

Yönetim Bilişim Sistemlerinde Yapay Zeka Uygulamaları

Atakan Büyükbostancı¹

Hüseyin Koçak²

Özet

Çalışma, Yönetim Bilişim Sistemleri (YBS) ve yapay zekanın yönetim süreçlerine entegrasyonunu ele almaktadır. İşletmelerin ve kurumların etkin kararlar alabilmesi için bilişim sistemlerine ihtiyaç duyduğu belirtilmiş, YBS'nin bu ihtiyacı karşılayarak yönetsel süreçleri desteklediği vurgulanmıştır. Son yıllarda yapay zekanın gelişimi ile YBS'nin karar alma süreçlerini daha verimli hale getirdiği ve işletmelerde hız, maliyet ve doğruluk açısından önemli avantajlar sağladığı ifade edilmiştir. Çalışmanın önemi, yapay zeka ve makine öğrenmesi destekli YBS'nin işletmelerde rekabet avantajı sağlaması ve stratejik karar alma süreçlerini geliştirmesi üzerinedir. Özellikle veri analizi, risk yönetimi, müşteri ilişkileri ve tahminleme gibi alanlarda YBS'nin sunduğu imkanlar ele alınarak, yöneticilere daha doğru ve hızlı karar alma fırsatı sunduğu vurgulanmıştır. Çalışmanın amacı, yapay zeka destekli YBS uygulamalarının etkinliğini inceleyerek literatüre katkı sağlamaktır. Bu bağlamda YBS'nin temel özellikleri, yapay zeka ile entegrasyonu ve makine öğrenmesi yöntemleri detaylı bir şekilde ele alınmıştır. Makine öğrenmesi kapsamında Naïve Bayes, Lojistik Regresyon, Karar Ağaçları ve K-En Yakın Komşu algoritmaları gibi yöntemlerin yöneticilere karar alma süreçlerinde sağladığı katkılar değerlendirilmiştir. Sonuç olarak, yapay zeka destekli YBS uygulamalarının, işletmelerin verimliliklerini artırdığı, hatalı kararları minimize ettiği ve stratejik yönetim süreçlerini geliştirdiği ortaya konmuştur. Yapay zekanın gelişimiyle birlikte YBS'nin önemi giderek artmakta ve işletmelerin dijital dönüşüm sürecinde vazgeçilmez bir araç haline gelmektedir.

- 1 Öğretim Görevlisi, Ordu Üniversitesi, Ünye Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, Lojistik Programı, Orcid: 0000-0003-1390-5610, e-posta: atakanbuyukbostanci@odu.edu.tr
- 2 Öğretim Görevlisi, Ordu Üniversitesi İkizce Meslek Yüksekokulu Finans, Bankacılık ve Sigortacılık Bölümü, Orcid: 0000-0003-1877-5413, e-posta: huseyinkocak@odu.edu.tr

1. Giriş

İşletmelerin ve kurumların günlük rutin işler ve geleceğe dair planlamalar için kararlar alması gerekmektedir. Alınan kararların hızlı, düşük maliyetli ve etkin olması gerekmektedir. Bunun için de bilgi sistemlerine ihtiyaç vardır. YBS’de işletmelerin ve kurumların bu ihtiyacını karşılayacak çözümleri üretmektedir. YBS, yönetim süreçlerini bilişim sistemleriyle entegre eden bir süreçtir. Günümüzde bilişim sistemlerinde ise yapay zekanın etkisi sürekli artmaktadır. 1980’li yıllardan sonra akıllı makineler ve robotlar şeklinde üretilen cihazlar sayesinde insan aklına benzer bir yapı makinelere eklenmiştir. Bu süreç işletmelerde ve kurumlarda da yöneticilerin alacakları kararları kolaylaştıracaktır. Yapay zeka ile desteklenen YBS sayesinde işletmeler daha hızlı kararlar alabilmekte ve alınabilecek yanlış kararlar minimize edilmektedir.

Yapay zeka teknolojisi, verilerden türetilen algoritmalarla çeşitli makine öğrenmesi uygulamalarıyla yöneticilere karar alma konusunda yardımcı olmaktadır. Makine öğrenmesi uygulamaları arasında iş zekası konusunda başarı oranı yüksek Navie Bayes, geleceğe dair tahminlerde kullanılan Lojistik Regresyon, risk analizi ve stratejik kararlarda etkili Karar Ağaçları ve müşteri ilişkileri yönetimi konusunda sıklıkla tercih edilen K-En Yakın Komşu yer almaktadır.

Bu çalışmada ilk olarak YBS ve yapay zeka kavramları açıklanmış, daha sonra makine öğrenmesi yöntemleri ve uygulamaları açıklanmıştır. Çalışmanın amacı yapay zeka ile desteklenen YBS’nin uygulamadaki başarısı hakkında literatüre katkı sağlamaktır.

2. Yönetim Bilişim Sistemleri Ve Yapay Zeka

2.1. Yönetim Bilişim Sistemleri Kavramı ve Önemi

YBS, bir organizasyonel yapıda etkin ve verimli kararlara ulaşma konusunda büyük öneme sahiptir. Bir organizasyonda yöneticiler karar verme sürecinde kararlarını destekleyecek bilgilere ihtiyaç duyarlar. Bunun için de yöneticilerin bilgi ve veri akışının iyi sağlanması gerekir (Eren Gümüştekin, 2004). YBS ile ilgili literatürde çeşitli tanımlar yer almaktadır. YBS, örgüt içinden ve dışından tüm verileri toplayan, toplanan verileri analiz ederek anlamlı bir bilgi haline getirdikten sonra yöneticilere raporlayan bir sistemdir (Murdick ve Munson, 1986).

YBS, bir organizasyon için gerekli olan bilgiyi toplayan, işleyen, depolayan ve çıktı olarak raporlayan bir bilgi teknolojisidir. Böylece organizasyonda

bir konu hakkında karar verme sürecini geliştirme ve hızlandırma amacı gütmektedir (Bendre vd., 2017).

