



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YAPAY ZEKÂ DESTEKLİ MALİYET YÖNETİMİ: İSTATİSTİKSEL VE
MAKİNE ÖĞRENMESİ MODELLERİ İLE BİR İNCELEME**

YÜKSEK LİSANS TEZİ

Senanur İPEK

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Tezli Yüksek Lisans Programı

ŞUBAT 2025

T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKÂ DESTEKLİ MALİYET YÖNETİMİ: İSTATİSTİKSEL VE
MAKİNE ÖĞRENMESİ MODELLERİ İLE BİR İNCELEME

YÜKSEK LİSANS TEZİ

Senanur İPEK
(21435025035)
ORCID: 0009-0006-7560-7482

Endüstri Mühendisliği Anabilim Dalı
Endüstri Mühendisliği Tezli Yüksek Lisans Programı

Danışman: Doç. Dr. Hasan ŞAHİN
ORCID: 0000-0002-8915-000X

ŞUBAT 2025

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 21435025035 numaralı Yüksek Lisans Öğrencisi Senanur İPEK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “YAPAY ZEKÂ DESTEKLİ MALİYET YÖNETİMİ: İSTATİSTİKSEL VE MAKİNE ÖĞRENMESİ MODELLERİ İLE BİR İNCELEME” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Hasan ŞAHİN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Hasan ŞAHİN**
Bursa Teknik Üniversitesi

Dr. Öğr. Üyesi Koray ALTUN
Bursa Teknik Üniversitesi

Doç. Dr. Abdulkadir ATALAN
Çanakkale Onsekiz Mart Üniversitesi

Teslim Tarihi : 13.01.2025

Savunma Tarihi : 11.02.2025



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneliği olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı:

İmzası:





Eşime,

ÖNSÖZ

Yüksek lisans ve tez yazım sürecimde yapmış olduđu desteklerden dolayı değerli danışman hocam Doç. Dr. Hasan ŞAHİN'e ve bu süreçte sabırla yanımda olup benden desteklerini esirgemeyen eşim ve aileme gönülden saygı ve sevgilerimi sunar teşekkür ederim.

Şubat 2025

Senanur İPEK
(Satış ve İş Geliştirme
Uzmanı)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
ÇİZELGE LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xii
SUMMARY	xiv
1. GİRİŞ	1
1.1 Tezin Amacı	3
2. LİTERATÜR ARAŞTIRMASI	5
2.1 Yapay Zekâ ile Tahminleme Alanında Yapılan Çalışmalar.....	5
2.2 Optimizasyon Alanında Yapılan Çalışmalar	10
3. KAVRAMLAR.....	16
3.1 Veri Bilimi.....	16
3.2 Makine Öğrenmesi	18
3.3 Yapay Zekâ	20
3.4 Maliyet Optimizasyonu	22
3.5 Tahminleme.....	23
3.5.1 Kalitatif yöntemler	24
3.5.2 Kantitatif yöntemler	25
3.5.3 Yapay zekâ tabanlı yöntemler.....	25
4. MATERYAL VE METOT	26
4.1 Materyal	26
4.1.1 Eviews 10.0.....	26
4.1.2 IBM SPSS Statistics 30.0.....	27
4.1.3 Knime 5.3.3.....	27
4.2 Metot	28
4.2.1 Model verileri.....	28
4.2.2 Verilerin mevsimsellikten arındırılması.....	30
4.2.3 Çoklu doğrusal regresyon modeli uygulaması.....	31
4.2.3.1 Değişkenlerin normalliği.....	33
4.2.3.2 Bağımlı ve bağımsız değişkenler arası korelasyon	34
4.2.3.3 Çoklu doğrusallık sorunu	35
4.2.3.4 Farkların normalliği	37
4.2.3.5 Otokorelasyon tespiti	39
4.2.3.6 Çoklu doğrusal regresyon modelinin yazılması.....	40
4.2.4 Makine öğrenmesi modellerinin uygulamaları	41
4.2.4.1 Eğitim ve test verilerinin belirlenmesi	42
4.2.4.2 Yapay sinir ağları	43
4.2.4.3 Gradyan arttırımlı regresyon ağaçları uygulaması	45
4.2.4.4 Ortalama mutlak yüzde hata.....	47

5. ANALİZ BULGULARI	48
5.1 Çoklu Doğrusal Regresyon Modeli Bulguları.....	48
5.2 Makine Öğrenmesi Modeli Bulguları	51
5.2.1 Yapay sinir ağları modeli bulguları	51
5.2.2 Gradyan arttırmalı regresyon ağaçları modeli bulguları	53
5.2.3 Makine öğrenmesi modellerinin karşılaştırılması.....	54
6. SONUÇ VE ÖNERİLER	57
KAYNAKLAR	60
ÖZGEÇMİŞ	65



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Bağımlı değişkenlerin genel özellikleri.....	28
Çizelge 4.2 : Bağımsız değişkenlerin genel özellikleri.	29
Çizelge 4.3 : Bağımlı değişkenlerin tanımlayıcı istatistik değerleri.....	32
Çizelge 4.4 : Bağımsız değişkenlerin tanımlayıcı istatistik değerleri.....	32
Çizelge 4.5 : Değişkenlerin çarpıklık ve basıklık değerleri.....	33
Çizelge 4.6 : Pearson Korelasyon testi çıktıları.....	35
Çizelge 4.7 : Varyans Büyütme Faktörü ve Tolerans parametreleri.	36
Çizelge 4.8 : Değişkenlerin Korelasyon katsayıları.	37
Çizelge 4.9 : Veri bölümlere modülleri ve detayları.	43
Çizelge 4.10 : Yapay sinir ağları parametre gösterimi.	44
Çizelge 4.11 : GBRT parametre gösterimi.	46
Çizelge 5.1 : X satış miktarı çoklu doğrusal regresyon modeline ait özet veriler.	48
Çizelge 5.2 : X satış miktarı çoklu doğrusal regresyon modeline ait varyans analizi.	49
Çizelge 5.3 : X maliyeti çoklu doğrusal regresyon modeline ait özet veriler.....	50
Çizelge 5.4 : X maliyeti çoklu doğrusal regresyon modeline ait varyans analizi.....	50
Çizelge 5.5 : Rastgele veri seçimi ile oluşturulan YSA model çıktıları.....	52
Çizelge 5.6 : Sıralı veri seçimi ile oluşturulan YSA model çıktıları.	52
Çizelge 5.7 : Rastgele veri seçimi ile oluşturulan GBRT model çıktıları.	53
Çizelge 5.8 : Sıralı veri seçimi ile oluşturulan GBRT model çıktıları.....	54
Çizelge 5.9 : Rastgele veri seçimi ile X maliyeti için oluşturulan model çıktıları. ...	55
Çizelge 5.10 : Sıralı veri seçimi ile X maliyeti için oluşturulan model çıktıları.	55
Çizelge 6.1 : Bağımlı değişkenlerin en iyi sonuç veren tahmin modelleri.	58

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1 : Makine öğrenmesi algoritmaları (Olgun, 2020).....	20
Şekil 3.2 : Tahmin teknikleri (Url-2).....	24
Şekil 4.1 : X satış miktarı verilerine ait mevsimsellikten arındırma grafiği.....	31
Şekil 4.2 : Standartlaştırılmış tahmin ve artık değerlerinin histogram dağılımı.....	38
Şekil 4.3 : Standartlaştırılmış tahmin ve artık değerlerinin Normal P-P grafiği.	39
Şekil 4.4 : Normalizer düğümü gerçekleştirilen ayarları.....	41
Şekil 4.5 : MLP yönetiminin Knime programı üzerinde modellenmesi.....	45
Şekil 4.6 : GBRT yönetiminin Knime programı üzerinde modellenmesi.	47

YAPAY ZEKÂ DESTEKLİ MALİYET YÖNETİMİ: İSTATİSTİKSEL VE MAKİNE ÖĞRENMESİ MODELLERİ İLE BİR İNCELEME

ÖZET

Günümüz iş dünyası, teknolojik gelişmelerin ve küreselleşmenin etkisiyle sürekli bir dönüşüm içerisindedir. Özellikle üretim sektöründe artan rekabet, işletmeleri maliyetlerini düşürmek, kaynaklarını daha verimli kullanmak ve müşteri taleplerine hızla uyum sağlamak için yeni yöntemler benimsemeye zorlanmaktadır. Geleneksel yönetim ve üretim planlama yaklaşımlarının bu karmaşık ve dinamik ortamda tüm ihtiyaçların aynı anda karşılanması hususunda yetersiz kalabileceği düşünülmektedir. Bu bağlamda, yapay zekâ ve veri analitiği gibi modern yöntemler, işletmelerin hem maliyetlerini optimize etmesine hem de operasyonel verimliliklerini artırmasına olanak tanımaktadır.

Bu tez, yapay zekâ destekli veri analitiği ve maliyet optimizasyonunun entegrasyonunu incelemektedir. Çalışma, otomotiv sanayisinde kullanılan X ürününün satış ve maliyet tahminleri için çoklu doğrusal regresyon ve makine öğrenmesi modelleri kullanarak, her iki yöntem arasındaki farkları analiz etmiş ve belirli değişkenlerin satış ve maliyet tahminlerinde ne derece etkili olduğunu ortaya koymuştur. Elde edilen bulgular, yapay zekâ ve veri analitiği teknolojilerinin işletmelerin maliyet optimizasyonu süreçlerinde nasıl etkin bir şekilde kullanılabileceğini göstermektedir.

