermektedir. Örneğin hayvanların sınıflandırılmasında köpekleri, atları, kuşları vb. üyeleri açık olarak hayvan sınıfı içerisindeyken; denizyıldızı, bakteri vb. gibi nesnelere bu sınıflamada belirsizlik durumundadır. Bulanık kümeler, bu tür kesin olmayan şekilde tanımlanmış sınıfları ele almak için esnek bir çerçeve sağlamaktadır. Böylece bu yaklaşım, rastgelelikten ziyade belirsiz üyelik ölçütlerinden kaynaklanan sorunları daha iyi ele almak için geleneksel küme teorisini genelleştirmektedir (Zadeh, 1965: 338-339).

Bulanık mantık matematiksel olarak şu şekilde açıklanabilir. Klasik mantıkta 0 ve 1 şeklinde iki değerli bir yapı bulunmaktadır. Bununla beraber bulanık mantıkta ise bu durum  $[0,1]$  aralığı şeklinde ele alınmaktadır. Bu durumda klasik küme teorisinde bir kümenin elemanı olup olmama durumu yerine; bulanık bir A kümesinde, U evreninde tanımlanan ve  $[0,1]$  aralığında değer alabilen ve bir üyelik fonksiyonu ile ifade edilebilen bir küme olarak tanımlanmaktadır (Sanca vd., 2022: 132). Böylece örneğin sıcaklığı “sıcak” ya da “soğuk” olarak kategorize etmek yerine, “kısmen sıcak” ve “kısmen soğuk” gibi farklı derecelerde tanımlanması olanaklı hale gelmektedir.

Bulanık mantık bulanıklaştırma, kural tabanı, çıkarım mekanizması ve durulaştırma temel bileşenlerinden meydana gelmektedir. Bulanıklaştırma, girdi değişkenlerinin bulanık küme üyelik fonksiyonlarına dönüştürülmesi işlemidir. Kural tabanı işleminde problemin çözümü için bulanık kuralların

---

2 Lütü Aliasker Zade (Sanca vd., 2022: 132).

tanımı yapılır. Çıkarım mekanizmasında girdilere dayalı olarak uygun kuralların seçilmesi ve uygulanması gerçekleştirilir. Durulaştırma işlemi ise elde edilen bulanık sonuçlar kesin değerlere dönüştürülür.

Bulanık mantığın yapay sinir ağlarına, büyük veri yöntemlerine ve yapay zekâ alanına entegrasyonu ile gelecekte işletme kararlarının daha hızlı ve daha kesin alınmasında; ayrıca işletme, yönetim ve muhasebede işlenecek veri miktarının artmasıyla nedeniyle büyük bir kullanım potansiyeli sunmaktadır (Hernandez ve Hidalgo, 2020: 2538-2539).

#### 4.2.5. Doğal Dil İşleme

Doğal dil işleme (Natural Language Processing, NLP), bilgisayar bilimi, yapay zekâ ve dilbilim arasında yer alan, bilgisayarların doğal dilleri anlama, yorumlama ve üretme yeteneğini geliştirmeyi amaçlayan bir disiplin olarak tanımlanabilir. Bu alan, insan diliyle makinelerin etkili bir şekilde etkileşim kurması için gerekli olan algoritmaları, modelleri ve sistemleri geliştirmeye odaklanmıştır. Doğal dil işleme; metin madenciliği, makine çevirisi, sesli komut sistemleri ve duygu analizi gibi pek çok uygulama alanına sahiptir (Chowdhury, 2003: 51-89; Hirschberg ve Manning, 2015: 261-266).

Doğal dil işlemenin kökenleri 1950'lerdeki makine çevirisi çalışmalarına dayanmakta olup, ilk yıllarda el ile yazılmış dilbilgisi kuralları ve sözlüklere dayalı basit modeller üzerinden gelişmiştir (Jones, 1994: 53-59).

1960'lı yıllarda Chomsky'nin dilbilim teorileri doğal dil işlemeye önemli bir yön vermiş, ancak bu teoriler yalnızca sentaks üzerine yoğunlaşmıştır (Nadkarni vd., 2011: 544). 1980'lerde ise istatistiksel yaklaşımların benimsenmesi, büyük veri setleri ve daha ileri makine öğrenme teknikleri ile desteklenmiştir (Hirschberg ve Manning, 2015: 261).

Doğal dil işleme süreçleri içerisinde metin madenciliği, makine çevirisi, konuşma tanıma ve sesli komut sistemleri ile duygu durumu analizleri çeşitli uygulamalar olarak sıralanabilir. Metin madenciliği (text mining), kısaca, metinlerden anlamlı bilgilerin otomatik olarak çıkarılması işlemi olarak tanımlanabilir. Örneğin, biyomedikal metinlerden hastalık belirtilerinin çıkarılması bu alana özgüdür (Nadkarni vd., 2011: 545). Makine çevirisi (machine translation), doğal dil işlemenin en eski uygulama alanlarından biri olup, diller arası otomatik çeviri sağlamaya çalışmaktadır. Özellikle istatistiksel ve yapay sinir ağları tabanlı modeller bu alana oldukça önemli katkılarda bulunmuştur (Hirschberg ve Manning, 2015: 262). Konuşma tanıma ve sesli komut sistemleri; sesli girdilerin metne dönüştürülmesi ve bu metinlerin analiz edilmesini hedeflemektedir. Siri, Alexa ve Google Asistan gibi sistemler bunun çarpıcı örnekleri olarak karşımıza çıkmaktadır

(Nadkarni vd., 2011: 546; Hirschberg ve Manning, 2015: 263). Duygu analizi (sentiment analysis) ise kullanıcı görüşlerini analiz ederek olumlu, olumsuz ya da tarafsız duyguları saptamayı amaçlamaktadır (Gerçek ve Özveren, 2023: 1050).

Geleneksel doğal dil işleme sistemleri dilbilim kurallarını esas alarak, dilbilgisel yapılara dayalı çözümler sunmaktadır. Bu sistemler kural tabanlı sistemler olarak bilinmektedir. Ancak bu sistemler kural tabanlı oldukları için esneklikleri sınırlıdır (Jain vd., 2018: 162). Son yıllarda, öğrenme algoritmalarının kullanılmasıyla dil anlama başarımları artmıştır. Özellikle sinir ağı modelleri bu alan ciddi katkılarda bulunmuştur. (Hirschberg ve Manning, 2015: 264; Nadkarni vd.,2011: 547). Ayrıca OpenAI'nin GPT ve Google'ın BERT gibi modelleri, çok büyük metin kümelerinden öğrenerek çeşitli doğal dil işleme görevlerinde kullanılmaktadır.

Doğal dil işleme, insan-makine etkileşimlerini önemli ölçüde kolaylaştırmakta ve teknolojik ilerlemelere hız kazandırmaktadır. Doğal dil işlemenin geleceğinin çok dilli sistemlerin geliştirilmesine, düşük kaynaklı dillerin desteklenmesine ve daha hassas anlam çıkarım tekniklerine dayalı olacağı ileri sürülmektedir. Ayrıca, etik ve gizlilik gibi konuların bu gelişimlerin merkezinde yer alacağı vurgulanmaktadır (Hirschberg ve Manning, 2015: 265; Jones, 1994: 58).

#### 4.2.6. Derin Öğrenme

Derin öğrenme (Deep Learnig), karmaşık veri modellerini analiz etmek ve yorumlamak için birçok katmana sahip sinir ağlarını kullanmaya odaklanan makine öğrenimi ve yapay zekanın bir alt alanıdır. Yapay zekâ araştırmaları, daha zeki sistemler tasarlamayı ve insan düşünce yapısını modellemeyi hedeflemektedir. Bu alandaki ilk önemli adım, McCulloch ve Pitts'in (1943) insan sinir sisteminden esinlenerek beyin fonksiyonlarının işleyişini mantıksal olarak modellemesidir. Bu çalışma, yapay sinir ağlarının temelini oluşturmuştur. Ancak, doğrusal modellerin doğrusal olmayan problemleri çözemediği için 1960'larda yapay sinir ağlarına olan ilgi azalmıştır. 1980'lerde paralel dağıtık işlem modeliyle sinir ağı araştırmaları yeniden canlanmış, bugünün derin öğrenme temelleri bu dönemde atılmıştır. Bu dönemde yapay sinir ağlarının eğitimi için geri yayılım algoritması geliştirilmiş ve yaygınlaştırılmıştır. 2000'li yıllarda GPU'ların hesaplama gücündeki artış, derin ağların kullanımını kolaylaştırmış ve sığ ağlardan derin ağlara geçişi hızlandırmıştır. Hilton vd. (2006) çalışması derin sinir ağlarının açgözlü katmanlı ön eğitim yöntemiyle etkili bir şekilde eğitilebileceğini göstermiştir. Bu yöntem, diğer araştırmacılar tarafından da

farklı derin ağlar için uyarlanmıştır. Bu süreçte derin sinir ağlarının daha iyi performans göstermesi için ağların daha derin olması gerektiği fark edilmiştir. Bu durum, derinlik kavramına vurgu yapan “Derin Öğrenme” teriminin yaygınlaşmasını sağlamıştır (İnik ve Ülker, 2017: 86; Şeker vd., 2017: 52).