YBS, işletmelerin faaliyetlerini yerine getirme sürecinde gerekli olan tüm veri, bilgi ve enformasyonu sağlayan sistemlerdir (Akıncı ve Kahraman, 2024). YBS, bilgisayar teknolojilerini, yönetim bilimi ve yöneylem araştırması disiplinlerini bir araya getirerek gerçek hayatta ortaya çıkan problemlere yönelik çözümler geliştirmek ve bilişim teknolojileri kaynaklarını en verimli biçimde yönetebilmek için birleştiren multi disiplinler bir alandır. Bu alan ayrıca, sadece bilişim teknolojileri ile sınırlı kalmamakta sosyoloji, ekonomi ve psikoloji alanındaki konularla da ilgilenmektedir. Özellikle organizasyonel yapıların etkinliğini artırabilmek için işletmeler ve kurumlar tarafından da kullanılmaktadır. Son dönemlerde yönetim bilişim sistemleri alanındaki konularda yapılan çalışmalarda, istatistiksel tekniklerin kullanımından dolayı, YBS'nin istatistik disiplini ile de ilişkili olduğu söylenebilir (Laudon ve Laudon, 2006; Yarlıkaş, 2015).

YBS, yönetimde karar verme sürecini geliştirerek bu süreci otomatik hale getirmek için bulut bilişim, yapay zeka ve makine öğrenme yöntemlerini kullanan veri odaklı ve değişken iş ortamlarında kurumun hedefleri ile uyumlu olan sistemlerdir (Boehmer, 2021).

YBS'nin amacı herhangi bir kuruluştaki yönetim operasyonlarını desteklemek için bilgilerin toplanması, işlenmesi, saklanması ve ilgililere aktarılması süreciyle ilgilidir (Hakimpoor ve Khairabadi, 2018).

YBS'nin bir örgüt hiyerarşisi içerisindeki yeri işletme bazında değişiklik gösterebilir. Bu farklılığın nedeni işletmelerin YBS'den yararlanma derecelerindeki farklılıktan kaynaklanmaktadır. Genel olarak işletme yönetiminin kontrol ve planlama fonksiyonlarını verimli bir şekilde yerine getirebilmesi için YBS'nin yönetim kademesinin en tepesinde yer alması daha doğru olacaktır (Özgen ve Yalçın, 1992).

YBS, karar vericilerin stratejik karar alma ve geleceğe yönelik planları yapabilmeleri için farklı alanlarda faaliyet gösteren kuruluşlar için vazgeçilmezdir. Yöneticilere faaliyetleri yürütme ve genel performansı artırma konusunda gerekli olan bilgileri sağlar (Ayaz, 2024).

2.2. Yönetim Bilişim Sistemlerinin Özellikleri

İlk olarak 1960'lı yıllarda akademik eğitim programlarında sadece bilgisayarlı ve matematikçilerin ilgi alanında yer alan yönetim bilişim sistemleri (Akpınar, 2011), 1970'li yıllardan itibaren bilgisayarların küçülmesi ve yaygınlaşmasının ardından hızla gelişme göstermiştir (Power

vd., 2016). Son yıllarda bilgi teknolojilerinde meydana gelen gelişimler sonucu her alanda kullanılmaya başlayan YBS, işletmelerde ve kurumlarda yöneticilerin karar almalarında önemli rol oynamaktadır.

Yönetim bilişim sistemlerine ait özellikler aşağıda yer almaktadır (Erol, 2021):

- ✓ YBS, bilgisayar kullanımını temel alan bir sistemdir.
- ✓ YBS, bütünlük bir sistemdir. İşletmenin sahip olduğu kaynakları yönetimin etkin karar almasını sağlayacak şekilde bütünlükleştirir.
- ✓ YBS, işletme ortak veri tabanı sağlar. Bu sayede toplanan verilerin işletme içinde farklı birimler tarafından ortaklaşa kullanımını sağlar.
- ✓ YBS, yöneticilere işlerin kontrol ve raporlama olanağını sağlar.
- ✓ YBS, toplanan veriler üzerinden yöneticilere hem işletme içi hem de işletme dışı konularda karar almaya yardımcı olur.
- ✓ YBS, büyük miktardaki bilgiye düşük maliyet ve hızlı ulaşma olanağı sağlar (Arı, 2014).
- ✓ YBS, işletmelerde rekabet avantajı sağlayacak olan stratejileri destekler (O'Brien & Marakas, 2007).
- ✓ YBS, yöneticiler için bilgi desteği sağlayan sistemlerin tümüdür. Günlük olağan işlemlere ait tüm bilgiler sisteme işlenir ve depolanır. Yöneticilerde doğru bir şekilde depolanan bu bilgileri karar alma sürecinde kullanırlar (Erkut, 1989).

2.3. Yapay Zeka Destekli Yönetim Bilişim Sistemleri

YBS'nin insanlar, teknoloji, veri/bilgi ve süreçler olmak üzere dört ana bileşeni vardır. İnsan bileşeni, sistemi kullanıcılar olarak kabul edilen yöneticiler ve çalışanlar ile paydaşlar olarak kabul edilen müşterilerden oluşmaktadır. Teknoloji bileşeni, yönetim bilişim sisteminin oluşumunu sağlayan ağ altyapısı, donanım ve yazılımdan oluşmaktadır. Veri/bilgi bileşeni, müşteri bilgileri, satış rakamları gibi kurum için gerekli olan ve yönetim bilişim sistemi tarafından depolanmış ham ve dönüştürülmüş verilerden oluşur. Süreç bileşeni ise yöneticilerin planlama ve karar verme aşamalarında, anlamlı bilgiler üretmek amacıyla veri toplama, kaydetme ve analiz aşamalarından oluşmaktadır (Berdibek ve Kayaoglu, 2023).