Çoklu doğrusal regresyon modelinde yapılan analizler, satış miktarları üzerinde etkili olan bağımsız değişkenleri belirlemiştir. Bu değişkenler arasında Motorlu Kara Taşıt Sayısı (MKTS), Sanayi Üretim Endeksi (SÜE), Tüketici Fiyatlarının Değişimine İlişkin Düşünce (TFDD) ve Ücretlerin Değişimine İlişkin Beklenti (ÜDİB) yer almaktadır. Satış miktarlarına ilişkin modelin Düzenlenmiş R^2 değeri 0,916 olup, bu da modelin satış miktarlarını yüksek bir doğrulukla açıklayabildiğini göstermektedir. Öte yandan, maliyet tahminlerine yönelik modelin Düzenlenmiş R^2 değeri 0,974 olarak hesaplanmış ve bu da modelin maliyet tahmininde oldukça güçlü bir açıklayıcılığa sahip olduğunu ortaya koymuştur. Elde edilen sonuçlar, satış ve maliyet tahminlerinde belirli değişkenlerin kritik bir rol oynadığını ve işletmelerin bu değişkenlere dikkat etmelerinin önemli olduğunu vurgulamaktadır.

Gradyan Arttırımlı Regresyon Ağaçları (GBRT) ve yapay sinir ağları (YSA) modelleri ile yapılan analizlerde, her iki bağımlı değişken için en iyi performans YSA modellerinden elde edilmiştir. YSA modelleri, doğrusal olmayan ilişkileri daha başarılı bir şekilde modelleyerek daha doğru tahminler sunmuş ve geleneksel istatistiksel yöntemlere kıyasla daha düşük hata oranları ve daha yüksek doğruluk oranlarına ulaşmıştır. Özellikle, X ürünü satış adetleri için yapılan analizde R^2 değeri 0,98 ve Ortalama Mutlak Yüzde Hata (MAPE) değeri 0,08 olarak hesaplanırken, maliyetler için R^2 değeri 0,997 ve MAPE değeri 0,02 olarak belirlenmiştir.

Çoklu doğrusal regresyon modeli sonucunda raporlanan değerler ise, X ürünü satış adetleri için yapılan analizde düzenlenmiş R^2 değeri 0,916 ve X ürünü maliyetleri için yapılan analizde de düzenlenmiş R^2 değeri 0,974'tür. Bu bulgular karşılaştırıldığında, makine öğrenmesi modellerinin geleneksel istatistiksel yöntemlere göre daha güçlü tahminler sunduğunu ve işletmelerin karar alma süreçlerine daha fazla katkı sağladığını göstermektedir.

Sonuçlar, MKTS ve SÜE gibi değişkenlerin satış ve maliyet tahminleri üzerinde önemli etkiler oluşturduğunu ortaya koymuştur. Bu bağlamda, işletmelerin üretim ve maliyet planlamalarında bu değişkenleri düzenli olarak takip etmeleri, daha doğru ve verimli stratejiler geliştirmelerine yardımcı olacaktır.

Sonuç olarak, bu tez hem geleneksel istatistiksel yöntemlerin hem de modern makine öğrenmesi yaklaşımlarının maliyet optimizasyonu süreçlerinde nasıl etkin bir şekilde kullanılabileceğini göstermiştir. Yapay zekâ ve makine öğrenmesi tabanlı modellerin, üretim ve maliyet planlamalarında daha güvenilir tahminler sağladığı ve işletmelerin stratejik karar alma süreçlerine katkı sağladığı ortaya çıkmıştır. Elde edilen bulgular, işletmelerin daha doğru tahminler yapabilmesine ve verimli planlamalar gerçekleştirerek rekabet avantajı elde etmelerine yardımcı olacaktır.

Anahtar kelimeler: Çoklu doğrusal regresyon, Maliyet optimizasyonu, Veri analitiği, Yapay zekâ

ARTIFICIAL INTELLIGENCE-SUPPORTED COST MANAGEMENT: AN ANALYSIS WITH STATISTICAL AND MACHINE LEARNING MODELS

SUMMARY

The modern business world is undergoing continuous transformation due to technological advancements and globalization. Increasing competition, particularly in the manufacturing sector, compels businesses to adopt new methods to reduce costs, utilize resources more efficiently, and quickly adapt to customer demands. Traditional management and production planning approaches may be insufficient in simultaneously addressing all these complex and dynamic needs. In this context, modern methods such as artificial intelligence and data analytics enable businesses to optimize costs while enhancing operational efficiency.

This thesis examines the integration of AI-supported data analytics and cost optimization. The study analyzes the differences between multiple linear regression and machine learning models for sales and cost forecasting of the X product used in the automotive industry. It also explores how specific variables influence sales and cost predictions. The findings demonstrate how artificial intelligence and data analytics technologies ca

The multiple linear regression analysis identified key independent variables affecting sales volumes, including the Number of Motor Vehicles (NMV), the Industrial Production Index (IPI), Consumer Price Expectation (CPE), and Wage Change Expectation (WCE). The Adjusted R^2 value of the sales volume model was 0.916, indicating high accuracy in explaining sales quantities. Meanwhile, the Adjusted R^2 value for the cost estimation model was calculated as 0.974, demonstrating its strong explanatory power. These results emphasize the critical role of certain variables in sales and cost predictions and highlight the importance of businesses monitoring these factors closely.

Further analyses using Gradient Boosted Regression Trees (GBRT) and Artificial Neural Networks (ANN) showed that ANN models provided the best performance for both dependent variables. ANN models successfully captured nonlinear relationships, yielding more accurate predictions with lower error rates and higher precision than traditional statistical methods. Specifically, the R^2 value for X product sales forecasts was 0.98, with a Mean Absolute Percentage Error (MAPE) of 0.08, while for cost forecasts, the R^2 value was 0.997, with a MAPE of 0.02.

The multiple linear regression model results reported an Adjusted R^2 value of 0.916 for X product sales and 0.974 for X product costs. When comparing these findings, machine learning models demonstrated superior predictive capabilities over traditional statistical methods, contributing more effectively to business decision-making processes.

The results revealed that NMV and IPI significantly impact sales and cost forecasts. In this regard, businesses should regularly monitor these variables in their production and cost planning to develop more accurate and efficient strategies.

In conclusion, this thesis demonstrates how both traditional statistical methods and modern machine learning approaches can be effectively utilized in cost optimization processes. AI and machine learning-based models provide more reliable predictions, supporting businesses' strategic decision-making processes. The findings help companies to make more accurate forecasts, enabling efficient planning and gaining a competitive advantage.

Keywords: Artificial intelligence, Cost optimization, Data analytics, Multiple linear regression



1. GİRİŞ

Günümüzde işletmeler daha rekabetçi ve sürdürülebilir olmayı hedefleyerek, gelir artışı, maliyetleri azaltma ve yeni değer yaratma yoluyla kârlılığını artırmak için yeni fırsatlar keşfetmektedirler (Stancheva-Todorova, 2018). İş dünyası kuralları, hızla değişen teknoloji ve küreselleşmenin etkisiyle sürekli bir dönüşüm içerisinde olup, işletmeleri daha yenilikçi ve verimli stratejiler benimsemeye zorlamaktadır. Özellikle endüstriyel ortamda artan rekabet, işletmeleri maliyetlerini azaltma, kaynaklarını daha etkin kullanma ve müşteri taleplerine daha hızlı yanıt verme konusunda büyük bir baskı altına almıştır.

Her işletme, kaynaklarını daha verimli kullanmak ve kârlılığını artırmak için maliyetlerini optimize etmek ister. Ürünleri veya hizmetleri son kullanıcıya ulaştıracaya kadar sarf edilen değerleri talep edilen kalite ölçüsünden ödün vermeden, işletmenin elindeki kaynakları en rasyonel bir biçimde kullanarak bir sistem dâhilinde maliyetlerin işletme tarafından en verimli yapıya getirilmesini maliyet optimizasyonu olarak tanımlanabilmektedir (Gökırmak, 2006). Daha düşük maliyetlerle üretim yapmak, işletmenin fiyat rekabetine uyum sağlamasına ve piyasadaki rekabet gücünü artırmasına olanak tanır. Bu hem kısa vadeli finansal başarı hem de uzun vadeli sürdürülebilirlik açısından kritik bir unsurdur.

Maliyetlerini optimize eden bir işletme, kaynaklarını israf etmeden doğru alanlara yönlendirebilmektedir. Bu yönlendirme, işletme içerisinde gerçekleştirilen optimizasyonların bütün süreçlerde aşamalı olarak iyileştirmeler sağlayabileceğini düşündürmektedir. Kaynak yönlendirmeleri, üretim süreçlerinden lojistiğe, pazarlama bütçesinden insan kaynaklarına kadar geniş bir alanda etkinlik sağlar.

Diğer bir fayda olarak, maliyet optimizasyonu işletmelere kriz dönemlerinde daha dayanıklı olma avantajı sunar. Ekonomik dalgalanmalar ya da talep düşüşü gibi durumlarda düşük maliyetli bir yapıya sahip olmak, işletmenin ayakta kalmasını ve rekabet gücünü korumasını sağlar.

Geleneksel yöntemler, üretim kapasitesi, iş gücü, malzeme tedarik zinciri, stok seviyeleri ve müşteri taleplerindeki dalgalanmalar gibi birçok değişkeni etkili bir şekilde ele almakta zorluk yaşamaktadır. Bu durum, yalnızca işletmelerin performansını olumsuz etkilemekle kalmayıp, aynı zamanda yüksek maliyetlere ve operasyonel verimsizliklere neden olmaktadır.

Yapay zekâ ve veri analitiği gibi modern teknolojik yaklaşımlar, işletmelere önemli fırsatlar sunmaktadır. Yapay zekâ, gelişmiş öğrenme algoritmaları sayesinde üretim süreçlerini optimize etme, kaynakları daha etkin kullanma ve üretim planlamasında esneklik sağlama konularında verimli sonuçlar elde etmeyi sağlamaktadır.