Derin öğrenmenin temel mimarileri arasında Konvolüsyonel Sinir Ağları (Convolutional Neural Network, CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN), Uzun Kısa Vadeli Bellek (Long-Short Term Memory, LSTM), Derin İnanç Ağları (Deep belief networks, DBN) ve Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines, RBM) gibi modeller yer almaktadır. Konvolüsyonel Sinir Ağları görüntü işleme ve doğal dil işleme gibi alanlarda hiyerarşik özellikleri öğrenme yetenekleriyle öne çıkarken, Tekrarlayan Sinir Ağları zaman serisi ve dil modeli gibi sıralı verilerle çalışmak için geliştirilmiştir. Bu sinir ağının uzun vadeli bağımlılık sorunlarını çözmek amacıyla tasarlanan Uzun Kısa Vadeli Bellek, bu tür problemlerde etkili bir çözüm sunmaktadır. Sınırlı Boltzmann Makineleri özellik öğrenimi, boyut indirgeme ve işbirlikçi filtreleme gibi görevlerde kullanılırken; Derin İnanç Ağları, Sınırlı Boltzmann Makineleri yığınlarından oluşarak denetimsiz öğrenme süreçlerinde başarıyla uygulanmaktadır. Derin Oto-Kodlayıcılar ise boyut indirgeme ve anormallik tespiti gibi görevlerde öne çıkmaktadır. Bu mimariler görüntü işleme, doğal dil işleme, konuşma tanıma ve biyomedikal sinyal işleme gibi çeşitli alanlarda güçlü performans sergilemektedir (Şeker vd., 2017).

Derin öğrenme, veri setlerindeki karmaşık özellikleri otomatik olarak öğrenebilme yeteneği sayesinde daha yüksek düzeyde soyutlamaların ve niteliklerin elde edilmesine olanak tanımaktadır. Ayrıca, büyük miktardaki verinin işlenmesi, derin öğrenme modellerinin genelleme yeteneğini artırabilir. Özellikle görüntü tanıma, ses tanıma ve doğal dil işleme gibi alanlarda, derin öğrenme geleneksel yöntemlere kıyasla çok daha iyi performans sergileyebilmektedir (LeCun vd., 2015: 436-439).

Derin öğrenme özellikle bilgisayar görüşü, ses işleme, doğal dil işleme ve otomatik öğrenme gibi alanlarda başarıyla uygulanmıştır. Ancak, derin öğrenme modellerini eğitmek ve optimize etmek genellikle büyük hesaplama gücü ve geniş veri setleri gerektirdiği için bu tekniklerin başarılı bir şekilde uygulanabilmesi belirli kaynaklar ve altyapılar gerekmektedir.

#### 4.2.7. Veri Madenciliği

Veriler çeşitli şekillerde oluşturulmakta ve toplanmaktadır. Herhangi bir düzenleme işlemine tabi tutulmamış nitelikteki veriler ham veri

olarak değerlendirilmektedir. Bu veriler geçmişte ne olduğuna dair bilgi sağladığından, karar almak için yeterli olmamaktadır. Ayrıca, ham veriler tek başına bir anlam ifade etmemektedir. Bu bağlamda veriler belli bir amaç doğrultusunda işlendiğinde anlamlı hale gelerek, bilgiye dönüşmektedir. Bu nedenle büyük miktarda veriyi işleyip anlamlı hale getirebilen teknikler, özellikle veri madenciliği, bu sürecin temel araçlarından biri olarak kabul edilmektedir (Savaş vd., 2012: 2).

Veri madenciliği (Data Mining), büyük miktardaki veriler arasında önemli olanları bulup çıkarma ve bu verilerden bilgi elde etme süreci olarak tanımlanmaktadır. Veri madenciliğinde sıradan sorgulama ya da istatistiksel analiz yöntemlerinden farklı olarak, milyarlarca veri ve birçok değişkenle çalışılmaktadır. Teknolojik gelişmeler sayesinde elektronik verilerin kaydedilmesi, saklanması ve erişilmesi kolaylaşırken, bu verilerin analiz edilmesi için özel uzmanlık ve algoritmalara ihtiyaç duyulmaktadır. Özellikle ilişkisel veri tabanlarında saklanan büyük veri setlerinden anlamlı sonuçlar çıkarabilmek için gelişmiş analiz teknikleri geliştirilmiştir (Coşlu, 2013: 615). Bir başka ifadeyle veri madenciliği; istatistiksel, matematiksel ve makine öğrenimi tekniklerinin bir kombinasyonunu kullanarak, büyük veri kümelerinden anlamlı desenler, eğilimler ve içgörüler çıkarma süreci olarak da ifade edilebilir. Bu çerçevede veri madenciliği, gizli ilişkileri ortaya çıkarmak ve inovasyonu yönlendirmek için sektörler arasında yaygın olarak uygulanır.

Veri madenciliğinin kökenleri, istatistikçilerin ve bilgisayar bilimcilerinin veri tabanlarında depolanan verileri analiz etmek için yöntemler geliştirmeye başladığı 1960'lara ve 1970'lere kadar uzanmaktadır. Bilgisayarların yaygınlaşması ve internet erişiminin her yerden sağlanabilmesi, büyük miktarda verinin saklanmasını ve işlenmesini kolaylaştırmıştır. Verilerin yorumlanıp bilgiye dönüştürülmesi ihtiyacı, zamanla veri işleme teknolojilerinin gelişmesini sağlamıştır. 1970'lerde İlişkisel Veri Tabanı Yönetim Sistemleri ve uzman sistemler geliştirilmiş, 1980'lerde ise veri tabanı yönetim sistemleri daha geniş alanlarda kullanılmaya başlanmıştır. Şirketler bu yıllarda müşteri, rakiplerini ve ürün verilerini topladığı büyük veri tabanları oluşturmuşlardır. 1990'larda artan veri miktarıyla bu verilerden anlamlı bilgi çıkarma ihtiyacı doğmuş ve bu konu üzerine çalışmalara başlanmıştır. 1989'da Knowledge Discovery in Databases çalışma grubu toplantıları, veri madenciliği kavramının temelini oluşturmuş; 1992 yılında ise ilk veri madenciliği yazılımı geliştirilmiştir. 2000'li yıllarda veri madenciliği hızla gelişmiş, hemen her alanda uygulanabilir hale gelmiş ve alınan başarılı sonuçlar bu alana olan ilgiyi artırmıştır (Savaş vd., 2012: 4-5).



İstatistik, bilim ve sanayideki problemlere çözüm sunmak için sürekli olarak gelişmektedir. İlk dönemlerde ziraat ve sanayi deneylerinden gelen, daha dar kapsamlı problemlere odaklanılmışken, bilgisayarların ve bilgi çağının gelişimiyle birlikte istatistiksel problemler boyut ve karmaşıklık açısından büyük bir artış göstermiştir. Modern istatistik, büyük veri yığınlarından önemli örüntü ve eğilimleri ortaya çıkarma ve “verinin ne söylediğini” anlama görevini üstlenmiştir. Bu sürece “veriden öğrenme” denilmektedir. Veriden öğrenme, hesaplama bilimleri, mühendislik, yapay zekâ ve veri madenciliği gibi farklı disiplinlerin kesişim noktasında yer almaktadır. Veriden öğrenme, özellikle sağlık, finans ve sanayi gibi birçok alanda kritik öneme sahip hale gelmiştir (Koyuncugil ve Özgülbaş, 2009: 24). Sonuç olarak 2000’lerde büyük verilerin yükselişi, veri madenciliğinin kapsamını ve ilgi düzeyini genişletmiş; bunun yanında yapay zekâ sistemleriyle entegrasyonuna yol açmıştır. Veri madenciliğinin geleceği, yapay zekâ ve büyük veri teknolojilerindeki gelişmelerle iç içe olduğu görülmektedir.

## 5. Bulut Teknolojisi ve Yapay Zekâ

Bulut teknolojisi verileri depolamak, yönetmek ve işlemek için internette barındırılan uzak sunucuların kullanımını ifade etmekte olup, yerel altyapıya olan ihtiyacı ortadan kaldırmaktadır. Bulut teknolojisinin temel bir uygulaması olan bulut bilişim sunucular, depolama, veri tabanları ile yazılım gibi bilgi işlem kaynaklarına internet üzerinden talep üzerine erişim sağlamaktadır. Bu hizmetler genellikle hizmet olarak altyapı, hizmet olarak platform ve hizmet olarak yazılım şekliyle üç modele ayrılmaktadır. Hizmet olarak altyapı, sunucular ve depolama gibi sanallaştırılmış bilgi işlem kaynakları sağlamaktadır. Hizmet olarak platform ise uygulamaları geliştirmek, test etmek ve dağıtmak için araçlar ve platformlar sunmaktadır. Hizmet olarak yazılım, yazılım uygulamalarını web tarayıcıları aracılığıyla erişilebilen internet üzerinden sunmaktadır (Tayaksi vd., 2016: 72-74).