Son yıllarda yapay zeka kavramı iş dünyasının önemli bir konusu olmuştur. Özellikle endüstri 4.0 ile beraber yapay zekanın üretimde kullanılması yönetim bilişim sistemlerini de etkilemiştir. Bu bağlamda yapay zeka destekli yönetim

bilişim sistemlerinin araştırılması gerekmektedir. Yapay zeka kavramı ile ilgili de literatürde çok çeşitli tanımlar yer almaktadır. Yapay zekanın babası olarak tanınan John McCarthy 1956 yılında “akıllı makineler yapmanın bilimi ve mühendisliği” şeklinde yapay zekayı tanımlamıştır (Gupta, 2017). Bir başka tanıma göre “insanlar ve diğer hayvanların sergilediği doğal zekanın aksine, makineler tarafından gösterilen zeka” şeklinde tanımlanmaktadır (Jain, 2018).

Yapay zekanın gelişimi ve uygulanması 20.yy’da başlamıştır. İlk olarak 1923 yılında Karel Capek’in “Rossum’un Evrensel Robotları” adlı oyunu ile robot sözcüğü kullanılmıştır. Daha sonra 1945 yılında Isaac Asimov Robotik kavramını bulmuştur (Gür vd., 2019).

Yapay zeka terimi ilk olarak 1956 yılında Dartmouth Koleji’nde düzenlenen bir çalıştayda John McCarthy tarafından kullanılmıştır. Yapay zekaya yönelik insana benzeyen ilk robot Japonya’da WABOT-I adıyla 1972 yılında yapılmıştır. 2000’li yılların başında “Roomba” isimli elektrikli süpürge ile yapay zeka evlere girmeye başlamıştır (Coşkun ve Gülleroğlu, 2021). Günümüzde yapay zeka hemen her sektörde etkin bir şekilde kullanılmaktadır. Yapay zekanın kullanım alanlarından biri de yönetim bilişim sistemleridir. Makine öğrenme uygulamaları, doğal dil işleme gibi yapay zeka teknolojileri, yönetim bilişim sistemlerini geliştirerek, yöneticilerin karar alma süreçlerinin verimliliğini ve etkinliğini artırmaktadır (Berdibek ve Kayaoğlu, 2023).

Yapay zeka, YBS dahil olmak üzere çeşitli sektörlerde büyük değişimler yaratmaktadır. Yapay zeka aracılığı ile makineler insan zekasının gerektirdiği işleri yerine getirmektedir (Berdibek ve Kayaoğlu, 2023). Bu bağlamda yapay zeka teknolojileri işletmelerdeki rutin işleri ve süreçleri otomatik hale getireceğinden yöneticilerin iş süreçleri optimize edilecek ve yöneticiler organizasyonu geliştirecek stratejik faaliyetlere odaklanacaktır (Berente vd., 2021).

3. Makine Öğrenmesi ve Yönetim Bilişim Sistemlerine Entegrasyonu

Makine öğrenmesi, 1959 yılında bilgisayar biliminin bir alt dalı olarak ortaya çıkmıştır. Makine öğrenmesi, verilere dayalı tahminlerde kullanılan algoritmalar üzerinden bilgisayar sistemine insan benzeri yetenekler kazandırmayı amaçlar (Zilyas ve Yılmaz, 2023).

Günümüzde bankacılık, eğlence, finans, eğitim, pazarlama vb. birçok sektörde makine öğrenmesi kullanılmaktadır. Makine öğrenmesi sayesinde

toplanan verilerden sağlanan sonuçlar aracılığı ile geleceğe dönük analizler yapılmaktadır (Türkmenoğlu ve Tantuğ, 2014).

3.1. Denetimli Öğrenme ve Yönetim Bilişim Sistemleri Uygulamaları

Denetimli öğrenme modelinde, bağımlı (çıkıtı) ve bağımsız (girdi) model kullanılmaktadır. Bu modeller matematiksel algoritmalar aracılığı ile girdiler ve çıktılar arasında bir neden-sonuç ilişkisi kurarak bir tahmin modeli üretilmektedir. Üretilen tahmin modeli aracılığı ile yeni girdilerin çıktılarını tahmin etmek mümkün olmaktadır (Ereken ve Tarhan, 2021). Denetimli öğrenmede, modellerin doğru tahminler yapabilmesini sağlamak için etiketli eğitim verileri kullanılır. Sisteme tanımlanan girdi veri seti ile çıktı veri seti arasında ilişki kurulmaya çalışılır. Buradaki amaç sonuçları bilinen veri setinden hareketle bilinmeyen veriler hakkında tahminler yapmaktır (Aydın ve Özkul, 2015). Sistemde algoritmalar yeterli eğitimi aldıktan sonra verileri sınıflandırabilir. Yötem ile spam e-postaları belirleme, dolandırıcılık girişimlerini ortaya çıkarma veya farklı görüntüleri ayırma işlemleri başarı ile gerçekleştirilebilir (Şahin, 2023).

3.2. Denetimsiz Öğrenme ve Örnek Senaryolar

Denetimsiz öğrenmede çıktılar, yani analiz sonucu elde edilen anlamlı bilgiler yer almamaktadır. Yöntem daha çok etkilenmemiş ve yapılandırılmamış verileri kümelemek ve sıralamak için algoritmaları kullanır. Denetimsiz öğrenmenin bu yönü denetimli öğrenmeden olan farkını göstermektedir. Denetimsiz öğrenmede çıktı bilgisi olmadan verilerden sonuçlar alınmaya çalışılır. En yaygın türü olan kümeleme analizi ile sistem çeşitli matematiksel algoritmaları kullanarak incelediği verileri gruplandırmaktadır (Polat, 2017). Örneğin bir e-ticaret sitesinden yapılan alışveriş sonucu müşteri sepetine bir ürün ekledikten sonra benzer ürünleri önermek için kullanılır.