Veri analitiği, büyük veri setlerini işleyerek işletmelere maliyet optimizasyonu, tedarik zinciri yönetimi ve operasyonel süreçlerde yeni fırsatlar sunmaktadır. Büyük verinin analizi, geçmiş verilere dayanarak gelecekteki eğilimlerin tahmin edilmesine olanak tanımakta, böylece işletmelerin stratejik karar alma süreçlerini desteklemektedir (Yıldız, 2022).

Bu tez, yapay zekâ destekli veri analitiği ile maliyet optimizasyonunun gerçekleştirilmesini merkeze alarak, işletmelerin bu teknolojik yeniliklerden nasıl yararlanabileceğini araştırmayı amaçlamaktadır. Tezde, optimizasyon çalışmalarında yapay zekâ ve veri analitiğinin uygulanabilirliği incelenerek, işletmelerin rekabet avantajı elde etmesi için gerekli stratejik ve operasyonel öneriler sunulmaktadır. Bu çerçevede, yapay zekâ tabanlı kurulan modellerin yalnızca maliyetleri düşürmekle kalmayıp, aynı zamanda esneklik ve verimlilik kazandırdığı vurgulanmaktadır. Veri analitiğinin işletmelerin geçmişten ders çıkarmasına, mevcut süreçlerini optimize etmesine ve gelecekteki olası senaryoları öngörmesine yardımcı olduğu ortaya konulmaktadır.

Çalışmanın ilk bölümünde, dünyada ve Türkiye'de yapay zekâ desteği ile gerçekleştirilen maliyet optimizasyonu süreçlerine yönelik yapılan araştırmalar incelenmiştir. Bu kapsamda, yapay zekâ tabanlı üretim planlama, veri analitiği teknikleri, klasik istatistiksel yöntemler ve optimizasyon modellerini içeren çalışmalar literatür taraması adına değerlendirilmiştir.

İkinci bölümde, dünyada ve Türkiye'de maliyet optimizasyonunun işletmeler için stratejik önemi ele alınmıştır.

Üçüncü bölümde, çalışmada kullanılan yöntemler açıklanmaktadır. Kullanılan yöntemler arasında veri analitiği teknikleri ve YSA ve GBRT gibi makine öğrenmesi modelleri bulunmaktadır.

Dördüncü bölümde, belirlenen veri seti ile bahsedilen yöntemler kullanılarak üretim süreçleri için maliyet optimizasyonu modeline ait uygulama gerçekleştirilmiştir. Bu uygulamada elde edilen sonuçlar karşılaştırmalı olarak analiz edilmiştir.

Beşinci bölümde ise çeşitli yöntemler ile uygulaması gerçekleştirilen analizlerin analiz bulguları ifade edilmiş ve bu bulgular açıklanmıştır.

Son bölümde ise çalışma bulguları tartışılmış, modelin işletmelere sağladığı faydalar ve sınırlılıklar değerlendirilmiş, gelecekte yapılabilecek çalışmalar için öneriler sunulmuştur.

1.1 Tezin Amacı

Günümüzde, iş dünyası sürekli bir değişim ve rekabet ortamı içerisinde evrim geçirmektedir. Bu dinamik ortamda başarılı bir şekilde faaliyet göstermek isteyen işletmeler için inovasyon ve verimlilik temel unsurlar haline gelmiştir. Bu bağlamda, çalışma içeriği ile özdeşleşen yapay zekâ ve veri analitiği gibi çağdaş yönetim stratejileri, işletmelerin sürdürülebilirlik, rekabet avantajı ve kârlılık hedeflerine ulaşmalarında kritik bir rol oynamaktadır.

Bu tez, yapay zekâ destekli veri analitiğini maliyet optimizasyonu ile bütünleştirerek işletmelerin bu teknolojik çözümlerle daha rekabetçi, esnek ve sürdürülebilir bir konuma ulaşmalarını amaçlamaktadır. Yapay zekâ, gelişmiş öğrenme algoritmalarıyla maliyet tahmin süreçlerini daha hızlı ve esnek hale getirerek, talep değişimlerine anında uyum sağlama yeteneği sunmaktadır. Veri analitiği ise işletmelerin büyük veri setlerini anlamlı bilgilerle donatarak, maliyet optimizasyonu ve kaynakların verimli kullanımı konularında önemli bir perspektif kazandırmaktadır.

Yapay zekâ, öğrenme algoritmaları ve tahminleme modelleri kullanarak, maliyet tahmin süreçlerinde daha etkili ve adaptif kararlar almayı hedefler. Yapay zekâ öğrenme algoritmaları geçmiş maliyet verileri ile bir öğrenme modeli oluşturmaktadır. Tahminleme modeli ile oluşturulan öğrenme modelinin verilerini kullanarak bir tahminleme gerçekleştirilmektedir. Bu sayede, maliyetlere ait geçmiş veriler gelecek verilere ışık tutmaktadır.

Veri analitiđi, iřletmenin sahip olduđu veri setlerini analiz ederek anlam ıkarmayı amalamaktadır. Bu tez, veri analitiđi aralarını kullanarak iřletmenin gemiř maliyet verileri ile maliyet yapısını detaylı bir řekilde incelemektedir. Analiz sonucu kaynakların kullanımını optimize eden bir model sunulmaktadır. Bu durum, iřletmenin maliyet etkinliđini artırarak rekabet avantajı sađlamasına olanak tanımayı amalamaktadır.

Tez, yapay zekâ destekli veri analitiđi ile maliyet optimizasyonunu birleřtirerek, bu yntemlerin birlikte kullanılmasının iřletmenin genel performansına nasıl katkı sađlayabileceđini arařtırmaktadır. Bu btnleřmiř model, iř srelerindeki etkinlik artıřını, maliyetlerin kontroln ve rekabet avantajının srdrlebilirliđini hedeflemektedir. Bahsedilen detaylar, tezin temel amacını ve bu amaca ulařmak iin kullanılacak stratejiyi daha aık bir řekilde ortaya koymaktadır.

Sonuç olarak, hızla deđiřen endstriyel ve rekabeti ortamda, yapay zekâ ve veri analitiđi destekli zmler, iřletmelerin srdrlebilirlik, kârlılık ve rekabet avantajı hedeflerine ulařmalarında kilit bir rol oynamaktadır. Bu tez, bahsedilen modern ynetim yaklařımlarının, iřletmelere karřılařtıkları zorluklara yeniliki ve etkili zmler sunarak katkı sađlayacađını ortaya koymaktadır.

2. LİTERATÜR ARAŞTIRMASI

2.1 Yapay Zekâ ile Tahminleme Alanında Yapılan Çalışmalar

Makine öğrenmesi ile tahmin gerçekleştirmek, geleneksel yöntemlere kıyasla bir dizi önemli avantaj sunar. En büyük artılarından biri, büyük ve karmaşık veri setlerini analiz ederek insanın fark edemeyeceği örüntüleri ve ilişkileri ortaya çıkarabilmesidir. Bu, özellikle dinamik ve hızlı değişen sektörlerde daha doğru ve zamanında tahminler yapılmasını sağlar. Ayrıca, makine öğrenmesi modellerinin veri miktarı arttıkça kendini geliştirdiği ve tahmin doğruluğunu artırdığı bilinmektedir. İnsan hatasını minimize etmesi, manuel analiz sürecini hızlandırması ve otomasyon imkânı sunması da işletmeler için ciddi bir maliyet ve zaman tasarrufu sağlar. Böylece makine öğrenmesi, stratejik karar alma süreçlerini desteklerken, rekabet avantajı elde edilmesine de katkıda bulunur.

Yapay zekâ, Endüstri 4.0'ın etkisiyle yeni nesil fabrikalar ve üretim yöntemlerinin gelişimine katkı sağlayarak giderek daha fazla ilgi görmektedir (Gür ve diğ., 2019; Okan Gökten, 2018). Bu teknolojiler, kalite ve verimliliği artırmak amacıyla hem üretim hem de hizmet sektörlerinde yaygın bir şekilde kullanılmaktadır (Lee ve ark., 2019). Ayrıca, sürdürülebilir kalkınmanın sağlanmasında da yapay zekânın kritik bir rol üstlendiği belirtilmektedir (Buchmeister ve diğ., 2019). Akıllı üretim süreçlerini destekleyen bu teknoloji, yeni sistem tasarımlarının, modellerin ve teknolojik araçların geliştirilmesini kolaylaştırmaktadır (Li ve diğ., 2017). Enerji ve kaynak kullanımı açısından verimli bir üretim modeli sunan yapay zekâ, sanayi şirketlerinin ekonomik faaliyetlerini sürdürmesi ve rekabet gücünü koruması açısından da önemli bir unsur olarak değerlendirilmektedir (Buchmeister ve diğ., 2019).

Şimşek Can (2021) tarafından yapılan çalışmada, ürün ağaçlarındaki değişimlerin ürün maliyetine olan etkilerini tahmin edebilecek bir yapay sinir ağı modeli geliştirilmiştir. Bu çalışmada, yapay zekâ kullanımının giderek yaygınlaştığı havacılık sektöründe, ürün maliyet tahmini ile ilgili elde edilebilecek sonuçlar incelenmiştir. Araştırmanın sonunda, gerçekleşen maliyet ile tahmini maliyet arasındaki hata oranları

analiz edilerek geliştirilen modelin, maliyet tahmininde etkili bir yöntem olarak kullanılabileceği sonucuna ulaşılmıştır (Şimşek Can, 2021).