Bulut Bilişim (Cloud Computing) verilerin, belgelerin, yazılımların ve uygulamaların internet üzerinde yer alan sanal bir depoda saklanmasını ve internet aracılığıyla erişilmesini sağlayan bir teknolojidir. Aynı zamanda kullanıcıların sunucu kaynaklarını ortak kullanmasına olanak tanıyan ve yönetimi nispeten kolay bir sistem olarak tanımlanmaktadır (Çelik, 2021: 438). Bulut Bilişim; bilişim teknolojilerindeki gelişmeler, yazılım ve donanım alanındaki ilerlemeler, iş ortamlarının değişimi ve web hizmetlerindeki yenilikler sayesinde hızla gelişmekte ve yaygınlaşmaktadır (Göktaş ve Baysal, 2018: 1417-1418). Ayrıca, esnek yapısı sayesinde ihtiyaçlara hızlı bir şekilde uyum sağlayabilen bir teknolojidir (Çelik, 2021).

Bulut bilişimin kökleri, yapay zekanın öncülerinden John McCarthy'nin bilişim fikrini kamu hizmeti olarak öngördüğü 1960'lara dayanmaktadır (Çelik, 2012: 239). Ancak, bu kavram 2000'lerde internet tabanlı hizmetler ve altyapının ortaya çıkmasıyla gerçeğe dönüşür. Amazon Web Services'inin 2006 yılında Elastic Compute Cloud'u (EC2) piyasaya sürmesi, bulut bilişimin ticari olarak benimsenmesinde önemli bir dönüm noktası olmuştur (Kalaç ve Zorlu, 2023: 3). Aynı zamanda bulut bilişim; yapay zekanın büyümesi makine öğrenimi, sinir ağları ve veri analitiğindeki gelişmelerle ilerlemiştir (Çelik, 2021: 241).

Bulut bilişim hesaplama taleplerini, veri depolamayı ve iş birliğine dayalı geliştirme süreçlerini kolaylaştırarak yapay zekâ için önemli bir destekleyici rol üstlenmektedir. Bu teknoloji, yapay zekâ girişimlerini çeşitli yönlerden desteklemektedir. Dinamik kaynak ölçeklendirme ile yoğun yapay zekâ eğitim ve çıkarım görevlerini karşılayarak ölçeklenebilirlik sağlamaktadır. Kullanım başına ödeme modeli sayesinde yüksek maliyetli altyapılara ihtiyaç duymadan yapay zekâ araçlarına erişim imkânı sunarak, maliyet verimliliği yaratılmaktadır. Uygulama Programlama Arayüzleri (Application Programming Interface, API) ve önceden oluşturulmuş modeller aracılığıyla güçlü bilgi işlem kaynaklarını herkesin kullanımına açarak, erişilebilirliği artırmaktadır. Ayrıca, ekiplerin verileri ve modelleri kolayca paylaşabilmesi sayesinde iş birliğini teşvik ederek, küresel ölçekte ortak çalışmalarını desteklemektedir. Son olarak, bulut ekosistemleri; makine öğrenimi çerçevelerini, önceden eğitilmiş modelleri ve veri analitiği platformlarını entegre ederek yapay zekâ araçlarının entegrasyonunu kolaylaştırmaktadır.

Bulut teknolojisi; muhasebe işlemlerinin ve bilgilerinin depolanması, saklanması, işlenmesi ve paylaşılması konusunda özellikle küçük ve orta ölçekli işletmeler için iş yapış şekillerinde devrim niteliğinde bir yenilik sunmaktadır. Muhasebe yazılımlarının bulut tabanlı hale gelmesi, finansal verilerin daha güvenli bir şekilde saklanmasını ve yedeklenmesini sağlayarak, veri kaybı riskini en aza indirmektedir. Ayrıca bulut teknolojisi, finansal tablo analizleri için gerçek zamanlı olarak verilere ulaşmayı mümkün kılmaktadır. Ayrıca, fiziki ortam bağımlılığı ortadan kaldırmaktadır. Böylece işletmelerin farklı noktalardaki işlemlerini, gerçek zamanlı olarak takip edebilmesi mümkün olmaktadır (Erturan ve Ergin, 2018: 159; Elitaş ve Özdemir, 2014: 102-106).

## 6. Muhasebe ve Yapay Zekâ

Yapay zekanın muhasebe alanında giderek artan önemi, geleneksel muhasebe yöntemlerinin sınırlılıkları ve veri işleme ihtiyaçlarından

kaynaklanmaktadır. Karar alma süreçlerinde öznel yargılar, düşük doğruluk oranları, büyük veri kümelerini yönetme zorlukları ve gerçek zamanlı bilgi eksikliği gibi sorunlar, bu alanda daha yenilikçi yaklaşımlara olan ihtiyacı ortaya koymaktadır. Yapay zekâ, yalnızca veri toplama ve işleme süreçlerini optimize etmekle kalmayıp; finansal tablo analizi, yatırım ve finansman kararları, risk yönetimi, dolandırıcılık tespiti gibi kritik alanlarda daha hızlı, doğru ve etkili çözümler sunmaktadır.

### 6.1. Yapay Zekânın Gerekliliği

Muhasebede karar alma süreci, öznel yaklaşımlar, düşük doğruluk oranları, büyük veri kümelerini işleme güçlüğü, farklı çalışma koşullarında düşük güvenilirlik ve doğruluk gibi pek çok sorunu beraberinde getirmektedir. Ayrıca, mevcut yöntemlerin pratiklik açısından yetersiz kalması, bu alanda daha gelişmiş çözümlere olan ihtiyacı artırmaktadır. Bu nedenle, muhasebe süreçlerinde yapay zekâ uygulamalarına yönelik talep giderek artmaktadır. Yapay zekâ, artan veri talebini karşılamak ve veri işleme gereksinimlerini daha etkin bir şekilde yönetmek için önemli bir çözüm sunmaktadır.

#### 6.1.1. Veri Talebi

Geleneksel muhasebede işletmeyle ait bilgiler (veriler) genellikle fiziki ve/veya dijital bir ortama elle yapılan, zahmetli ve oldukça zaman alan işlemlerle kaydedilmektedir. Bu işlemin dijitalleşerek otomatik bir hale getirilmesi muhasebe bilgilerinin hızlı bir şekilde üretilebilmesini sağlamaktadır. Bu kapsamda örneğin faturaların otomatik olarak tanınması ve fişlerin otomatik olarak girilmesi sırasında insan hatası kaynaklı ortaya çıkan hataların minimize edilebilmektedir. Dolayısıyla günümüzde işletmelerin sahip oldukları büyük verinin insan eliyle girilmesi, karar süreçleri için anlamlı bilgiler sağlanmasının önünde önemli bir sınırlılık olarak karşımıza çıkmaktadır.

İşletmelerin kullandığı veriler çoğunlukla standart dışı veriler niteliğindedir. Standart dışı veriler, genel olarak, kamuya açık finansal raporlar ya da düzenleyici kurumlar tarafından sağlanan standart verilerin dışındaki daha özel, ayrıntılı ya da alternatif veriler olarak ifade edilebilir. Çalışanların performansları, üretim süreci verimliliği, dahili operasyonel raporlar, işletme içi yapılan görüşmeler ve anketler, dış kaynaklardan elde edilen nicel ve nitel veriler örnek olarak verilebilir. Bu verilerin elde edilmesi genellikle maliyetli, zaman alıcı ve zordur. Ancak, bu bilgiler kullanılarak daha derinlemesine analizler yapılabilir ve elde edilen bilgiler ile karar süreçlerine daha iyi katkıda bulunulabilir.

İşletmelerin denetlenmesinde sadece finansal bilgilerden yeterli kanıt elde edemeyebilir. Bu nedenle daha detaylı bilgiler için standart dışı verilere ihtiyaç duyulabilir. Bu nedenle fatura, makbuz, mizan kayıtlarının alt kırılımları, sözleşme bilgileri, ilgili taraflarla yapılan yazışmalar gibi destekleyici belgeler; kurumsal kaynak planlaması sistemlerinden ya da muhasebe yazılımlarından elde edilen detaylı işlem kayıtları, işletmenin finansal olmayan ancak muhasebeyle ilgili olabilecek e-ticaret işlemleri ya da blockchain tabanlı muhasebe sistemlerinden alınan işlem kayıtları gibi dijital verileri ile üretim verileri, envanter hareketleri ya da lojistik kayıtları gibi finansal olayların doğruluğunu destekleyen operasyonel bilgiler kullanılabilir (Bkz. Knechel ve Payne, 2001).

Görüldüğü üzere, işletmelerin sürdürülebilirliklerini ve karlılıklarını devam ettirebilmeleri, ayrıca yasal gerekçelerden dolayı standart ve standart verilere ihtiyaç duymaktadır. Günümüzün rekabet ortamında artan veri hacmini geleneksel yöntemler ile derlemek ve analiz etmek oldukça zorlu bir hale gelmiştir. Ayrıca, standart dışı verilerin sağladığı bilgilerin kullanımının sağladığı avantajlar nedeniyle yapay zekâ kullanımı bir gereklilik haline gelmektedir.