3.3. Yarı Denetimli Öğrenme ve Kullanım Alanları

Denetimli öğrenme ve denetimsiz öğrenmenin yetersiz kaldığı alanlarda yarı denetimli öğrenme kullanılmaktadır. Az sayıda etiketlenmiş veri karşısında çok fazla sayıda etiketlenmemiş veri bulunuyorsa yarı denetimli öğrenmeye ihtiyaç vardır. Bu durumda az sayıdaki etiketlenmiş veriden hareketle etiketlenmemiş veriler hakkında bilgi sahibi olmaya çalışılır (Kızılıkaya ve Oğuzlar, 2018).

Yarı denetimli öğrenme tıp alanında hastalıkların tespiti, görüntü işlemede nesnelere tanıma, yüz tanıma ve doğal dil işlemede metin sınıflandırma gibi

alanlarda kullanılabilir. Örneğin sürücüsüz araç geliştirme sürecinde yarı denetimli öğrenme kullanılabilir. Sürücüsüz araçlar, yerleştirilen sensörler aracılığı ile çevre algılaması yapar ve verileri işleyerek güvenli sürüş sağlar. Ancak ortaya çıkabilecek her olumsuz duruma karşı verileri etiketlemek yüksek maliyetli olabilir. Burada yarı denetimli öğrenme kullanılmaktadır. Böylece bazı durumlara karşı güvenli sürüşü sağlayacak veriler etiketlenir (Yürek, 2024).

3.4. Pekiştirmeli/Takviyeli Öğrenme Yöntemleri ile Optimizasyon Süreci

Makine öğrenmesinin bir alt yaklaşımı olarak denetimli ve denetimsiz öğrenmeden farklıdır. Pekiştirmeli öğrenme, herhangi bir ortamda yer alan aracının bir problemi çözmek ve ortamdaki varlığını optimal bir şekilde devam ettirmek için gerçekleştirdiği eylemlerden aldığı geri dönmüşler üzerine kendini eğitmesidir (Köyüm ve Atıkan, 2024). Bu yöntemde algoritmaya yüklenen veriler deneme yanılma yoluyla kendini eğitmektedir. Böylece etkileşimlerden sağlanan öğrenme ile zaman içinde en iyi veya en iyiye yakın çözümler bulunur.

Pekiştirmeli öğrenme yöntemi finansal tahmin sürecinde kullanılabilir. Algoritmalar, finansal piyasalardaki karmaşık özellikleri zamanla dikkate alır ve piyasa değişimlerine uyum sağlar. Bu bağlamda uzun vadeli getiriler optimize edilebilir.

3.5. Derin Öğrenme: Büyük Veri ve Karmaşık Modelleme

Derin öğrenme, bilgisayarların tecrübelerinden ders almasını ve dünyayı kavramların hiyerarşisi üzerinden anlamasını sağlayan makine öğrenmesi yöntemidir. Günümüzde doğal dil işleme, nesne tanıma, robotik, finans, kimya, arama motorları sistemleri, biyomedikal sinyal ve görüntü işleme alanlarında kullanılmaktadır (Gündüz ve Cedimoğlu, 2019).

Derin öğrenmede özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanı kullanılır. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik temsil oluşur (Şeker vd., 2017).

4.3. Makine Öğrenmesi Yöntemleri

Makine öğrenmesi yöntemlerinin çok farklı çözümlenmeleri mevcuttur. Bu çalışmada Navie Bayes, Lojistik Regresyon ve Karar Ağaçları modellerine yer verilmiştir.

4.3.1. Navie Bayes Algoritması ve İş Zekası Uygulamaları

Bayes teoremi olarak literatürde yerini alan Navie Bayes (NB), sınıflandırma alanında en çok bilinen veri madenciliği algoritmalarından biridir. Navie Bayes ismini 17. yy'da çalışmalarıyla bilinen İngiliz matematikçi Thomas Bayes'ten almıştır. Navie Bayes, verileri sınıflandırmak için kullanılan olasılıksal bir makine öğrenmesi algoritmasıdır (Çelik vd., 2021). Naive Bayes her bir girdinin birbirinden bağımsız olduğunu varsayarak sınıf koşullu olasılıkları tarafsız tahmin eder. Bu yöntem, özellikle hızlı tahmin gerektiren büyük veri setlerinde sıklıkla kullanılmaktadır. Ancak eğitim kümesinde karşılığı olmayan verilerde "0 frekans" problemi yaşanabilmektedir. Çalışmalarda genellikle GaussianNB gibi Python sklearn kütüphanesinin algoritmaları tercih edilmektedir (Wu, 2013). Naive Bayes, giriş verilerini sınıflandırmak için özellik bağımsızlığı varsayımına dayanan basit bir olasılıksal sınıflandırıcıdır. Basitliğine rağmen, algoritma birçok görüş madenciliği uygulamasında metin sınıflandırması için kullanılmaktadır (Pak vd., 2010). Her bir özelliğin olasılıkları hesaplandıktan sonra, algoritma yeni verileri sınıflandırmak için kullanılmaktadır. Yeni metinler sınıflandırılırken, algoritma metni tek kelimelik özelliklere bölmekte ve model, duyguyu tahmin etmek için yeni özelliklerin olasılıklarını hesaplamak amacıyla eğitim aşamasında hesaplanan olasılıkları kullanmaktadır.

Bayes teoreminin avantajı sınıflandırma için gerekli olan parametreleri tahmin etmekte az miktarda eğitim verisine ihtiyacı olmasıdır. Eğitim verisinde bulunan her bir özelliğin koşullu olasılık dağılımı hesaplanır ve daha sonra verilerin koşullu olasılık dağılımı için Bayes teoremi uygulanır ve tahminde kullanılır. Test kümesinde herhangi bir verinin eğitim kümesinde karşılığı yoksa o veri için olasılık değeri '0' olarak dikkate alınmakta ve tahmin yapılamamaktadır (Çelik vd. 886).

$$P(A/B) = (P(B/A)P(A) / P(B))$$

$P(A/B)$: B olayının gerçekleştiği durumda A olayının gerçekleşme olasılığı,

$P(B/A)$: A olayının gerçekleştiği durumda B olayının gerçekleşme olasılığı

$P(A)$ ve $P(B)$: A ve B olaylarının önsel olasılıklarıdır.