Kaya ve toprak dolgu barajlarının inşaat projelerinde maliyet tahminlerinin doğruluğu, projenin tipine, kullanılan malzemelerin miktarına ve türüne bağlı olarak önemli belirsizlikler içermektedir. Bu belirsizlikler, yaklaşık maliyet hesaplamalarının uzun süre almasına neden olmakta ve hem teklif veren firmalar hem de işi alan yükleniciler için riskler oluşturabilmektedir. Yükleniciler, hatalı fiyat teklifleri nedeniyle zarara uğrayabilmekte ve projeler yarıda kalabilmektedir (Şimşek Can, 2021).

Genç (2022) tarafından gerçekleştirilen çalışmada, 2011 ve 2020 yılları arasında 4734 sayılı Kamu İhale Kanunu (KİK) kapsamında ihalesi yapılmış ve sonuçları ilan edilmiş 114 baraj ve gölet projesi incelenmiştir. Bu projelerden elde edilen verilerle yaklaşık maliyet için önemli iş kalemleri belirlenmiş ve fiyatlar 2020 yılı aralık ayına göre güncellenmiştir. Farklı yaklaşım modelleri oluşturulmuş ve bu modeller, Gri Kurt Algoritması kullanılarak test edilmiştir. Sonuç olarak, KİK kapsamında baraj projelerinde az veri bulunan durumlarda, matematiksel modeller kullanılarak hızlı ve yüksek doğruluk oranında maliyet tahminleri yapılabileceği ortaya konulmuştur (Genç, 2022).

Yazılım maliyet tahmini, bir yazılım mühendisliği projesi için gerekli kaynakların önceden tahmin edilmesini sağlayan bir süreçtir. Ancak, yazılım projelerinde maliyet tahminleri genellikle zor ve karmaşık olmaktadır. Bu zorluklar, projenin özgün özelliklerinden, bilgi eksikliklerinden ve maliyet analizlerindeki hatalardan kaynaklanmaktadır. Bu nedenle, doğru yazılım maliyet tahmini, projelerin zamanında tamamlanması ve bütçe aşımının önlenmesi için kritik öneme sahiptir. Gelişen yazılım teknolojileri ve değişken senaryolar, efor tahminlerini daha da zorlaştırmakta ve bu doğruluğun yazılım şirketlerinin rekabet gücü üzerinde doğrudan etkisi bulunmaktadır. Bu bağlamda, doğru tahminler, yazılım projelerinin etkili yönetimi ve verimli gelişimi için önemlidir (Genç, 2022).

Gültekin (2019) tarafından gerçekleştirilen doktora tez çalışmasında, yazılım maliyet tahminini iyileştirmek amacıyla üç farklı model geliştirilmiştir. İlk model, regresyon tabanlı bir yaklaşımla yazılım maliyetini tahmin etmek için Cocomo81, Cocomonasa ve Cocomonasa2 veri setlerini kullanmış ve çeşitli regresyon yöntemleri ile modelin başarısı test edilmiştir. İkinci modelde, YSA kullanılarak yazılım maliyeti tahmin

edilmiştir ve veri setlerinin özelliklerine göre yeni bir yaklaşım benimsenmiştir. Üçüncü modelde ise, makine öğrenme algoritmaları ve Scrum metodolojisi dikkate alınarak yazılım maliyet tahmini gerçekleştirilmiştir. Bu modelde, Destek Karar Regresyonu, Gradyan Artırma, Rastgele Orman ve Çok Katmanlı Perseptron gibi regresyon tabanlı algoritmalar kullanılmıştır. Sonuç olarak, bu tez, yazılım maliyeti tahminine yönelik bütüncül bir yaklaşım sunarak, yazılım geliştiricilerin ve karar vericilerin daha doğru tahminler yapmalarına yardımcı olmayı amaçlamaktadır (Gültekin, 2019).

Olgun (2009) tarafından gerçekleştirilen çalışmada, tedarik zinciri yönetiminde talep yönetiminin önemine dikkat çekilmiş ve talep tahminine yönelik farklı yöntemler analiz edilmiştir. Araştırmada, kalitatif, kantitatif ve yapay zekâ tabanlı yöntemlere odaklanılmış, bu yaklaşımların başarılarını etkileyen kritik unsurlar ele alınmıştır. Özellikle yapay zekâ temelli talep tahmin yöntemlerinden biri olan YSA detaylı bir şekilde incelenmiş ve belirli bir uygulama probleminde performansı değerlendirilmiştir. Bu çalışma, yapay zekâ destekli talep tahmin modellerinin tedarik zinciri yönetiminde etkin kullanım potansiyelini ortaya koymaktadır (Olgun, 2009).

Turizm sektörü, dünya genelinde hızla büyüyen ve ülkeler üzerinde önemli ekonomik etkiler yaratan bir alandır. Seyahat ve turizm, küreselleşme ve teknolojik yeniliklerin etkisiyle hızla gelişmekte ve büyüme potansiyelini sürekli artırmaktadır. Ancak, Türkiye, yabancı turist sayısı açısından üst sıralarda yer almasına rağmen, turizm gelirleri bakımından dünya ortalamasının gerisinde kalmaktadır. Bu durum, turizm performansını değerlendirmek için genellikle kullanılan ziyaretçi sayısına ek olarak, turizm gelirlerinin daha fazla önem verilmesi gereken bir gösterge olduğunu ortaya koymaktadır (Olgun, 2009).

Güler (2021) tarafından gerçekleştirilen çalışma içerisinde, 2003-2019 yılları arasındaki çeyrek dönem verileri kullanılarak Türkiye'nin turizm gelirine etki eden 20 farklı faktör incelenmiştir. Bu faktörler arasında ekonomi, turizm altyapısı, özgürlük, güvenlik ve kalkınmışlık seviyesi gibi geniş kapsamlı unsurlar yer almıştır. Araştırmada, birim kök ve eş bütünleşme analizleri temel alınarak çoklu doğrusal regresyon modeli, esnek geri yayılım algoritmasına sahip çok katmanlı YSA modeli ve GBRT modeli karşılaştırılmıştır. Bulgular, turizm gelirlerini etkileyen önemli unsurlar arasında küresel terör endeksi ve uluslararası uçuş trafiğinin öne çıktığını

göstermiştir. Ayrıca, en iyi tahmin performansının, klasik istatistiksel yöntemlere kıyasla YSA modeliyle elde edildiği tespit edilmiştir (Güler, 2021).

Tang ve diğ. (2019) Çin'in önde gelen limanları Lianyungang ve Şanghai'nin konteyner üretim hacmini tahmin etmek amacıyla kapsamlı bir çalışma gerçekleştirmiştir. Bu çalışmada, konteyner kapasitesini etkileyebilecek ekonomik, ticari ve endüstriyel faktörler detaylı bir şekilde incelenmiştir. Ele alınan faktörler arasında tüketim mallarının toplam perakende satışları, yerel şehirlerin gayri safi yurtiçi hasılası (GSYH), ithalat ve ihracat ticaret hacmi, ikinci sanayinin toplam çıktı değeri ve toplam duran varlık yatırımları yer almaktadır. 1990-2011 dönemine ait veriler model oluşturmak için kullanılırken, 2012-2017 dönemine ait veriler bu modellerin performansını değerlendirmek amacıyla seçilmiştir. Araştırmada Gri Model, Üçlü Üstel Düzeltme, Çoklu Doğrusal Regresyon ve Geri Yayılım Sinir Ağı modelleri karşılaştırılmıştır. 2018-2020 yıllarını kapsayan tahminlerde, Geri Yayılım Sinir Ağı Modeli'nin her iki limanda da en doğru sonuçları sağladığı tespit edilmiştir. Bu durum, yapay zekâ tabanlı yöntemlerin tahmin süreçlerindeki başarısını bir kez daha ortaya koymaktadır (Tang ve diğ., 2019).

Finansal piyasalarda YSA'nın kullanımı, özellikle döviz ve altın fiyatlarının tahmini gibi kritik alanlarda giderek yaygınlaşmaktadır. Döviz kurları ve altın fiyatlarının doğru tahmini, bankalar, işletmeler ve finans kuruluşları için büyük bir önem taşımaktadır (Güler, 2019). Güler (2019) tarafından gerçekleştirilen çalışmada, altın ve döviz fiyatlarındaki dalgalanmaların yapay zekâ sistemleri kullanılarak öngörülmesi ve bu tahminlerin ekonomik kriz öngörüsü için değerlendirilmesi hedeflenmiştir.

Dolar/TL kur tahmini için 2006-2018 yılları arasındaki aylık verilere ek olarak BIST100 endeksi, Amerika ve Türkiye enflasyon verileri, faiz oranları gibi dış etmenler bağımsız değişken olarak modele dahil edilmiştir. Altın fiyatları tahmini ise 2000-2018 yılları arasındaki aylık verilerle gerçekleştirilmiş ve dolar/TL kuru, BIST100 endeksi, gümüş fiyatları ve Amerika enflasyon verileri gibi dış faktörler kullanılmıştır. Ayrıca, kriz öngörüsü için yıllık verilere dayalı bir model oluşturulmuş, Türkiye enflasyon oranları, ithalat verileri ve faiz oranları gibi bağımsız değişkenler değerlendirilmiştir. Bu kapsamlı analiz, yapay zekâ tabanlı yaklaşımların ekonomik dalgalanmaların ve krizlerin öngörüsündeki potansiyelini ortaya koymaktadır (Güler, 2019).

Özcan ve diğ. (2023) tarafından gerçekleştirilen çalışma sırasında, banka müşterilerine ait bir veri seti üzerinde makine öğrenmesi teknikleri kullanılarak müşteri kaybı tahmini yapılmıştır. Çalışmada kullanılan yöntemler arasında Rastgele Orman, Karar Ağacı, Gauss, K-En Yakın Komşu, Adaboost ve Lojistik Regresyon algoritmaları yer almaktadır. Modellerin performansını doğru bir şekilde karşılaştırabilmek ve en iyi sonuçları elde edebilmek için, her bir model üzerinde hiper parametre optimizasyonu yapılmıştır. Araştırma sonuçlarına göre, Rastgele Orman algoritması, diğer yöntemlere kıyasla daha başarılı performans sergilemiştir (Özcan ve diğ., 2023).