### 6.1.2. Veri İşleme İhtiyacı

Muhasebede karar alma araştırmaları 1960'lara kadar uzanmasına rağmen, yönetsel muhasebe odaklı çalışmaların ağırlıkta olduğu görülmektedir. Bunun nedeni, finansal muhasebe bilgilerinin zamanla şirket yönetimini desteklemekten yatırımcılara rehberlik etmeye kadar genişleyen hedefleridir (Socea, 2012: 47). Muhasebe, yalnızca mekanik bir raporlama süreci olmayıp, pek çok uzmanlık gerektiren meslek gibi kararlar alma yetkinliğine sahip olmayı gerektirmektedir. Ancak bu kararlar, dikkatsizlik, tecrübesizlik ya da gelecekteki belirsizlikler gibi nedenlerle hata riski taşımaktadır (Şaban ve Atalay, 2005: 52). Finansal muhasebe bilgilerinin karar almada faydalı olabilmesi için somut olmayan, alakalı, güvenilir ve karşılaştırılabilir nitelikte olması gerekmektedir. Kararlar yalnızca mevcut bilgilerden değil, aynı zamanda bireylerin kişisel inanç ve vizyonlarından etkilenmektedir. Muhasebe ve finans araştırmaları, genellikle bilim ve teknolojiye titiz kanıt süreçlerinden ziyade profesyonellerin deneyimlerine dayanmaktadır (Socea, 2012: 47). Bu bağlamda karar alma süreçlerinde veri işleme ihtiyacı giderek artmaktadır.

Muhasebe işlemleri içerisinde hızla artan veri hacmi nedeniyle gerçek zamanlı karar almaya yönelik bir talep oluşmuştur. Bununla beraber geleneksel muhasebe sistemleri, genellikle periyodik raporlama ve elle veri

işleme ile sınırlıdır. Gerçek zamanlı muhasebe verileri, finansal olayların anlık olarak işlenmesi, analiz edilmesi ve raporlanmasını ifade etmektedir. Bu veriler, şirketlerin finansal pozisyonlarını sürekli bir şekilde izlemelerine olanak tanımaktadır. Örneğin günlük operasyonların finansal sonuçları anlamlandırılmasında ve stok seviyeleri optimize edilmesinde kullanılabilir. Bu bilgi asimetrisini azaltarak karar alma süreçlerini daha etkili hale getirir. Böylece hızlı karar verme süreçlerini desteklerken, aynı zamanda hata oranlarını düşürerek daha sağlam finansal yönetim sağlanabilir. Bu nedenle gerçek zamanlı karar alma, işletmelerin değişen çevresel koşullara hızlı bir şekilde tepki vermesini sağlayan bir süreçtir. Muhasebe işlemlerinden elde edilen verilerin bu süreçte kullanımı karar alma süreçlerinin doğruluğunu artırırken, operasyonel verimliliği de geliştirecektir. Gerçek zamanlı muhasebe verileri, yalnızca işletmelerin mevcut durumlarını anlamalarına değil, aynı zamanda gelecekteki stratejilerini daha etkin bir şekilde planlamalarına olanak tanır. Dolayısıyla gerçek zamanlı veriler, işletmeler için stratejik bir kaynak olarak rekabet avantajı yaratabilir. Ancak, geleneksel modeller ve algoritmalar ise gerçek zamanlı karar almada ve bazı sorunları çözmek konusunda yeterli olmayabilir. Bu nedenle muhasebe işlemlerinden elde edilen büyük verinin analizinde yapay zekâ kullanım ihtiyacı artmakta ve yaygınlaşmaktadır.

## 6.2. Yapay Zekânın Etkisi ve Entegrasyonu

Muhasebe, işletmenin kaynaklarının oluşumu, bu kaynakların kullanımı, faaliyetler sonucunda kaynaklarda meydana gelen artış ya da azalışlar ve işletmenin finansal durumunu açıklayan bilgileri derleyen, sınıflandıran ve ilgili kişi ya da kuruluşlara ileten bir sistemdir. Kaydetme, sınıflandırma, özetleme ve raporlama muhasebenin temel işlevleri arasında yer alırken, analiz ve yorumlama ise muhasebenin ileri düzey işlevlerindedir (Gençtürk, 2008: 57). Ancak geleneksel muhasebe yöntemleri, veri toplama, işleme ve nesnel karar alma süreçlerinde çeşitli zorluklarla karşılaşmaktadır. Bu bağlamda, yapay zekânın muhasebe alanındaki etkisi ve entegrasyonu giderek daha fazla önem kazanmaktadır. Yi vd. (2023) sınıflaması kullanılarak, yapay zekânın muhasebe süreçlerine katkıları finansal tablo analizi, yatırım ve finansman kararları, firma değerlendirme, finansal varlık fiyatlandırması, risk yönetimi ile dolandırıcılık ve mali suç başlıkları altında incelenmiştir.

### 6.2.1. Finansal Tablo Analizi

Finansal rapor, bir işletmenin parasal değer olarak ifade edilen ve muhasebe işlemleri ile kaydedilen, kategorize edilen ve özetlenen faydalı finansal bilgilerden oluşmaktadır. Bir başka ifadeyle bir finansal rapor,

işletmenin mali durumunu ve performansını ortaya koymak için gerekli tüm ham bilgileri belirli standartlara göre sunmaktadır. Bu finansal bilgiler ile yöneticilere, yatırımcılara, kredi verenlere vb. faydalı ve güvenilir bilgi sağlanarak kararlarında yardımcı olması amaçlanmaktadır. Ancak, bu bilgiler işletmenin geçmiş faaliyetlerinden elde edilmektedir. Bu nedenle işletmenin faaliyetlerinin tam olarak anlaşılmasında yeterli ölçüde katkı sağlayamazlar (Gençtürk, 2008: 59). Finansal tablo analizi ise finansal raporların çeşitli analiz yöntem ve teknikleriyle incelenmesi sonucunda işletmenin güçlü ve zayıf yönleri ortaya konularak işletme kararlarına temel oluşturmaktadır (Özkan ve Erdener Acar, 2010: 54).

İşletmeler yürütmüş oldukları faaliyetleri düzenli aralıklarla kamuoyunu bilgilendirmek için açıklamakla yükümlüdürler. Böylece yatırımcılar, finans kuruluşları vb. bu açıklamaları değerlendirerek çeşitli kararlar alırlar. Bu nedenle bir işletmenin finansal tablolar şeffaf ve güvenilir olması oldukça önemlidir. Bu bağlamda finansal analizler ile desteklenmiş finansal raporlar işletmeler ile finansal piyasalara arasında şeffaf ve güvenilir iletişimi sağlamaktadır (Örerler, 2005: 2, 6).

Dijitalleşme, muhasebe işlemlerini geleneksel yöntemlerden daha hızlı, güvenilir ve verimli bir hale getirmiştir. Ele işlenen yevmiye kayıtları, bu süreçte özet muhasebe bilgisi olarak birçok kullanıcının görebildiği bir dijital bilgi olarak görülebilmektedir (Zor ve Ala, 2021: 82). Böylece finansal tablolar daha hızlı, doğru ve güvenilir bir şekilde hazırlanabilmektedir. Finansal tablo analizleri daha etkin şekilde gerçekleştirilebilmektedir. Bu dijitalleşmeye eklenen bulut teknolojisi, finansal bilgilerin gerçek zamanlı elde edilmesine sağlayarak, güncel ve güvenilir finansal rapor analizlerinin oluşturulmasına imkân sunmaktadır.

Yapay zekâ, finansal tablo analizlerinde devrim niteliğinde yenilikler sunarak analiz süreçlerinin hızını ve doğruluğunu önemli ölçüde artırmıştır. Geleneksel finansal analiz yöntemleri genellikle ekonomik sezgi ve sektör deneyimlerine dayanmaktaydı. Örneğin, finansal tablo dolandırıcılığını tespit eden denetçiler, genellikle daha fazla sektör deneyiminden faydalanır ve bu da öznel yargı gerektirebilir. Bunun yanı sıra, belirli bir sorunun analizinde çoğu zaman bir dizi finansal oran kullanılır ve bu oranlar, analiz öncesinde verilerin boyutunun küçültülmesini gerektirir. Bu durum, geleneksel analiz yöntemleri için önemli bir zorluk oluşturmuştur (Yi vd., 2023: 129102).

Yapay zekanın getirdiği en önemli yeniliklerden biri, finansal sıkıntı ve iflas tahmini gibi karmaşık analizlerde derin öğrenme modellerinin kullanılmasıdır. Metinsel bilgi, finansal tabloların metinsel içeriği duygular ya da tonlar içerebileceğinden kurumsal mali sıkıntıyı tahmin etmek için eşit

derecede değerlidir. Bu modeller, finansal tabloların metinsel içeriğinden faydalanarak, kurumların finansal sıkıntı riskini daha iyi tahmin edebilmekte ve duygu analizleri gibi yenilikçi yaklaşımlar sunmaktadır. Geleneksel yöntemlerde yaygın olarak kullanılan ayırıcı analiz ve lojistik regresyon modelleri, makine öğrenme yöntemlerine kıyasla daha düşük doğruluk oranlarına sahiptir (Yi vd., 2023: 129108).

### 6.2.2. Yatırım ve Finansman Kararları

İşletmeler faaliyetlerini sürdürebilmek, operasyonel kapasitelerini koruyabilmek ve işletmenin değerinin maksimize edilebilmek için büyük miktarlarda yatırımlar gerçekleştirirler. Yatırım kararlarının işletmelerin gelecekteki performansları üzerinde doğrudan belirleyici rolleri bulunmakta olup, piyasa değerlerinin oluşmasında kritik öneme sahiptir. Bu nedenle yatırım kararlarındaki yaygın görüş net bugünkü değeri pozitif olan projelere yatırım yapılmaktır (Özer vd., 2023: 244). Bir yatırımın net bugünkü değeri, genellikle belirli bir t zamanında belli bir iskonto oranına göre indirgenmiş giderlerinin toplamı ile indirgenmiş net gelirlerinin toplamı arasındaki farkın, yani net nakit akışının bugünkü değerini ifade etmektedir (Gedik vd., 2005: 56).