İş zekası uygulamaları günümüzde finans, telekomünikasyon, perakende, enerji, kamu, sağlık sektörleri gibi çoğu sektörde analitik analiz sürecinde kullanılmaktadır. Mishan vd. (2017), yaptıkları "An Analysis On Business Intelligence Predicting Business Profitability Model Using Naive Bayes Neural Network Algorithm" isimli çalışmalarında iş zekası modelinin bilgi

edinme sürecinin etkinliğini artırmak ve değerlendirmek için önermiştir. Çalışmalarında işletmelerdeki kârlılığı tahmin etmede iş zekası modelini kullanmışlardır. Ayrıca Navie Bayes ile iş zekası modelinin birlikte kullanımının karar almada etkili olduğu sonucuna ulaşmışlardır. Kurnia (2018), “Business Intelligence Model to Analyze Social Media Information” isimli çalışmasında iş zekası modellerinin sosyal medya platformunda analizini yapmıştır. İş zekası analizlerinde Navie Bayes modelinin doğruluk oranının %74,67 ile ikinci sırada olduğu sonucuna ulaşmıştır.

4.3.2. Lojistik Regresyon ile Öngörüsül Analitik

Lojistik regresyon, veri sınıflandırmada yaygın olarak kullanılan bir regresyon türüdür. İkili sınıflandırma sorunlarında, logaritmik fonksiyonlarla modelleme yaparak sınıflandırma kurallarını öğrenir. Lojistik regresyon (LR), denetimli bir makine öğrenmesi algoritması olarak sınıflandırma problemleri için geliştirilmiştir.

Hedef değişken bir kategorik değişken olduğunda sınıflandırma problemleri ortaya çıkar (Keerthi vd., 2005). Lojistik regresyonun amacı, bağımsız değişkenler arasındaki ilişkileri modelleyerek bir örneğin belirli bir sınıfa ait olma olasılığını tahmin etmektir (Zou vd., 2019). Lojistik regresyon kategorik bir şekilde sınıflandırılmış bağımlı değişkenin olasılığını tahmin etmek için kullanılan denetimli makine öğrenmesi algoritmasıdır. Kullanım amacı, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi en az iki değişken ile en iyi uyuma sahip olacak şekilde model kurabilmektir (Çokluk, 2010: 1359).

Lojistik regresyonun matematiksel ifadesi aşağıda yer almaktadır:

$$\pi(x) = e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)} / (1 + e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)})$$

$\pi(x)$: İncelenen olayın gözlenme olasılığı,

β_0 : Bağımsız değişken sıfır değerini aldığı anda, bağımlı değişken üzerindeki etkisi,

β_1, \dots, β_p : Bağımsız değişkenlerin regresyon katsayıları,

X_1, \dots, X_p : Bağımsız değişkenleri,

p : Bağımsız değişken sayısını,

e : 2,718 sayısını göstermektedir (Akyol, vd., 2012).

Bu yöntem özellikle tıbbi teşhis, finansal başarısızlık riskleri, pazarlama ve kredi risk analizi gibi alanlarda öngörü yapmak amacıyla yaygın olarak kullanılmaktadır. Model, bir hedef değişkeni 0 veya 1 gibi iki olasılıkla sınırlar.

Bu tahminler, sigmoid işlevi aracılığıyla elde edilir. Yakıcı Ayan ve Değirmenci (2018), tarafından yayınlanan “Firma Finansal Başarısızlık Öngörüsü İçin Bir Lojistik Regresyon Modeli” isimli çalışmada, lojistik regresyon modeli ile firmaların bilançoları üzerinden hesaplanan rasyolar kullanılarak, 1 yıl önceden finansal başarısızlık durumunun öngörüldüğü sonucuna ulaşılmıştır. Dalvi vd. (2016), “Analysis of Customer Churn Prediction in Telecom Industry using Decision Trees and Logistic Regression” isimli çalışmalarında Telekom sektöründe faaliyet gösteren şirketlerin müşteri kaybını önlemek için veri madenciliği çalışmalarının etkisini analiz etmişlerdir. Çalışmanın sonucunda Telekom sektöründe faaliyet gösteren firmaların müşteri kaybını önlemek için veri madenciliği ve makine öğrenme modellerinden karar ağaçları ve lojistik regresyonun kullanılması önerilmektedir. Böylece firmalar hangi müşterilerin ayrılma riski altında olduğunu veya yeni müşterilerin hangileri olduğunu önceden tahmin edebilir. Bu bağlamda firmalar maliyetleri düşürerek tasarruf sağlayabilirler.

4.3.3. Karar Ağaçları (CART) ile Risk Analizi ve Stratejik Yönetim

Karar Ağaçları, büyük veri setlerini karar verme kurallarına göre küçük parçalara ayırarak sınıflandırma yapan bir yöntem olarak tanımlanmaktadır.

Karar düğümleri ve yaprak düğümlerinden oluşmakta ve Algoritma genellikle CART (Classification and Regression Trees) yaklaşımını kullanılmaktadır. Bu modelle, Python’un sklearn.tree kütüphanesindeki DecisionTreeClassifier metodu ile çalışmaktadır (Aksu ve Doğan, 2019). Karar Ağaçları, sınıflandırma için kullanılacak kalıpları belirlemek amacıyla sağlanan eğitim verilerini daha küçük parçalara bölen denetlenen bir makine öğrenme algoritması olarak kullanılmaktadır. Duygu Analizi alanındaki önceki çalışmalarda Karar Ağacı algoritması kullanılmıştır.