Son yıllarda artan enerji talebi, fosil yakıtların tükenmesi ve çevre kirliliğine karşı duyarlılığın yükselmesiyle birlikte yenilenebilir enerji kaynaklarına olan gereksinim hızla artmaktadır. Özellikle güneş enerjisi, bu süreçte dikkat çeken bir yükseliş göstermiştir (Somuncu, 2024). Somuncu (2024) tarafından gerçekleştirilen çalışmada, güneş enerji santralının üretim verilerinin meteorolojik verilere dayalı olarak tahmin edilmesi hedeflenmiştir. Bu amaç doğrultusunda, çok katmanlı yapay sinir ağları (ÇKYSA) ve uyarlamalı bulanık yapay sinir ağı çıkarım sistemi (ANFIS) gibi yapay zekâ teknikleri kullanılmıştır

Somuncu (2024), çalışmasında ÇKYSA metodu ile yapılan tahminlerde en başarılı sonucun Levenberg-Marquardt (trainlm) algoritması kullanılarak elde edildiğini anlatmaktadır. ANFIS metodunda ise en yüksek başarı, melez algoritma ve gbellmf üyelik fonksiyonu tipi ile 4-4-4 üyelik fonksiyonlarının bir arada kullanıldığı model ile sağlanmıştır. ÇKYSA ve ANFIS modelleri ile yapılan tahminlerin sonuçları, ölçülen verilerle karşılaştırıldığında, makul düzeyde yakınsama gösterdiği ve tahminlerin güvenilir olduğu gözlemlenmiştir. Bu sonuçlar, enerji üretim verilerinin benzer yöntemlerle hesaplanabileceğini ve santrallerin üretim tahminlerinde kullanılabilirliğini ortaya koymaktadır (Somuncu, 2024).

Güneş paneli teknolojisi, sürdürülebilir ve temiz enerji üretimini destekleyen önemli bir alan olup, güneş enerjisini elektrik enerjisine dönüştürme sürecinde yüksek verimlilik sağlar. Bu alanda yapay zekâ, enerji yönetimi, veri analizi ve panel verimliliği optimizasyonu gibi çeşitli işlevlerde önemli bir rol oynamaktadır. Yapay zekâ uygulamaları ile güneş paneli sistemlerinin verimliliği artırılabilir ve enerji üretimi daha verimli hale getirilebilmektedir (Özer ve Aksoy, 2024). Özer ve Aksoy (2024) tarafından yayınlanan makale, sensörler aracılığıyla toplanan verileri kullanarak güneş panellerinin gerçek performansını yapay zekâ tabanlı tahminlerle

karşılaştırmayı ve makine öğrenmesi yöntemleriyle en uygun güneş paneli kurulum alanlarını belirlemeyi amaçlamaktadır. Yüksek doğrulukla elde edilen tahminlerle, sensörler ve yapay zekâ kullanılarak güneş paneli kurulumu gerektirmeksizin potansiyel enerji üretimi tahmin edilebilecektir (Özer ve Aksoy, 2024).

Makaleye ait çalışmada, yapılan tahminlerde en başarılı sonuçları sağlayan yapay zekâ modeli, Gradient Boosting modeli olmuştur ve bu model R^2 performans değerlendirme metriğine göre %97.04 doğruluk değeri ile en yüksek performansı göstermiştir. Bu sonuç, güneş paneli sistemlerinin enerji üretim verimliliğini tahmin etmek için yapay zekâ uygulamalarının etkili bir yöntem olduğunu ortaya koymaktadır (Özer ve Aksoy, 2024).

Wu ve diğ. (2022), çalışmalarında öncelikle rüzgâr enerjisini tahmin etmek için derin öğrenme modellerinin kullanılmasına odaklanmıştır. Son beş yılda rüzgâr tahmini için kullanılan derin öğrenme tekniklerine genel bir bakış sağlanmıştır. Derin öğrenme tekniklerini kullanarak rüzgâr enerjisi tahminini ilerletmek için potansiyel yollar araştırılmıştır. Zaman serilerine dayalı tekrarlayan sinir ağları, kısıtlı Boltzmann makineleri ve sinir ağları model çalışmalarında denenmiştir. Rüzgâr enerjisini tahmin etmek için otomatik kodlayıcıları (autoencoder) kullanan yöntemler gibi gelişmiş derin öğrenme tekniklerini kullanarak rüzgâr enerjisi tahminlerinin iyileşmesinden bahsedilmiştir. Bu çalışma rüzgâr tahmini araştırmacıları için kapsamlı bir inceleme sunmaktadır (Wu ve diğ, 2022).

Markovics ve Mayer (2022), sayısal hava tahmini kullanarak fotovoltaik güç tahmini için 24 makine öğrenimi modelinin karşılaştırmalı bir analizini yapmıştır. Tahminde kullanılacak özelliklerin seçimi ve modelde uygulanan hiper parametre ayarlamasının etkisini değerlendirmiştir. Çalışmalarında optimum modeller: kernel ridge regresyonu ve çok katmanlı perceptron (MLP) öne çıkmıştır. Gerçek uygulamalar için çok katmanlı bir perceptron modeli kullanılmasını önermiştir (Markovics ve Mayer, 2022).

2.2 Optimizasyon Alanında Yapılan Çalışmalar

Ever ve Demircioğlu (2022) tarafından hazırlanan çalışma kapsamında yapay zekâ teknolojilerinin işletmeler için dijital dönüşümün kaçınılmaz bir gereklilik haline getirdiği vurgulanmaktadır. İşletmelerin sürdürülebilirlik hedeflerine ulaşmak, maliyetleri azaltmak ve kârlılığı artırmak amacıyla yapay zekâyâ yatırım yapmalarının

önemine dikkat çekilmektedir. Yapay zekâ, üretim süreçlerini planlamak, iyileştirmek ve kalite kontrolünü sağlamak amacıyla kullanılarak işletmelerin verimliliklerini artırmayı ve karşılaşılan sorunlara hızlı çözümler üretmeyi amaçlamaktadır. Ancak, geleneksel maliyet sistemlerinin bu modern teknolojilerle yetersiz kaldığı belirtilmiş ve bu nedenle çağdaş bir yaklaşım olan kalite maliyetlerine duyulan ihtiyaç vurgulanmıştır (Ever ve Demircioğlu, 2022).

Yapay zekâ destekli kalite yönetim sistemlerinin endüstrilerdeki yaygın kullanımı ile, kalite faaliyetlerinin iyileştirilmesi, hataların erken tespiti ve ortadan kaldırılması sayesinde kalite maliyetlerinin düşürülebileceği belirtilmektedir. Bu durum, yapay zekâ teknolojilerinin muhasebe açısından değerlendirilmesiyle, kalite maliyetleri modellerinin avantajlarını ve işletmelerin dijital dönüşüm süreçlerindeki etkilerini incelemeyi önemli kılmaktadır. Bu bağlamda, amaç, yapay zekâ teknolojilerinin kalite maliyetleri üzerindeki etkilerini teorik bir çerçevede açıklamak ve yapay zekâ ile kalite yönetimi arasındaki ilişkiyi anlamaktır (Ever ve Demircioğlu, 2022).

Aylak ve diğ. (2021) tarafından hazırlanan çalışma kapsamında lojistik sektörünün dünya genelinde ve Türkiye'de hızla büyüdüğü ve potansiyelinin zaman içinde daha iyi anlaşıldığı vurgulanmaktadır. Lojistik sektörünün teknolojik yeniliklere açık olduğu ve Endüstri 4.0'ın etkisiyle özellikle rekabetin yoğun olduğu sektörlerden biri olduğu belirtilmektedir. Yapılan son araştırmalara göre yapay zekâ tekniklerinin lojistikte büyük ölçüde arttığına dikkat çekilmektedir. Makalede, yapay zekânın lojistik sektöründe kullanılmasıyla işleyiş ve dinamiklerde önemli değişikliklerin meydana geldiği ve bu teknolojinin lojistik süreçlerindeki hataları en aza indirmeye yardımcı olduğu vurgulanmaktadır. Yapay zekâ, insan zekasının fizyolojik ve nörolojik yapısını çeşitli teknolojilerle modelleyerek makinelerde uygulamaktadır. Bu doğrultuda, sürücüsüz araçlar, depolama alanları ve raflardaki robotlar gibi yapay zekâ temelli teknolojik gelişmelerin lojistik sektöründe verimlilik sağladığı belirtilmektedir (Aylak ve diğ., 2021).

Namlı (2012) tarafından yapılan çalışmanın amacı, lojistik sektöründe yapay zekâ ve makine öğrenmesi uygulamalarını geniş bir bakış açısıyla incelemektir. Çalışma, yapay zekâ ve makine öğrenimi kavramlarını açıklığa kavuşturmuş, endüstri ve lojistik terimlerini ele almış ve lojistikte kullanılan yapay zekâ ve makine öğrenmesi uygulamalarına örnekler sunmuştur. Ayrıca, küresel lojistik ve tedarik zinciri yönetimi

alanlarında yapay zekâ teknolojilerinin gelişmeye devam ettiği ve lojistik süreçlerde kolaylık sağladığı vurgulanmıştır (Namlı, 2012).