Yatırım kararlarındaki en kritik nokta, gelecekteki nakit akışlarının tahmin edilmesindeki belirsizliktir. Karar alıcıların sezgisel yargıları ve sektör deneyimlerinden etkilenecek nakit akış tahminlerinin çoğunlukla öznel olduğu belirtilmektedir. Bunun yanında geleceğe dair nakit akışların belirsiz doğası, bu tahminlerin bilimsel kesinlikle yapılmasını zorlaştırmaktadır. Dolayısıyla yatırım kararları sadece net bugünkü değer ya da iç verim oranı gibi göstergelerle değil; işletmenin sermaye yapısını optimize etmek, maliyetlerin minimize edilmesi, işletme değerinin maksimize edilmesi ve paydaş motivasyonunun artırılması gibi birden fazla kritik hedefi optimize etmeye yönelik stratejik yaklaşımlarla desteklenerek alınmalıdır (Yi vd., 2023: 129102).

Muhasebe tarafından hazırlanan finansal raporlar işletmelerin yatırım ve finansman kararlarında temel bilgi kaynağıdır. Bu raporlar işletmenin mali durumu, gelir durumu ve nakit akışı hakkında bilgiler sunmaktadır. Muhasebe verileri ile yatırım projelerinin fayda maliyet analizleri yapılabilmektedir. Ayrıca işletmelerin finansman maliyetleri izlenerek, sermaye yapısına ilişkin kararlar etkili bir şekilde alınabilmektedir (Cengiz vd., 2017). Muhasebe özelindeki literatürde sermaye yapısını etkileyen faktörler yoğun bir şekilde incelenmiş ve bu faktörlerin sermaye yapısıyla olan ilişkisi genellikle doğrusal modellerle analiz edilmiştir. Ancak, sermaye yapısı ve etkileyen faktörler



arasındaki ilişki her zaman doğrusal olmayabilir. Bu durum, daha karmaşık ilişkileri analiz edebilen yeni teknolojilere olan ihtiyacı ortaya koymaktadır (Yi vd., 2023: 129102).

Yatırım projelerinin değerlendirilmesinde kesinlik varsayımı yapılmaktadır. Ancak, bu durum gerçek dünyanın stokastik ve bulanık faktörleri ile çalışmaktadır. Huang (2007) net bugünkü değer yöntemini genetik algoritma ve stokastik bulanık simülasyon tekniklerini kullanarak yatırım problemlerinde sadece net bugünkü değer maksimizasyonun yeterli olmadığını göstermektedir. Bu nedenle çok hedefli durumlarda yapay zekâ destekli optimizasyon algoritmaları kullanılabilir. Ayrıca, Abdou vd. (2012), sermaye yapısını etkileyen faktörlerin analizinde genelleştirilmiş regresyon sinir ağlarını kullanarak daha doğru sonuçlara ulaştıklarını raporlamaktadır (Yi vd., 2023: 129109-129110).

Sonuç olarak muhasebede dijitalleşme ile bulut teknolojisinin ve yapay zekanın kullanılmaya başlaması işletmelerin yatırım ve finansman kararlarının daha isabetli olmasını ve risklerin daha etkili şekilde yönetilebilmesine olanak tanımaktadır.

### 6.2.3. Firma Değerleme

Değer, malların alıcı ve satıcı tarafından belirlenen fiyatını ifade ederken; değerleme, varlıkların parasal değerinin belirlenmesi için yapılan faaliyetlerin bütünüdür. Firma değerlemesi ise, belirli bir zamanda, mevcut koşullar ve özellikler dikkate alınarak bir firmanın değerinin hesaplanmasıdır. Bu süreçte amaç, piyasada tam bilgiye sahip, zorlama olmadan hareket eden alıcı ve satıcıların belirlediği alım-satım değerini tespit etmektir (Toraman ve Körpi, 2015: 42).

Firma değerini belirlemek için Aktif Bazlı Yaklaşım, Piyasa Değeri Yaklaşımı ve Gelir Yaklaşımı temel yöntemler olarak kullanılmaktadır. Bu yöntemler, önceden hazırlanmış ve erişilebilir olduğu için muhasebe bilgilerini temel almaktadır. Bu durum, karar vericilerin diğer bilgi kaynaklarına başvurmadan mevcut muhasebe bilgilerini kullanmalarını sağlamaktadır. Ayrıca, muhasebe bilgileri geçmiş olayları ortak bir finansal dilde kaydettiği için alınan kararların açıklanması daha kolay hale gelmektedir (Özdemir ve Öncü, 2018: 124). Bu süreç, özellikle birleşme ve satın alma, halka arz, borçlanma ya da stratejik ortaklık kararlarında kritik bir rol oynamaktadır. Ayrıca firma değerlendirme, işletmenin mali durumunu ve piyasa konumunu anlamak için gerekli olan kapsamlı bir araç sunmaktadır. Bu bağlamda işletmelerin rekabet avantajını artırmak ve paydaşlarına güvenilir bilgi

sunmak amacıyla, firma değerlendirme süreçlerinin etkin bir şekilde yürütülmesi büyük bir önem arz etmektedir.

Genel olarak, denetlenmiş mali tablolardan elde edilen bilgilerin değeri, rekabet odaklı kullanıcılar alternatif bilgi kaynakları elde edebileceğinden denetim raporu gecikmesi, yani bir şirketin mali yıl sonu ile denetim raporu tarihi arasındaki zaman dilimi arttıkça azalacaktır. Ayrıca, kazanç kalitesi ve kazanç yönetimi literatürü, beklenmeyen raporlama gecikmelerinin daha düşük kaliteli bilgilerle ilişkili olabileceğini öne sürmektedir (Knechel ve Payne, 2001: 137). Bu bağlamda muhasebe işlemlerinin dijitalleşmesi firma değerlendirme süreçlerini hızlandırmış, doğruluğunu artırmış ve daha kapsamlı analizlerin yapılmasını mümkün kılmıştır. Dijitalleşme sayesinde finansal raporlar, varlık değerlemeleri ve nakit akışı projeksiyonları gibi kritik bilgiler hızlı ve sistematik bir şekilde toplanıp analiz edilebilirken; otomasyon araçları karmaşık matematiksel modellerin uygulanmasını kolaylaştırarak hata oranlarını minimize etmektedir. Ayrıca, karmaşık değerlendirme modelleri kullanan büyük işletmeler için bulut tabanlı çözümler maliyet etkin, yüksek performanslı ve güvenli bir çözüm olarak süreçleri hızlandırmakta ve daha şeffaf hale getirmektedir.

Firma değerlemesi yeniden yapılandırma, birleşme, satın alma ve hisse senedi analizi gibi finansal faaliyetlerin önemli bir bileşenidir. Firma değerlemede serbest nakit akışı tahmini kritik bir rol oynar ve bu tahminin bilimsel ve makul bir yöntemle yapılması doğru değerlendirme için gereklidir. Geleneksel yöntemlerden ARIMA modeli sadece doğrusal ilişkileri dikkate alır ve kısa vadeli tahminlerle sınırlıdır. Yapay zekâ yöntemleri ise özellikle doğrusal olmayan ve durağan olmayan verilerde daha başarılıdır. Örneğin destek vektör makineleri, bu tür verilerde etkili tahminler sunmaktadır. Ayrıca, Wang ve Ning (2015) parçacık sürüsü optimizasyon algoritmasını ve bulanık mantık sistemi modelini nakit akışı tahmini için kullanmaktadır. Zhu vd. (2022) ise genetik algoritmaya dayalı geri yayımlı sinir ağı modeliyle serbest nakit akışını tahmin etmiş ve bu modelin hata oranının diğer yöntemlere göre daha düşük olduğunu göstermiştir. Bu yöntemler, nakit akışı tahmininde doğruluk ve etkinliği artırarak firma değerlendirme süreçlerini geliştirmektedir (Yi vd., 2023: 129102, 129110-129111). Görüldüğü üzere yapay zekâ, firma değerlendirme süreçlerini dönüştürerek daha hızlı, doğru ve öngörülü analizlerin yapılmasını sağlamıştır.

#### 6.2.4. Finansal Varlık Fiyatlandırması

Finansal varlık fiyatlandırması hisse senetleri, tahviller, türev ürünler ve diğer finansal araçların değerinin analitik ve matematiksel yöntemlerle

belirlenmesini kapsayan bir çalışma alanı olup, bir finansal varlığın gelecekteki nakit akışlarının ya da risk-getiri profilinin değerlendirilmesiyle adil değerinin belirlenmesi amaçlanmaktadır. Finansal raporlama ve muhasebe sistemleri, varlıkların performansı ve değerlemesi için temel teşkil eden geçmiş verileri sağlayarak; finansal varlık fiyatlandırmasında işlev görmektedir.