Bireysel bir ağaç kullanıldığında bulunan ana sorun, yüksek varyansa sahip olma problemidir (yani, bir dizi (rastgele) sayının ortalama değerlerinden ne kadar uzağa yayıldığıyla ilgilidir) ve her bir bireysel ağaç yüksek varyansa sahip olduğundan, bunun bir ağaç topluluğu üzerinde ortalaması alınabilmekte ve böylece genel sınıflandırmanın varyansı azaltılabilmektedir. Rastgele ormanların bir dizi karar ağacı sınıflandırıcısını birleştirerek sınıflandırmayı iyileştirebileceği yer burası olup, eğitim sırasında oluşturulan karar ağaçları, rastgele orman tarafından nihai karar olarak seçilen tüm ağaçlar için çoğunluk kararını belirlemek için kullanılabilir.

Bemidele-Sadiq (2022) vd., The Importance of Decision Tree Analysis on Strategic Management Practice: Evidence from Retail Industries in US, isimli çalışmalarında karar ağacı modelinin hem bireysel hem de

kurumsal karar vericiler için organizasyonlarda önemli bir araç olduğunu ileri sürmüşlerdir. Ayrıca çalışmalarında ABD’de perakende sektörlerinin stratejik yönetiminde karar ağacı analizinin önemli olduğunu, bu bağlamda da analiz sonucunda perakende sektörlerinin kendi işlerinde etkili kararlar almak için karar ağaçlarını kullandıkları sonucuna varmışlardır. Tong ve Tong (2022), “A Novel Financial Risk Early Warning Strategy Based on Decision Tree Algorithm” isimli çalışmalarında bir çok şirketin ekonomik kriz sonunda zarar gördüklerini hatta iflas ettiklerini ve bunun nedeni olarak da işletmelerin finansal kriz öncesi erken uyarı sisteminin olmadığını ileri sürmüşlerdir. İşletmeler için kriz dönemlerinde risklerinin azalması için finansal operasyonlarını izlemek ve takip edecek erken uyarı sistemlerine ihtiyaç vardır. Çalışmanın sonucunda işletmelere ortaya çıkabilecek riskler için erken uyarı sistemi olarak karar ağaçları algoritmasının kullanılabilceği ifade edilmiştir.

4.3.4. K-En Yakın Komşu Algoritması ve Müşteri Segmentasyonu

Hart ve Cover tarafından örnek veri noktasının yer aldığı sınıfın ve buna en yakın komşusunun, k değerine göre belirlendiği sınıflandırma yöntemi olarak önerilmiştir. Algoritmada birbirine benzer olan unsurların yakın olduğu varsayılmaktadır (Cover & Hart, 1967).

Avantajları arasında, kullanılabilirliğinin ve yorumlanmasının kolay olması, analitik izlenilebilir olması, yerel bilgilere uygunluğu, gürültülü eğitim verilerine dirençli olması yer almaktadır (Taşçı ve Onan, 2016). Dezavantajları arasında yüksek bellek alanına ihtiyaç duyması, veri seti arttıkça işlem yükü ve maliyetin artması yer almaktadır.

KNN algoritması ile sınıfı belirsiz olan bir verinin eğitim veri setinde yer alan her bir örneğe olan uzaklığı hesaplanır ve hesaplanan uzaklığa göre veriye ait optimal sınıf bulunur. Optimal sınıfa ait olacak verinin eğitim veri setindeki her bir sınıfa olan uzaklığı hesaplanır ve burada ifade edilen k sayısı sınıfın belirlenmesinde kullanılan en yakın komşu sayısını ifade etmektedir. Burada k değeri 1, 3, 5 gibi tek bir sayı olarak belirlenir. Burada optimal sınıfa ait olacak veri en yakın komşuların dahil olduğu sınıfa göre belirlenir (Dilki ve Başar, 2020).

Bazı firmaların satış hacminde, müşteri ve şube sayılarında meydana gelen artışlar sonucu satışlarını tahmin etmek zorlaşmaktadır. Müşteri çeşitliliğindeki ve sayısındaki artışı yönetmek firmaların stratejik planlamasını ve operasyonel faaliyetlerini uygulamada güçlükler neden olmaktadır. Bu bağlamda, müşteri segmentasyonu ve kişisel pazarlama stratejileri geliştirmek önem kazanmaktadır. Makine öğrenmesi yöntemleri de bu zorluklarla

mücadelede firmalara çözümler üretmektedir. Bir makine öğrenmesi yöntemi olan K-En Yakın komşu algoritması da müşteri segmentasyonu ve satış tahminleme yönteminde kullanılmaktadır (Sinap, 2024).

5. Yapay Zeka ve Makine Öğrenmesi Destekli YBS Uygulamaları

1970'li yıllardan itibaren işletmelerde, yönetim bilgi sistemleri ve finans alanlarında akıllı donanım ve yazılımların faydaları fark edilmeye başlamıştır. İş dünyasında yöneticilerin yapay zekayı ticari kazanç amacıyla kabul etmeleri 1984 yılında Texas Üniversitesi'nde düzenlenen Ulusal Yapay Zeka konferansına dayanmaktadır (Ünal ve Kılınç, 2020).

Günümüzde işletmeler yapay zekâyı çeşitli görevlerin yerine getirilmesinde araç olarak kullanmaktadır. Örneğin şirketlerde işe alınacak adayların doğru pozisyonlara seçilmesi, finansal ürün çeşitliliğinde müşterilere önerilerde bulunma, finansal işlemlerin online platformlardan gerçekleştirilmesi, karmaşık lojistik süreçlerin düzenlenmesi, hastalara teşhis koyma vb. alanlarda yapay zeka kullanılmaktadır (Ünal ve Kılınç, 2020).

Günümüzde yapay zeka yöneticilerin karar verme sürecinde de kullanılmaktadır. Yapay zeka uygulamaları karmaşık durumlarda verileri toplama, düzenleme ve işleyip analiz ederek alternatifler arasından seçim yaparak yöneticilere yardımcı olmaktadır (İnce vd., 2021).