Çalışmada sürekli artan rekabet ortamında faaliyet gösteren firmaların proje bazlı çalışmalarda etkin bir proje yönetimi uygulamasının hayati bir önem taşıdığını vurgulamaktadır. Etkin proje yönetiminin zaman, maliyet ve kalite optimizasyonu sağlamakla birlikte proje sürecinin izlenmesi ve risklerin doğru yönetilmesi gerekliliğine işaret etmektedir. Bu yaklaşımın, performans göstergelerinin doğru seçimi, başarı ölçümü ve rakiplerle kıyaslamalar gibi unsurlara olanak tanıyarak iyi bir yönetim altyapısını oluşturduğu belirtilmektedir (Namlı, 2012).

Mobil iletişim teknolojilerindeki gelişmeler, bilgiye her an, her yerden yüksek hız ve kapasitede erişim ihtiyacını artırmıştır. Kranda (2021) tarafından gerçekleştirilen çalışmada, mobil radyo ağ performans ve kapasitesini artırmak amacıyla tahminleme algoritmalarını optimize etmeye odaklanmaktadır. Çalışmada, mobil ağların performansını olumsuz etkileyen iki durum ele alınmıştır: baz istasyonlarındaki mevsimsel etkilerin ve değişim noktalarının tespiti ile yeterli geçmiş veriye sahip olmayan yeni hücrelerin trafik tahmin hatalarının azaltılması. Hiperparametre optimizasyonu, ideal nitelik seçimi ve algoritmaların hassas ayarlamaları gerçekleştirilerek tahminleme doğruluğu artırılmıştır. Bu süreçte, SARIMAX ve STL-ETS gibi klasik yöntemler ile LSTM ve CNN-LSTM gibi derin öğrenme modelleri entegre edilerek mobil ağlarda daha verimli kapasite planlaması ve maliyet optimizasyonu sağlanmıştır (Kranda, 2021).

Savunma sanayi, bir ülkenin ulusal güvenliği ve ekonomik gücünün temellerini oluşturan stratejik bir sektördür. Küreselleşen dünyada, ülkeler arasındaki iş birlikleri artarken, özellikle savunma alanında ülkelerin kendi savunmalarını yerli üretimle güçlendirmeleri kritik öneme sahiptir. Bu bağlamda, savunma sanayi, yüksek Ar-Ge yatırımları, ileri teknoloji kullanımı ve özel kalite standartları ile diğer sektörlerden farklılaşmaktadır. Savunma sanayi projeleri, genellikle sınırlı sayıda alıcıya sahip ve politik etkilerle şekillenen bir pazara hizmet etmektedir. Ayrıca, bu alandaki yatırımlar, ülkelerin teknolojik altyapılarının gelişmesine büyük katkı sağlamaktadır (Kranda, 2021).

Şeker (2019) tarafından gerçekleştirilen çalışmada, savunma sanayi projelerinde prototip ürünlerin hızlı ve düşük maliyetle devreye alınmasını sağlamak amacıyla bir

simülasyon modeli geliştirilmiştir. Prototip ürünlerin üretim süreci, Arena 10.0 programı ile modellenmiş ve OptQuest modülü kullanılarak maliyet minimizasyonu yapılmıştır. Gerçek bir savunma projesi üzerinden uygulanan bu model, sistemin kısıtlarını göz önünde bulundurarak üretim hattı verimliliğini artırmayı hedeflemiştir. Çalışma, prototip ürünlerin seri üretime geçiş sürecinde maliyetleri optimize etmek için modelleme tekniklerinin etkin bir şekilde nasıl kullanılabileceğini ve bu tür projelerde karşılaşılan zorlukların üstesinden nasıl gelinebileceğini göstermektedir. Literatürde benzer çalışmalar, savunma sanayii projelerinde üretim sürecinin optimize edilmesi ve maliyetlerin kontrol altına alınması için simülasyon tabanlı yöntemlerin yaygın olarak kullanıldığını ortaya koymaktadır (Şeker, 2019).

Ulaşım, toplum için temel bir ihtiyaç olmasına rağmen, artan nüfus ve araç sayısı nedeniyle hem şehir içi hem de şehir dışı seyahatlerde büyük zorluklar yaşanmaktadır. Trafik sıkışıklığı, kazalar, trafik ihlalleri ve zaman kaybı, maddi ve manevi maliyetleri artırırken, aynı zamanda trafik stresi çalışanların verimliliğini olumsuz yönde etkileyebilmektedir. Bu problemlerin çözülmesi için, trafikte en uygun rotaların seçilmesi, trafik yoğunluğu noktalarının belirlenmesi ve kaza analizi gibi alanlarda optimizasyon, simülasyon ve tahmin çalışmaları yapılmaktadır (Erzurum Çiçek, 2020). Erzurum Çiçek (2020) tarafından yapılan bir araştırmada, trafik akışını tahmin etmek amacıyla Yapay Sinir Ağı tabanlı bir melez model geliştirilmiş ve bu model, zaman serisi tahmin teknikleriyle karşılaştırılarak olumlu sonuçlar elde edilmiştir. Ayrıca, Eskişehir'deki trafik kazalarına dair yapılan incelemelerde, olasılık dağılımları hesaplanmış ve kaza tahminleri veri madenciliği yöntemleriyle gerçekleştirilmiştir. Trafik ağlarının belirsizlikleri ve dinamik özellikleri göz önünde bulundurularak, en kısa süreli güzergahları belirlemek için Markov Karar Süreci temelli dinamik programlama yöntemine başvurulmuş ve bu yaklaşım, deterministik yöntemlere göre daha başarılı sonuçlar vermiştir (Erzurum Çiçek, 2020).

Sarıgül (2019) tarafından gerçekleştirilen çalışmada, MDF üretim sürecinde kullanılan hammaddelerin, ürünün çekme mukavemeti, eğilme direnci ve yüzey sağlamlığı üzerindeki etkileri analiz edilmiştir. Geçmiş üretim verileri incelenerek, hammadde oranlarının bu fiziksel özellikler üzerindeki etkisi belirlenmiş ve üretim maliyetlerini minimize ederken kaliteyi optimize eden matematiksel modeller geliştirilmiştir. Hem tek amaçlı hem de çok amaçlı modeller kullanılarak, maliyet ve kaliteyi dengeleyen çözümler üretilmiştir. Çok amaçlı modellerin çözümünde önceliklendirmeli hedef

programlama yaklaşımı kullanılarak, verimli ve etkili üretim süreçleri için optimize edilmiş hammadde karışımları belirlenmiştir. Bu tür optimizasyon çalışmalarının, özellikle endüstriyel üretim süreçlerinde kalite ve maliyet yönetimini geliştirmede önemli katkılar sağladığı literatürde sıklıkla dile getirilmektedir (Sarigül, 2019).

Elektrik üretim planlaması, sürdürülebilir gelişim ve çevre koruma hedefleri doğrultusunda ülkelerin enerji politikalarını belirlemede kritik bir rol oynamaktadır. Bu çerçevede, yerel ve sürdürülebilir enerji kaynaklarının kullanımının artırılması, çevresel etkilerin azaltılması ve ekonomik verimliliğin yükseltilmesi temel hedefler arasında yer almaktadır. Literatürde, elektrik üretiminde çok sayıda parametrenin eş zamanlı olarak optimize edilmesi gerektiği vurgulanmaktadır. Özellikle, enerji üretim maliyetlerinin, CO2 salınımının, fosil yakıt kullanımının, ithalatın ve istihdamın optimize edilmesi gibi çoklu hedefler, enerji planlamasında önemli bir yer tutmaktadır (Sarigül, 2019).

Özcan (2013) tarafından gerçekleştirilen çalışmada, Türkiye'nin özel koşullarını dikkate alan ve elektrik üretiminde tüm enerji kaynaklarını göz önünde bulunduran çok amaçlı bir optimizasyon modeli geliştirilmiştir. Model, elektrik üretim maliyetlerinin ve çevresel etkilerin minimize edilmesini, aynı zamanda sosyal kabul ve istihdam gibi faktörlerin maksimizasyonunu hedefleyen bir doğrusal programlama yaklaşımını benimsemektedir. Türkiye'nin 2012-2023 yılları arasındaki elektrik enerjisi talebini karşılamak için oluşturulan bu model, aynı zamanda yeni elektrik üretim tesislerinin yatırım planlamasını da içermektedir. Bu çalışma, elektrik üretiminde daha sürdürülebilir ve verimli bir yaklaşım için kapsamlı bir planlama sunmaktadır (Özcan, 2013).

Mutlu (2024) tarafından gerçekleştirilen çalışmada, enerji piyasalarında ticaret yaparken maliyet optimizasyonunu sağlamak amacıyla derin pekiştirmeli öğrenme tabanlı bir model geliştirilmiştir. Türkiye gibi gelişmiş ve gelişmekte olan ülkelerde elektrik üretimi ve tedariki, lisans sahibi işletmeler tarafından yürütülmektedir ve bu işletmelerin enerji ticareti faaliyetleri önemli bir sektörel bilgi ve yüksek efor gerektirir. Enerji piyasalarında etkin ticaret yapmak için, işletmelerin her günün 24 saati için üretim ve tüketim planlaması yapması, ayrıca plan sapmalarını gün içi piyasasında ticaretle düzeltilmesi gerekmektedir. Bu noktada, derin pekiştirmeli öğrenme destekli bir ticaret stratejisi, plandan sapmaların uygun fiyatlarla kapatılması ve kâr elde edilmesi için önemli bir rol oynamaktadır. Gün içi piyasaların dinamik

yapısı ve sürekli emir gerektiren özellikleri göz önünde bulundurularak, bu model, enerji maliyetlerini azaltacak stratejiler belirlemeyi ve uygulamayı amaçlamaktadır. Model, ayrıca elektrik şebekelerinin stabilitesine katkıda bulunarak, elektrik kalitesini artırmaya yönelik önemli bir çözüm sunmaktadır (Mutlu, 2024).