Finansal varlık fiyatlandırmasında beklenen getiri fonksiyonunu belirleme, risk primini ölçme, dış makro ortamın etkisini dikkate almanın yanında; geleneksel yöntemlerle ele alınması zor olan yeni davranışsal finans açıklamalarının modele dahil edilmesi gibi çeşitli zorluklar bulunmaktadır. Örneğin sermaye varlık fiyatlandırma modelleri, iskontolu nakit akışı modelleri ve faktör modelleri uluslararası hisse senedi fiyatlandırmasında temel yaklaşımlar olarak kabul edilmektedir. Ancak sistematik risk, hisse senedi fiyatlarını etkileyen en önemli bir faktör olmayabilir. Bunun yanında şirket büyüklüğü, P/E oranı ve diğer şirket özellikleri yer alır olabilir. Bu nedenle bu fiyatlandırma modellerinin revize edilmesi ve iyileştirilmesi gerektiği belirtilmektedir. Bunların yanında geleneksel istatistiksel modeller, büyük miktardaki makroekonomik zaman serisi verisinden ekonominin durumunu belirlemede zorlanmaktadır (Yi vd., 2023: 129103, 129111).

Mevcut zorluklar karşısında yapay sinir ağları ve derin öğrenme yöntemleri, doğrusal olmayan ve karmaşık fiyatlama problemlerini çözüme etkili araçlar sunmaktadır. Makine öğrenimi algoritmaları, finansal piyasalardaki karmaşık ilişkileri ve eğilimleri analiz ederek gelecekteki fiyat hareketlerini daha doğru tahmin edebilmekte ve doğal dil işleme teknikleriyle piyasa duyarlılığını anlamak için haber akışlarını ve sosyal medya yorumlarını değerlendirebilmektedir. Ayrıca, geleneksel temel analiz yöntemleri, finansal verilerin stokastik doğasını tam anlamıyla ele alamamaktadır. Ancak metin madenciliği teknikleri, bu eksikliği gidermek için kullanılmaktadır. Hagenau vd. (2013) ile De Fortuny vd. (2014), finansal haberlerden anlamlı göstergeler çıkararak tahmin doğruluğunun arttırılabildiği göstermektedir (Yi vd., 2023: 129111-129112).

### 6.2.5. Risk Yönetimi

Risk, bir olayın gerçekleşme ihtimalinin belirli bir hedefe ulaşmayı etkileyebilecek bir durum yaratmasıdır. Bu durum etki ve olasılık cinsinden hesaplanmaktadır. Risk yönetimi ise kurumların hedeflerine ulaşmasını desteklemek amacıyla, potansiyel olay ve durumları tanımlama, değerlendirme, yönetme ve kontrol etmesidir (Bozkurt, 2010: 19). Bu çerçevede risk yönetimi bireylerin, kurumların ya da toplumların karşılaşılabileceği riskleri belirlemek, analiz etmek, öncelik sırasına koymak

ve bu riskleri azaltmak ya da ortadan kaldırmak için sistematik yöntemler geliştirmektedir. Muhasebenin işletmelerin finansal durumlarını gösteren objektif ve doğrulanabilir veriler sunması, risk analizi ve yönetimi için temel bilgi kaynağı olmasını sağlamaktadır.

Yapay zekâ, risk yönetiminde verimliliği artırmakta ve daha doğru kararlar alınmasına olanak sağlamaktadır. Büyük miktarda yapılandırılmış ve yapılandırılmamış veriyi analiz ederek potansiyel riskleri önceden tespit edebilir, anormallikleri belirleyebilir ve senaryo analizleri yaparak olası riskleri tahmin edebilir. Oynaklık, piyasa riskinin önemli bir göstergesidir. Bu nedenle oynaklık tahmini süreçleri risk yönetimi için kritik öneme sahiptir. Geleneksel oynaklık tahmininde ARCH, GARCH vb. modeller kullanılmaktadır. Bu modeller asimetrik ilişkileri ve çok değişkenli durumları dikkate almamaktadır. Hibrit makine öğrenimi teknikleri, bu sınırlamaları aşarak daha doğru tahminler yapmaktadır. Bunun yanında kredi risk yönetiminde, geleneksel istatistiksel yöntemler doğrusal varsayımlar nedeniyle karmaşık ilişkileri yeterince ele alamamaktadır. Makine öğrenimi ise doğrusal olmayan ve çok değişkenli ilişkileri modelleyerek kredi puanlamasında daha doğru ve kapsamlı bir yaklaşım sunmaktadır. Ayrıca doğal dil işleme modeli çevrimiçi mesaj panoları, doğal afet vb. haberler ve medya kaynaklarından elde edilen yapılandırılmamış veriler, oynaklığı tahmin etmekte önemli göstergeler sağlamaktadır (Yi vd., 2023: 129112-129113).

#### 6.2.6. Dolandırıcılık ve Mali Suç

Kişiler temel ihtiyaçlarını karşılayabilmek için gelire ihtiyaç duymaktadırlar. Bazı kişiler ihtiyaç duydukları bu geliri, yasa dışı yollardan elde etmeyi tercih edebilmektedirler. Bu durum yasal olarak elde edilen kazancın yetkili kurumlardan gizlenmesinden yasa dışı faaliyetlerden elde edilen gelire kadar değişen şekillerde kazanç sağlayabilirler. Bu tür kazançlar, mali suç ya da kara para olarak tanımlanmaktadır. Mali suçlar, finansal sistemlerin bütünlüğünü tehdit eden ve toplumda güven kaybına yol açan ciddi sorunlardır. Ekonomik suçlar ve mali suçlar sıklıkla birbirine karıştırılmaktadır. Güvel (2005), ekonomik suçları aldatma, suiistimal ya da yanlış beyan yoluyla haksız kazanç elde etme amacı taşıyan, genellikle özel bilgi ve beceri gerektiren yasa dışı eylemler olarak tanımlamaktadır. Mali suçların en ayırt edici özelliği ise genellikle şiddet içermemeleridir. Bu suçlarda bir taraf haksız kazanç elde ederken, diğer tarafın ekonomik olarak zarar görmesine neden olmaktadır. Dolandırıcılık, kaçakçılık, yolsuzluk, rüşvet, kalpazanlık, mali sektör suçları ve kara para aklama mali suçlar arasında yer almaktadır. Dolandırıcılık, aldatma kastıyla gerçekleştirilen yasa dışı eylemler olarak tanımlanmaktadır (Doğan ve Yıldız, 2021: 131-132).

Mali suçların belirlenmesi, izlenmesi ve önlenmesi için dolandırıcılık ve mali suç tespit süreçleri geliştirilmiştir. Bu süreçler, anomalilerin belirlenmesi, şüpheli işlemlerin analizi ve dolandırıcılığın önlenmesi gibi yöntemlerden oluşmaktadır. Dijital teknolojiler, dolandırıcılık ve kara para aklama faaliyetlerinin tespitinde önemli araçlar sunmaktadır. İşlemlerin dijital ortamda kaydedilmesi ve analiz edilmesi, yasa dışı finansal hareketlerin izlenmesini kolaylaştırmaktadır. Finansal kurumlar, algoritmalar ve yazılımlar kullanarak şüpheli işlemleri tespit edebilmekte ve yasal gerekliliklere uygun şekilde raporlayabilmektedir (Shademanpoor, 2025: 105-106). Bu kapsamda muhasebe, dolandırıcılık ve mali suçların tespitinde temel bir bilgi kaynağı konumunda olup, finansal işlemleri kayıt altına alarak şeffaf bir altyapı sağlamaktadır. Ayrıca, iç kontrol sistemlerinin tasarlanması ve uygulanmasında merkezi bir role sahiptir. Günümüzde etkin bir dolandırıcılık tespiti yalnızca geçmiş verilere dayanmakla kalmamakta, aynı zamanda gerçek zamanlı analitik teknikleri de içermektedir.

Finansal tablo dolandırıcılığının tespiti, denetçilerin finansal oranlara dayalı öznel yargılarına bağlıdır. Ancak bu yöntem zaman alıcı, maliyetli ve çoğu zaman yetersiz kalmaktadır. Yapay zekâ tabanlı algoritmalar ise finansal işlemler arasında norm dışı davranışları tespit ederek dolandırıcılığı belirlemede yüksek doğruluk oranları sunmaktadır. Spathis (2002), lojistik regresyon modeli kullanarak finansal dolandırıcılığı %84 doğruluk oranıyla tahmin etmektedir. Özellikle derin öğrenme algoritmaları, büyük veri setlerinde karmaşık örüntüleri analiz ederek şüpheli işlemleri belirlemede etkili olmaktadır. Ayrıca, veri madenciliği teknikleri, dolandırıcılıkla ilişkili özelliklerin çıkarılmasında yaygın olarak kullanılmaktadır. Entegre bulanık sinir ağları gibi yöntemler, geleneksel yaklaşımlardan daha yüksek performans göstermektedir. Bunların yanında bankalarda kredi kartı dolandırıcılığı tahminleri, geçmiş işlem verileri ve müşteri profilleri kullanılarak şüpheli davranışları tahmin edebilir ve dolandırıcılık gerçekleşmeden önce önlem alınmasına olanak tanıyabilir. Doğal dil işleme, finansal raporlar ve e-postalar gibi yapılandırılmamış verilerden anlamlı bilgiler çıkararak dolandırıcılık tespitine entegre edilebilmektedir. Craja vd. (2020) yıllık raporlardaki yönetim tartışma ve analizi bölümlerinden metinsel bilgileri çıkararak dolandırıcılık tespitinde model doğruluğunu artırmıştır (Yi ve diğerleri, 2023: 129115-129116). Sonuç olarak dolandırıcılık ve mali suçlar, finansal sistemler için ciddi bir tehdit oluşturmaktadır. Muhasebe, bu tür faaliyetlerin tespitinde bilgi ve şeffaflık sağlayarak merkezi bir rol oynamaktadır.