İşletmelerde ortaya çıkan sorunları çözüme görevi yöneticilere aittir. Günümüzde kurumsal sorunların çözümü de yapay zeka destekli akıllı bir bilgi yönetimi platformunu gerektirir. YBS anlamında dijitalleşmeye kapalı olan kuruluşlar rekabet sürecinde başarısız olacaktır. Çünkü yapay zeka ile desteklenmiş YBS süreci işletmelerde hızı artıracak, zaman ve maliyet kaybını en aza indirecektir. Yapay zeka ile desteklenen YBS sayesinde kuruluşlara (Efe, 2021);

- ✓ Belge ve raporlar daha hızlı hazırlanacak ve bunların en güncel sürümüne ulaşım sağlanacaktır,
- ✓ Kaynak tahsisinde etkinliği sağlanacak ve maliyetler optimize edilebilecektir,
- ✓ Kararlar için doğru, kapsamlı veya özet şeklinde tablo ve grafikler üretilebilecektir,
- ✓ Yapılan işler ve üretilen çıktılar izlenebilecektir,
- ✓ Aksamalarda erken uyarı sistemleri hazırlanabilecektir,
- ✓ İdari, teknik veya mali tüm görevlendirmeler takip edilebilecektir.

6. Sonuç

Yapay zeka destekli YBS uygulamaları, kurumlardaki rutin görevleri otomatik hale getirerek yöneticilerin zamanını katma değeri yüksek diğer işlere ayırmalarını sağlamaktadır. Yapay zeka sayesinde veri girişi ve işleme işleri bilgisayarlar aracılığı ile gerçekleştirilmektedir. Bu da rapor hazırlama sürecinde insan müdahalesini azaltmaktadır. Ayrıca yapay zeka sadece veri girişi ve işleme yapmaz aynı zamanda verileri analiz ederek yöneticilere karar alma süreçlerinde yardımcı olmaktadır. Yapay zeka destekli YBS sayesinde işletmeler Pazar tahminleri yapabilir, müşteri ilişkilerini yönetebilir, risk ve finansal durumlarını önceden tahmin edebilir ve stratejik kararlarını verebilirler. Çünkü yapay zeka aracılığı ile geçmişteki veriler sisteme işlenmekte ve makine öğrenme algoritmalarını kullanarak mevcut risklerini tahmin edebilir ve geleceğe dair tahminlerde bulunabilmektedir.

Sonuç olarak yapay zeka YBS üzerinde daha fazla kullanıldıkça veri analiz miktarı artmakta ve yöneticilerin daha optimal kararlar almalarını sağlamaktadır. Aynı zamanda yapay zekanın kullanımı arttıkça veri analiz sürecinde hata olanağı en aza indirilmekte, hızlı ve düşük maliyetli analiz süreci gerçekleşmektedir. Bu sayede de kuruluşlar kaynaklarını daha etkin kullanma olanağına sahip olmaktadır.

Kaynakça

- Akıncı, H., & Kahraman, Ü. (2024). Endüstri 4.0: Yönetim Bilişim Sistemleri Bakış Açısıyla Değerlendirme. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 8(1), 76-99.
- Akpınar, H. (2011). Türkiye’de Enformasyon Sistemleri Öğretiminde 20. Yıl. *Uluslararası 9. Bilgi, Ekonomi ve Yönetim Kongresi Bildirileri*, (s. 565-665).
- Arı, S. (2014). *Üniversitelerde Çalışan Yöneticilerin ve Diğer Personellerin Yönetim Bilişim Sistemleri Hakkındaki Algı ve Dirençlerinin Karşılaştırılması: Selçuk Üniversitesi Örneği*. Konya: Selçuk Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yüksek Lisans Tezi.
- Ayaz, A. (2024). *Yönetim Bilişim Sistemleri Araştırmalarının Evrimi: Konu Modelleme Temelli Bibliyometrik Analiz ve İş Zekası Uygulaması Geliştirme*. Atatürk Üniversitesi SBE Doktora Tezi.
- Aydın, S., & Özkul, A. (2015). Veri Madenciliği ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 36-44.
- Bamidele-Sadiq, M., Popoola, O., Lawal, G. O., & Awodiji, T. O. (2022). The Importance of Decision Tree Analysis on Strategic Management Practice: Evidence from Retail Industries in US. *Journal of Marketing and Consumer Research*, 87, 30-42.
- Bendre, P., Murukate, P., Desai, V., Dhenge, D., & Kelkar, B. (2017). Management Information System. *International Journal of Advance Research and Development*, 2(4), 119-126.
- Berdibek, U., & Kayaoğlu, M. (2023). Yönetim Bilişim Sistemlerinde Yapay Zekanın Rolü. *Uluslararası Sosyal ve Beşeri Bilimler Araştırma Dergisi*, 10(102), 3492-3500.
- Berente, N., Recker, J., Gu, B., & Santhanam, R. (2021). Managing Artificial Intelligence. *MIS quarterly*, 45(3), 1433-1450.
- Boehmer, j. (2021). *Management Information Systems*. Edward Elgar Publishing.
- Coşkun, F., & Gülleroğlu, D. (2021). Yapay Zekanın Tarih İçindeki Gelişimi ve Eğitimde Kullanılması. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, 54(3), 947-966.
- Cover, T., & Hart, P. (1967). Nearest Neighbor Pattern Classification. *IEEE transactions on information theory*, 13(1), 21-27.
- Dalvi, P. K., Khandge, S. K., Deomore, A., Bankar, A., & Kanada, V. A. (2016). Analysis of Customer Churn Prediction in Telecom Industry using Decision Trees and Logistic Regression. *2016 symposium on colossal data analysis and networking (CDAN)* (s. 1-4). IEEE.