3. KAVRAMLAR

3.1 Veri Bilimi

Veri, herhangi bir analiz işlemine başlamadan önce sistemde depolanan ve analiz sürecine katkı sağlayacak tüm bilgilerdir. Ayrıca, matematiksel, istatistiksel çalışmalarda ve genel olarak çeşitli araştırmalarda kullanılabilen tüm bilgiler de veri olarak tanımlanabilmektedir (Demir ve diğ., 1992).

Veri analitiği, veriyi anlamlı ve uygulanabilir bilgilere dönüştürme sürecidir. Bu süreç, verilerdeki desenleri ve eğilimleri keşfetmek, görselleştirmek ve ilişkilendirmek için istatistiksel yöntemler (örneğin, merkezi eğilim ölçüleri, grafikler), bilgi sistem yazılımları (veri madenciliği) ve yöneylem araştırması tekniklerinin (örneğin, doğrusal programlama) kullanılmasını içerir (Schniederjans ve diğ., 2014).

Veri analitiği, farklı analiz tekniklerini kullanarak verilerden anlam çıkarma sürecini ifade eder ve genellikle dört ana yaklaşımla incelenir. İlk yaklaşım, tanımlayıcı analitikler olarak adlandırılır. Tanımlayıcı analitikler, veriyi grafikler, merkezi eğilim ölçüleri, olasılık ve frekans dağılımları gibi istatistiksel tekniklerle inceleyerek olayların daha anlaşılır bir biçime gelmesini sağlar. Bu sayede geçmiş verilere dayalı anlamlı çıkarımlar elde edilebilmektedir (Erzurum Çiçek, 2020).

İkinci olarak, kestirimsel analitikler ifade edilmektedir. Kestirimsel analitikler, geçmiş verilerden gelecekteki olayları tahmin etmeye yönelik olarak ileri düzey istatistiksel, veri madenciliği ve yöneylem araştırması tekniklerini kullanır. Kestirimsel analitikler, işletmelerin ürün ve hizmetlerini geliştirmeleri için önemli fırsatları ortaya koyar (Ajah ve Nweke, 2019).

Üçüncü analiz yaklaşımı ise teşhis analitikleridir. Bu yaklaşım, geçmişte gerçekleşen olayların veya karşılaşılan problemlerin nedenlerini derinlemesine incelemeyi amaçlamaktadır. Bu aşama, problemin çözülmesinde veya iyileştirme gerçekleştirilmesinde kritik bir rol oynar (Erzurum Çiçek, 2020).

Dördüncü ve son olarak, kuralcı analitikler, verilerden elde edilen bulgulara dayanarak en etkili eylem stratejisini belirlemeyi hedeflemektedir. Bu tür analizler, karar bilimi, yönetim bilimleri ve yöneylem araştırması yaklaşımlarını kullanarak, kaynakları en verimli şekilde dağıtmak için kararlar vermektedir (Ajah ve Nweke, 2019). Bu tür analitik yöntemler, karar alma süreçlerinde rehberlik sağlamak amacıyla tek başına ya da birleşik olarak kullanılabilir ve işletmelere önemli stratejik üstünlükler kazandırır.

Veri madenciliği, verilerdeki anlamlı korelasyonları ve desenleri keşfetme süreci olarak tanımlanır. Başka bir ifadeyle, veri madenciliği, büyük veri setlerinde var olan ilişkileri analiz edip, bu verileri anlamlı ve faydalı bir biçimde özetleyerek veri sahiplerine sunma yöntemidir (Hand ve diğ, 2001). Veri madenciliği, büyük veri tabanlarından bilgi çıkarma amacıyla; makine öğrenmesi, örüntü tanıma, istatistik, veri tabanı yönetimi ve görselleştirme tekniklerini birleştiren çok disiplinli bir alan olarak tanımlanabilmektedir (Cabena ve diğ, 1998).

Veri madenciliğinin, kökenleri klasik istatistiğe dayansa da 1980'li yıllardan sonra bilgisayar teknolojilerinin gelişmesiyle yapay zekâ ve makine öğrenmesi gibi yöntemleri de bünyesine alarak alanı genişlemiştir. Karar alma süreçlerinde veri analizi yaparak sorunların daha anlaşılır hale gelmesini sağlayan bir alan haline almıştır.

Veri madenciliği süreci, temel olarak dört ana aşamadan oluşmaktadır. İlk aşama, çözülmesi gereken problemi net bir şekilde tanımlamak ve bu problemle ilgili gerekli veri kaynaklarını değerlendirmektir. İşletmenin amacı ve problemi açıkça ifade edilerek, bu amaca yönelik hangi verilerin kullanılacağı belirlenir. İkinci aşama, verilerin analiz amacıyla kullanılabilir duruma getirilmesi, yani veri hazırlık sürecidir. İkinci aşamada veri setleri toplanır, temizlenir ve betimlenir. Veri ön işleme işlemi, verilerin kalitesinin artırılması ve güvenilirliğinin sağlanması için kritik bir adımdır. Gerçekleştirilen ön işleme işlemleri ile veri madenciliği sürecinin sonraki aşamalarında sağlıklı analizler yapılabilir. Üçüncü aşama ise, belirlenen problemi çözmek için uygun bir modelin kurulması ve bu modelin değerlendirilmesidir. Bu aşamada, problem için en uygun çözümü bulabilmek adına birçok model denenir ve süreç, en iyi sonuçları elde edene kadar tekrarlanır. Dördüncü ve son aşama, oluşturulan modelin uygulanmasıdır. Dördüncü aşamada kurulan modelin geçerliliği kabul edilir ve model, doğrudan bir çözüm olarak

kullanılabilmesinin yanında, başka bir uygulamanın alt parçası olarak da entegre edilebilmektedir.

3.2 Makine Öğrenmesi

Makine öğrenimi, bilgisayar programları (algoritmalar) verilerdeki örneklerden tahmin gücü, ilişkilendirme, öğrenme gibi konularda yapay zekânın alt disiplini. Makine öğrenimi, en basit haliyle istatistiksel modellerin bilgisayar kullanılarak verilere uygulanmasıdır. Makine öğrenimi, tipik olarak kullanım alanlarında geniş bir dizi istatistiksel teknik kullanmaktadır. Diğer taraftan derin öğrenme gibi daha yeni yöntemler, temel alınan veriler hakkında daha az varsayımda bulunan modellere dayanmaktadır. Derin öğrenme, makine öğrenmesinin bir alt dalıdır (Panch ve diğ., 2018).

Makine öğrenmesi, bilgisayarların insan benzeri bir şekilde öğrenmesini, bilgi edinmesini ve problem çözmesini sağlayan bir bilim dalıdır. Temel olarak, zekânın bir özelliği olan öğrenmeyi makineler aracılığıyla gerçekleştirmeyi amaçlamaktadır. Bu alanda kullanılan algoritmalar, ham verilerden anlamlı bilgiler çıkararak bu bilgiyi gelecekteki durumlar hakkında tahminlerde bulunmak için kullanır. Model geliştirme aşaması hem eğitim hem de test süreçlerini kapsar. Eğitim aşamasında, algoritmalar verileri analiz eder ve bir öğrenme sürecinden geçer. Ardından elde edilen model, test verileri üzerinde doğrulanarak tahminler yapma yeteneği kazanır.

Makine öğrenmesi, mevcut verilerden anlamlı bilgiler elde etmek için matematiksel yöntemler kullanan bir dizi tekniktir. Bu bilgiler, sadece verilerin anlaşılmasını sağlamakla kalmaz, aynı zamanda yeni veriler hakkında tahmin yapmayı mümkün kılar. Günümüzde, üretim planlaması, maliyet optimizasyonu, sağlık ve finans gibi birçok sektörde makine öğrenmesi uygulamaları, verimliliği artırmak ve süreçleri iyileştirmek için kullanılmaktadır. Makine öğrenmesi, hızla gelişen teknolojinin önemli bir parçası olarak hayatımızda yer almaya devam etmektedir.

Makine öğreniminin temel amacı, veri türetme sürecine katkıda bulunmak ve analistlerin gözlemledikleri verilere dayanarak gözlenmeyen olayları genelleme yeteneği sağlayan bir yapı oluşturmak olmuştur. İlk makine öğrenme modelini 1962 yılında Rosenblatt geliştirmiştir. Ardından 1980'lerin ikinci yarısında YSA üzerine çalışmalar yapılmış, aynı dönemde bazı araştırmacılar ise karar ağacı teorisini

geliştirerek bunu sınıflandırma problemlerinde kullanılabilir hale getirmiştir. İstatistiğin her dönemde modelleme için bir araç olarak kabul edilmesiyle, bilgisayar teknolojilerinin ilerlemesiyle birlikte, bilgisayarlı yöntemlerin istatistiksel analizlerdeki önemi giderek artmıştır. 1990'lı yıllarda istatistikçiler de makine öğrenme yöntemlerine ilgi göstermiş ve bu da metodolojinin gelişiminde önemli bir aşama olmuştur (Guidici, 2003).

Makine öğrenmesi algoritmaları temelde üç geniş kategoriye ayrılır. Bunlar şöyledir; öğrenme sisteminin etiketli eğitim verilerinden bir fonksiyona girdiği denetimli öğrenme, öğrenme sisteminin etiketsiz verilerin yapısını çıkarmaya çalıştığı denetimsiz öğrenme ve sistemin dinamik bir ortamla etkileşime girdiği takviyeli öğrenme (Kavakiotis ve diğ, 2017).