## 7. Sonuç

Endüstri 4.0 ve büyük veri teknolojilerinin entegrasyonu, muhasebe süreçlerinde devrim niteliğinde yeniliklere yol açmıştır. Yapay zekâ algoritmalarının kullanımı, finansal raporlamada hata oranlarını azaltırken; büyük veri analitiği, karar alma mekanizmalarının daha stratejik hale gelmesini sağlamıştır. Gerçek zamanlı veri işleme sayesinde finansal işlemlerin izlenmesi ve öngörüler oluşturulması daha hızlı ve etkili hale gelmiştir. Bunun sonucunda, finansal karar alma süreçlerinde daha şeffaf, verimli ve sürdürülebilir bir yaklaşım benimsenmiştir.

Ancak, yapay zekâ ve büyük veri teknolojilerinin muhasebe alanına entegrasyonu sürecinde öne çıkan etik ve veri mahremiyeti gibi konular, bu teknolojilerin tam potansiyelini ortaya koyması için uygun yönetmeliklerin oluşturulmasını gerektirmektedir. Bununla birlikte, yasal ve etik düzenlemelerin geliştirilmesi, teknolojilerin daha etkin ve güvenilir bir şekilde kullanılmasına olanak tanıyacaktır.

Sonuç olarak, Endüstri 4.0'ın sunduğu yenilikler, muhasebe süreçlerini sadece otomasyonla sınırlı kalmayıp, stratejik karar alma ve risk yönetiminde çok boyutlu gelişmeleri desteklemektedir. Bu teknolojilerin gelecekte finansal sistemleri daha entegre, şeffaf ve şirketlerin rekabet avantajlarını arttıracığı düşünülmektedir.

## Kaynaklar

- Abdou, H. A., Kuzmic, A., Pointon, J., and Lister, R. J. (2012). Determinants of Capital Structure in the UK Retail Industry: A Comparison of Multiple Regression and Generalized Regression Neural Network. *Intelligent Systems in Accounting, Finance and Management*, 19(3), 151-169.
- Akın, E. ve Şahin, M. E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Aktan, E. (2018). Büyük Veri: Uygulama Alanları, Analitiği ve Güvenlik Boyutu. *Bilgi Yönetimi*, 1(1), 1-22.
- Bozkurt, C. (2010). Risk, kurumsal risk yönetimi ve iç denetim. *Denetişim*, (4), 17-30.
- Cengiz, S., Dinç, Y., and Tosunoğlu, B. (2017). Impact Of Financial Reporting Quality On Investment Efficiency: An Application in İstanbul Stock Exchange. In *International Congress Of Eurasian Social Sciences (ICOESS) Özel Sayısı*, 8(8), 421-439.
- Chowdhury, G. G. (2003). Natural Language Processing. *Annual Review of Information Science and Technology*, 37, 51-89.
- Copeland, B. J. (2024). Dendral, Britannica, <https://www.britannica.com/technology/DENDRAL>
- Coşlu, E. (2013). Veri Madenciliği. *Akademik Bilişim - XV. Akademik Bilişim Konferansı Bildirileri*, 615-619.
- Cox, M. and Ellsworth, D. (1997). Application-Controlled Demand Paging for Out-of-Core Visualization. In *Proceedings of the 8th Conference on Visualization'97*, 235-244.
- Craja, P., Kim, A., and Lessmann, S. (2020). Deep Learning for Detecting Financial Statement Fraud. *Decision Support Systems*, 139, 113421, 1-13.
- Çelik, K. (2021). Bulut Bilişim Teknolojileri. *Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(24), 436-450.
- Çelik, K. (2021). Bulut Bilişimde Temel Konular. *Uluslararası Batı Karadeniz Sosyal ve Beşerî Bilimler Dergisi*, 5(2), 236-250.
- DDO. (2024). Yapay Zekâ. Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi, <https://cbddo.gov.tr/sss/yapay-zeka/> erişim tarihi: 29.01.2024.
- De Fortuny, E. J., De Smedt, T., Martens, D., and Daelemans, W. (2014). Evaluating and Understanding Text-based Stock Price Prediction Models. *Information Processing & Management*, 50(2), 426-441.
- Delipetrev, B., Tsinaraki, C., & Kostić, U. (2020). AI Watch, Historical Evolution of Artificial Intelligence: Analysis of the Three Main Paradigm Shifts in AI. European Commission, Joint Research Centre.



- Demirtaş, B. ve Argan, M. (2015). Büyük Veri ve Pazarlamadaki Dönüşüm: Kuramsal Bir Yaklaşım. *Pazarlama ve Pazarlama Araştırmaları Dergisi*, 8(15), 1-22.
- Dhall, D., Kaur, R., and Juneja, M. (2020). Machine Learning: A Review of the Algorithms and Its Applications. *Proceedings of ICRIC 2019: Recent innovations in computing*, 47-63.
- Doğan, B. ve Yıldız, A. (2021). Mali Suçlar ve Mali Suçlarla Mücadele: Türkiye Örneği. *Uluslararası Turizm, Ekonomi ve İşletme Bilimleri Dergisi (IJ-TEBS)* E-ISSN: 2602-4411, 5(2), 129-150.
- Doğan, K. ve Arslantekin, S. (2016). Büyük Veri: Önemi, Yapısı ve Günümüzdeki Durum. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 56(1), 15-36.
- Elitaş, C. ve Özdemir, S. (2014). Bulut Bilişim ve Muhasebede Kullanımı. *Muhasebe Bilim Dünyası Dergisi*, 16(2), 93-108.
- Ersoy, E. ve Karal, Ö. (2012). Yapay Sınır Ağları ve İnsan Beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Erturan, İ. E., & Ergin, E. (2024). Muhasebe mesleğinde dijitalleşme: Endüstri 4.0 etkisi. *The Journal of Academic Social Science*, 72(72), 153-165.
- Erturan, İ. E. ve Ergin, E. (2024). Muhasebe Mesleğinde Dijitalleşme: Endüstri 4.0 Etkisi. *The Journal of Academic Social Science*, 72(72), 153-165.
- Gahi, Y., Guennoun, M., and Mouftah, H. T. (2016). Big Data Analytics: Security and Privacy Challenges. In *2016 IEEE Symposium on Computers and Communication (ISCC)*, 952-957.
- Gedik, T., Akyüz, K. C. ve Akyüz, İ. (2005). Yatırım Projelerinin Hazırlanması ve Değerlendirilmesi (İç Karlılık Oranı ve Net Bugünkü Değer Yöntemlerinin İncelenmesi). *Bartın Orman Fakültesi Dergisi*, 7(7), 51-61.
- Gençtürk, M. (2008). İşletmelerin Finansal Raporları Kullanım Amacı ve Düzeyini Belirlemeye Yönelik Muhasebe Mensuplarının Tutumları Üzerine Bir Araştırma. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, 15, 56-72.
- Gerçek, M. ve Özveren, C. G. (2023). Yapay Zeka Araçları İky İçin Nasıl Değer Yaratabilir? Çalışan Duygu Analizinin Uygulama Alanlarının İncelenmesi. *Yönetim Bilimleri Dergisi*, 21(50), 1048-1076.
- Göktaş, P. ve Baysal, H. (2018), Türkiye’de Dijital İnsan Kaynakları Yönetiminde Bulut Bilişim, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 23(4), 1409-1424.
- Güvel, A. (2005), Ekonomik Suçlar, Tanım, Türleri ve Ölçüleri, Ekonomik Suç ve Ceza Sempozyumu, 30 Nisan – 1 Mayıs, Ankara: TOBB Yayın No: 25, 28-34.