- Dilki, G., & Başar, Ö. D. (2020). İşletmelerin İflas Tahmininde K-En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 19(38), 224-233.
- Efe, A. (2021). Yenilikçi Endüstri 4.0 Paradigması Kapsamında Kurumsal Kaynak Planlaması ve Yönetim Bilişim Sistemlerinde Yapay Zekâ. *Pamukkale Üniversitesi İşletme Araştırmaları Dergisi (PIAR)*, 8(1), 186-214.
- Ereken, Ö., & Tarhan, Ç. (2021). İş Başvurularının Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi. *Yönetim Bilişim Sistemleri Dergisi*, 7(2), 65-85.
- Eren Gümüştekin, G. (2004). İşletmelerde Yönetim Bilişim Sistemleri. *Yönetim ve Ekonomi*, 11(1), 125-141.
- Ercut, H. (1989). *Yönetim Bilişim Sistemleri*. İstanbul: M E S S Yayınları.
- Erol, V. (2021). Yönetim Bilişim Sisteminin Bir Örneği Olarak Türkiye'de Elektronik Seçim Sistemi. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Dergisi*, 6(2), 427-440.
- Gündüz, G., & Cedimoğlu, İ. (2019). Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 9-17.
- Gür, Y., Ayden, C., & Yücel, A. (2019). Yapay Zeka Alanındaki Gelişmelerin İnsan Kaynakları Yönetimine Etkisi. *Fırat Üniversitesi İİBF Uluslararası İktisadi ve İdari Bilimler Dergisi*, 3(2), 137-157.
- Hakimpoor, H., & Khairabadi, M. (2018). Management Information Systems, Conceptual Dimensions of Information Quality and Quality of Managerial Decisions: Modelling Artificial Neural Networks. *Universal Journal of Management*, 6(4), 127-133.
- İnce, H., İmamoğlu, S. E., & İmamoğlu, S. Z. (2021). Yapay Zeka Uygulamalarının Karar Verme Üzerine Etkileri: Kavramsal Bir Çalışma. *International Review of Economics and Management*, 9(1), 50-63.
- Kızılkaya, M., & Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*(37), 90-98.
- Köyüm, F., & Atıkan, Y. (2024). Otonom Araçlarda Derin Pekiştirmeli Öğrenme Yöntemleri İle Söllama. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(2), 429-439.
- Kurnia, P. F. (2018). Business Intelligence Model to Analyze Social Media Information. *3rd International Conference on Computer Science and Computational Intelligence*. 135, s. 5-14. Procedia Computer Science.
- Laudon, K., & Laudon, J. (2006). *Management Information Systems: Managing the Digital Firm, 9th Ed.* Englewood Cliffs: Prentice Hall.
- Mishan, M. T., Kushan, A. L., Fadzil, A. A., Amir, A. B., & Anuar, N. B. (tarih yok). An Analysis On Business Intelligence predicting business profitabi-

- lity model using Naive Bayes neural network algorithm. *7th IEEE International Conference on System Engineering and Technology (ICSET 2017)*, (s. 59-64). Malaysia.
- Murdick, R., & Munson, J. C. (1986). *Management Information Systems*. USA: Prentice Hall.
- O'Brien, J. A., & Marakas, G. M. (2007). *Enterprise Information Systems*. New York: The McGraw-Hill.
- Özgen, H., & Yalçın, A. (1992). İşletmelerde Yönetim Bilişim Sistemi ve Yönetim Kararlarında Kullanılması. *Anadolu Üniversitesi İİBF Dergisi*, 10(1-2), 249-264.
- Polat, S. (2017). Yazılım Hata Kayıtlarının Makine Öğrenmesi Yöntemleriyle Kümelenecek, Hataya Sebep Olan Bileşenlerin Tespit Edilmesi. *11. Ulusal Yazılım Mühendisliği Sempozyumu Kitabı* (s. 444-453). Alanya: Atılım ve Alanya Hamdullah Emin Paşa Üniversitesi.
- Power, D., Scheibe, K., & Hadidi, R. (2016). Celebrating 50 Years of Management Information Systems (MIS) Research and Teaching. *Journal of the Association for Information Systems*, 2016(2), 1-6.
- Sinap, V. (2024). Perakende Sektöründe Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Performans Analizi: Black Friday Satış Tahminlemesi. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 27(1), 65-90.
- Şahin, M. (2023, Temmuz). İnsan Kaynakları Alanında Büyük Veri ve Makine Öğrenmesi. İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Şeker, A., Diri, B., & Balık, H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Taşçı, E., & Onan, A. (2016). K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Tong, L., & Tong, G. (2022). A novel financial risk early warning strategy based on decision tree algorithm. *Scientific Programming*, 1-10.
- Türkmenoğlu, C., & Tantıoğlu, A. (2014). Sentiment Analysis in Turkish Media. *ICML 2014 (International Conference on Machine Learning)*. Beijing Volume: Workshop on Issues of Sentiment Discovery and Opinion Mining.
- Ünal, A., & Kılınc, İ. (2020). Yapay Zekâ İşletme Yönetimi İlişkisi Üzerine Bir Değerlendirme. *Yönetim Bilişim Sistemleri Dergisi*, 6(1), 51-78.
- Yakıcı Ayan, & Değirmenci, N. (2018). Firma Finansal Başarısızlık Öngörüsü İçin Bir Lojistik Regresyon Modeli. *Uluslararası İktisadi ve İdari İncelemeler Dergisi* (18. EYİ Özel Sayısı), 77-88.

- Yarlıkaş, S. (2015). Yönetim Bilişim Sistemleri Disiplininin Türkiye'deki Mevcut Durumu Üzerine Bir İnceleme. *Yükseköğretim ve Bilim Dergisi*, 5(2), 136-147.
- Yürek , E. (2024, Şubat 27). *İlge Yapay Zeka*. Şubat 10, 2025 tarihinde ILGE-AI: <https://ilge.com.tr/yari-denetimli-ogrenme--veriyi-etkili-kullanmanin-yolu> adresinden alındı
- Zilyas, D., & Yılmaz, A. (2023). Makine Öğrenmesi Yöntemleri ile Eğitim Başarısının Tahmini Modeli. *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, 14(3), 437-447.
- Zou, X., Hu, Y., Tian, Z., & Shen, K. (2019). Logistic regression model optimization and case analysis. In *2019 IEEE 7th international conference on computer science and network technology (ICCSNT)*, 135-139.