- Hagenau, M., Liebmann, M., and Neumann, D. (2013). Automated News Reading: Stock Price Prediction Based on Financial News Using Context-Capturing Features. *Decision support systems*, 55(3), 685-697.
- Hernández, A. B., and Hidalgo, D. B. (2020). Fuzzy Logic in Business, Management and Accounting. *Open Journal of Business and Management*, 8(6), 2524-2544.
- Hinton, G. E., Osindero, S., and Teh, Y. W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural computation*, 18(7), 1527-1554.
- Hirschberg, J. and Manning, C. D. (2015). Advances in Natural Language Processing. *Science*, 349(6245), 261-266.
- Huang, X. (2007). Optimal Project Selection with Random Fuzzy Parameters. *International journal of production economics*, 106(2), 513-522.
- İçen, D. ve Günay, S. (2014). Uzman Sistemler ve İstatistik. *İstatistikçiler Dergisi: İstatistik ve Aktüerya*, 7(2), 37-45.
- İnik, Ö. ve Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Jain, A., Kulkarni, G., and Shah, V. (2018). Natural Language Processing. *International Journal of Computer Sciences and Engineering*, 6(1), 161-167.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine Learning: Trends, Perspectives, and Prospects. *Science*, 349(6245), 255-260.
- Kablan, A. (2018). Endüstri 4.0, "Nesnelerin İnterneti" -Akıllı İşletmeler ve Muhasebe Denetimi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23 (Endüstri 4.0 ve Örgütsel Değişim Özel Sayısı), 1561-1579.
- Kalaç, M. Ö. ve Zorlu, D. Sürdürebilir İşletmeler için Bulut Teknolojilerin Önemi Üzerine Bir İnceleme. *Yönetim Bilişim Sistemleri Dergisi*, 9(2), 1-14.
- Karan, T. (2023). Yapay Zeka: Doğuşu ve Gelişimi, *Medium*, <https://medium.com/t%C3%BCrkiye/bu-zeka-yapay-2-yapay-zekan%C4%B1n-i%C-C%87lk-d%C3%B6nemi-4f654459b7ce>
- Karacioğlu, R., Yalçın, S. ve Gültekin, Ö. F. (2020). Sezgisel Bulanık Mantık ve Entropi Tabanlı Çok Kriterli Karar Verme Yöntemiyle Finansal Performans Analizi: BİST’de İşlem Gören Enerji Şirketleri Üzerine Bir Uygulama. *MANAS Sosyal Araştırmalar Dergisi*, 9(1), 360-372.
- Kaya, İ., Gözen, Ş. ve Engin, O. (2004). Kalite Kontrol Problemlerinin Çözümünde Uzman Sistemlerin Kullanımı. *Journal of Aeronautics and Space Technologies*, 1(4), 87-101.
- Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.

- Koyuncugil, A. ve Özgülbaş, N. (2009). Veri Madenciliği: Tıp ve Sağlık Hizmetlerinde Kullanımı ve Uygulamaları. *Bilişim Teknolojileri Dergisi*, 2(2), 21-32.
- Krahel, J. P. and Titera, W. R. (2015). Consequences of Big Data and Formalization on Accounting And Auditing Standards. *Accounting Horizons*, 29(2), 409-422.
- Kütük, Y. ve Zor, Ü. (2020). Muhasebe Alanında Geliştirilen Uzman Sistemler. *Muhasebe ve Denetime Bakış*, 20(61), 193-208.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep Learning. *nature*, 521(7553), 436-444.
- Lin, J. W., Hwang, M. I., and Becker, J. D. (2003). A Fuzzy Neural Network for Assessing The Risk of Fraudulent Financial Reporting. *Managerial Auditing Journal*, 18(8), 657-665.
- Mahesh, B. (2020). Machine Learning Algorithms-A Review. *International Journal of Science and Research (IJSR)*, 9(1), 381-386.
- Milana, C. and Ashta, A. (2021). Artificial Intelligence Techniques in Finance and Financial Markets: A Survey Of The Literature. *Strategic Change*, 30(3), 189-209.
- Nadkarni, P. M., Ohno-Machado, L., and Chapman, W. W. (2011). Natural Language Processing: an Introduction. *Journal of the American Medical Informatics Association*, 18(5), 544-551.
- Oracle. (2024). Makine Öğrenimi Nedir? <https://www.oracle.com/tr/artificial-intelligence/machine-learning/what-is-machine-learning/> erişim tarihi: 29.01.2024.
- Örerler, E. O. (2005). Finansal Değerlendirme Açısından Finansal Tabloların Şeffaflığı. *Muhasebe ve Denetime Bakış*, (15), 1-8.
- Özdemir, Ö. ve Öncü, E. (2018). Muhasebe Verilerinin Firma Değerine Etkisi: Borsa İstanbul Metal Sektörü Üzerine Bir Uygulama. *Muhasebe ve Finansman Dergisi*, (78), 125-138.
- Özer, G., Çam, İ. ve Kocaman, M. Yönetim Kurulu Yapısının Yatırım Etkinliği ve Firma Değeri Üzerindeki Moderatör Etkisi: BİST Örneği. *Uluslararası Ekonomi İşletme ve Politika Dergisi*, 7(2), 242-261.
- Özkan, S. ve Acar, E. E. (2010). Uluslararası Muhasebe/Finansal Raporlama Standartlarının Finansal Tablolar Analizi Üzerindeki Etkilerine Genel Bakış. *Mali Çözüm Dergisi/Financial Analysis*, 97, 49-85.
- Sanca, M., Artun, H. ve Okur, M. (2022). Fen Eğitiminde Bulanık Mantık Uygulamaları Neden Kullanılmalıdır? *Ulusal Eğitim Akademisi Dergisi*, 6(1), 130-144.

- Savaş, S., Topaloğlu, N. ve Yılmaz, M. (2012). Veri madenciliği ve Türkiye'deki uygulama örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 11(21), 1-23.
- Shademanpoor, F., (2025), Kara Para Aklamanın Önlenmesinde ve Mücadelede Dijital Teknolojinin Rolü, *Ekonomi Bilimleri Dergisi*, 17(1), 89-125.
- Jones, K. S. (1994). Natural Language Processing: A Historical Review. Current issues in computational linguistics: in honour of Don Walker, 9-10, 3-16.
- Spathis, C. T. (2002). Detecting False Financial Statements Using Published Data: Some Evidence From Greece. *Managerial Auditing Journal*, 17(4), 179-191.
- Stearns, P. N. (2013). *The Industrial Revolution in World History* (4th ed.). Westview Press.
- Şaban, M. ve Atalay, B. (2005). Yönetim Muhasebecileri Açısından Etik ve Etik Davranışın Önemi. *Muhasebe ve Denetime Bakış*, 16, 49-60.
- Şeker, A., Diri, B. ve Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Taskin, A. and Guneri, A. F. (2006). Economic Analysis of Risky Projects by ANNs. *Applied Mathematics and Computation*, 175(1), 171-181.
- Taşar, B., Üneş, F., Demirci, M. ve Kaya, Y. Z. (2018). Yapay Sinir Ağları Yöntemi Kullanılarak Buharlaştırma Miktarı Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 543-551.
- Tayaksi, C., Ada, E. ve Kazançoğlu, Y. (2016). Bulut Üretim: İşlemler Yönetiminde Yeni Bir Bulut Bilişim Modeli. *Ege Academic Review, Özel Sayı*, 16, 71-84.
- Toraman, C. ve Körpi, M. (2015). Firma Değerinin Piyasa Çarpanları ile Tahmin Edilmesi: BIST Dokuma, Giyim Eşyası ve Deri Sanayii Sektöründe Bir Uygulama. *Muhasebe ve Finansman Dergisi*, 66, 41-56.
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind a Quarterly Review of Psychology and Philosophy*, 433-460.
- Turkel, S. ve Yeşilkuş, F. (2020). Dijital Dönüşüm Paradigması: Endüstri 4.0. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, 7(5), 332-346.
- Vickery, A. and Brooks, H. (1987). Expert Systems and Their Applications in LIS. *Online Review*, 11(3), 149-165.
- Wang, J. S. and Ning, C. X. (2015). ANFIS Based Time Series Prediction Method of Bank Cash Flow Optimized by Adaptive Population Activity PSO Algorithm. *Information*, 6(3), 300-313.
- Warren, J. D., Moffitt, K. C., and Byrnes, P. (2015). How Big Data Will Change Accounting. *Accounting Horizons*, 29(2), 397-407.

- Wu, Y. C. and Feng, J. W. (2018). Development and Application of Artificial Neural Network. *Wireless Personal Communications*, 102, 1645-1656.
- Xu, J., Zhang, R., Wang, Y., Yan, H., Liu, Q., Guo, Y. and Ren, Y. (2022). Assessing China's Investment Risk of the Maritime Silk Road: A Model Based on Multiple Machine Learning Methods. *Energies*, 15(16), 5780.
- Yıldız Tonga, M. ve Tonga, M. (2022). Endüstri 4.0'a Genel Bir Bakış: Sana-yinin Geleceği. *G. Ü. İslahiye İİBF Uluslararası E-Dergi*, 6(6), 40-60.
- Yıldız, A. (2017). Endüstri 4.0 ve Akıllı Fabrikalar. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(2), 546-556.
- Yi, Z., Cao, X., Chen, Z., and Li, S. (2023). Artificial Intelligence in Accounting and Finance: Challenges and Opportunities. *IEEE Access*, 11, 129100-129123.
- Zadeh, L. A. (1965). Fuzzy Sets. *Information and Control*, 8(3), 338-353.
- Zhu, L., Yan, M., and Bai, L. (2022). Prediction of Enterprise Free Cash Flow Based on a Backpropagation Neural Network Model of the Improved Genetic Algorithm. *Information*, 13(4), 172.
- Zor, Ü. ve Ala, T. (2021). Teknoloji Odaklı Muhasebe Çalışmalarına Genel Bir Bakış: DergiPark Akademik Veri Tabanı ve Journal of Emerging Technologies Temelinde Sistemik Bir Literatür Taraması. *Muhasebe ve Finansman Dergisi*, (91), 81-102.
- Zou, J., Han, Y., and So, S. S. (2009). Overview of Artificial Neural Networks. *Artificial neural networks: methods and applications*, 14-22.