- Denetimli (Supervised) Öğrenme
- Denetimsiz (Unsupervised) Öğrenme
- Takviyeli (Reinforcement) Öğrenme

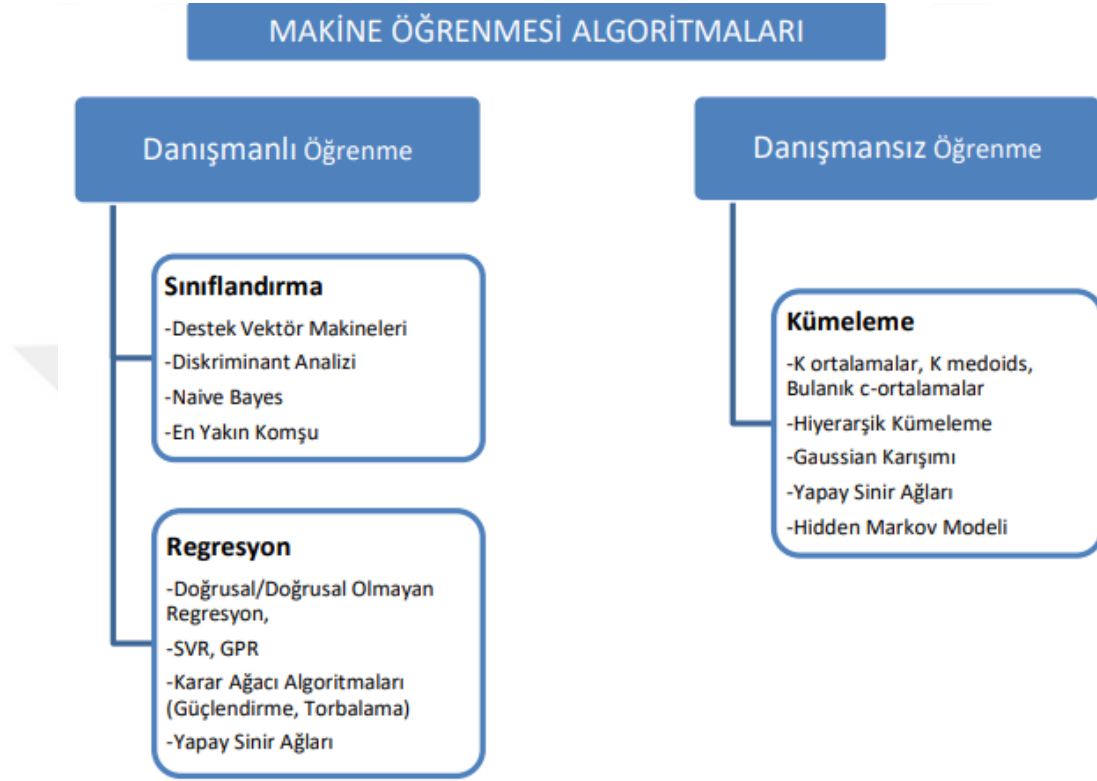
Denetimsiz öğrenme, yalnızca ham girdi verilerini kullanarak çalışır ve bu verilerin altında yatan yapıları keşfetmeyi amaçlar. Bu yöntemde veriler etiketlenmemiştir ve sistem, çıktı verilerine ihtiyaç duymadan öğrenir. Kümeleme ve temel bileşenler analizi, gözetimsiz öğrenmede yaygın olarak kullanılan yöntemlerdir ve özellikle büyük veri kümelerinde desenlerin anlaşılmasında etkili bir rol oynar. Denetimsiz öğrenme bazı kaynaklarda danışmansız öğrenme olarak da tanımlanmaktadır (Url-1).

Denetimli öğrenme, sistemin, girdi ve çıktı verileri arasındaki ilişkileri öğrenmesini sağlar. Eğitim sırasında, etiketlenmiş veri setlerinden faydalanılarak bir model oluşturulur ve bu model, yeni veriler üzerinde doğru tahminler yapmak için kullanılır. Gözetimli öğrenmenin iki ana uygulama alanı bulunmaktadır: sınıflandırma, verileri belirli kategorilere ayırırken; regresyon, sayısal değerleri tahmin etmeye odaklanır. Denetimli öğrenme bazı kaynaklarda danışmanlı öğrenme olarak da tanımlanmaktadır (Url-1).

Takviyeli öğrenme, sistemin çevresiyle etkileşime girerek en iyi eylemleri öğrenmesini amaçlayan bir yöntemdir. Bu süreçte sistem, aldığı kararlar sonucunda ya ödüllendirilir ya da cezalandırılır. Takviyeli öğrenmede, eğitmen yalnızca sınırlı bilgi sağlar; bu da sistemin kendi başına stratejiler geliştirmesini teşvik eder. Bu yöntem,

özellikle oyun kuramı, optimizasyon, simülasyon ve istatistik gibi alanlarda yaygın olarak uygulanmaktadır (Url-1).

Yaygın olarak kullanılan makine öğrenmesi teknikleri şekil 3.2’de gösterilmiştir.



Şekil 3.1 : Makine öğrenmesi algoritmaları (Olgun, 2020).

3.3 Yapay Zekâ

Yapay zekâ, makine öğrenmesi ve verilere dayalı karar verme süreçleri ile otonom yönetim yetenekleri sağlayabilen, verileri matematiksel ve mantıksal modeller üzerinden analiz ederek insan benzeri kalıplarla en doğru tahminleri yapabilen bir yazılımdır (Serçemeli, 2018).

Yapay zekanın gelişimi, onlarca yıl boyunca yapılan kapsamlı araştırmaların ve teknolojik ilerlemenin bir sonucudur. İlerlemesindeki en önemli etkenler arasında, artan hesaplama kapasitesi ve büyük miktarlarda veriye erişimlerdir. Bu durum, araştırmacıların daha karmaşık algoritmalar ve modeller formüle etmelerini sağlayarak yapay zekanın yeteneklerinde önemli ilerlemelere yol açmıştır (Walk ve diğ., 2023).

Günümüzde yapay zekâ uygulamaları her yerde hayatımıza girmiş durumdadır. Bankalar, araçlar, hastaneler, evler, internet ve mobil cihazlar gibi pek çok alanda bu teknolojiler kullanılmaktadır. En basit örneklerden biri, herkesin her gün yaptığı Google aramalarının yapay zekâ teknolojilerine dayanıyor olmasıdır. Bunun yanı sıra, sağlık, finans ve ulaşım sektörlerinde de yapay zekâ sistemlerinden yararlanılmaktadır. Şu anda 60'tan fazla farklı yapay zekâ tekniği olduğu belirtilmektedir. Bu tekniklerin başlıcaları aşağıda sıralanmıştır (Paksın, 2020).

- Yapay Sinir Ağları
- Genetik Algoritmalar
- Makine Öğrenmesi
- Konuşma Tanıma
- Bulanık Mantık
- Robotik
- Uzman Sistemler

Yapay zekâ, bilgisayarların insan zekâsını taklit etmelerini sağlamak amacıyla kullanılan her türlü tekniği kapsar ve bunun içerisinde makine öğrenmesi ile derin öğrenme yer alır (Stancheva-Todorova, 2018). Yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları literatürde çoğunlukla birbirinin yerine kullanılmakta olup, bu terimler günümüzde işletmeler için ayrılmaz bir bütün hâline gelmiştir (Reese, 2017). Makine öğrenmesi ve derin öğrenme, yapay zekânın alt alanları olarak değerlendirilir (Reese, 2017). Aylak ve diğ. (2021) ise makine öğrenmesini, yapay zekânın bir parçası olarak, derin öğrenmeyi ise makine öğrenmesinin bir alt kategorisi olarak tanımlamaktadır. Yapay zekâ, makine öğrenmesi ve derin öğrenme terimleri bazen birbirinin yerine kullanılsa da aralarında belirgin farklar bulunmaktadır. Makine öğrenmesi, analitik modelleme sürecini otomatikleştirerek, belirli görevleri çözmek için sunulan verilerden öğrenme yeteneğine sahip sistemlerin işlevini tanımlamaktadır. Derin öğrenme ise YSA dayalı bir makine öğrenmesi alt alanıdır (Janiesch ve diğ., 2021). Du-Harpur ve diğ. (2020) ise makine öğrenmesini, verilerden öğrenmeye yönelik olarak tasarlanmış algoritmalar ve istatistiksel modeller olarak tanımlarken, derin öğrenmeyi, ayarlanabilir ağırlıklarla çok katmanlı 'nöron' yapılarına sahip bir sinir ağı olarak açıklamışlardır.

3.4 Maliyet Optimizasyonu

Optimizasyon, belirli bir hedefe ulaşmak için iş gücü, zaman, maliyet, araç donanımı, hammadde, kapasite ve güvenlik gibi kaynakların mümkün olan en iyi şekilde kullanımını hesaplayan bir yöntemdir. Bu süreç, hedeflenen sonuca bağlı olarak işlem zamanını en aza indirmeyi ya da üretim miktarını, hizmet kalitesini veya sağlanan faydayı en üst düzeye çıkarmayı amaçlar. Optimizasyon, kaynakların etkin kullanımını sağlayarak hem verimliliği artırır hem de hedeflere daha hızlı ve düşük maliyetle ulaşmayı mümkün kılar.

Optimizasyon, belirli bir hedefe en düşük maliyetle ulaşmayı ya da sınırlı kaynaklarla en fazla verimi elde etmeyi amaçlamaktadır. Optimizasyon çalışmaları sadece üretilen ürünlerde değil, tasarım süreçlerinde de gerçekleştirilebilmektedir. Minimum malzeme ile maksimum dayanıklılığa ulaşmaya çalışmak da bir optimizasyon çalışmasıdır. Optimizasyon, kaynakların etkin kullanımını sağlayarak maliyetleri düşürmeyi ve verimliliği artırmayı hedefler.

Maliyet optimizasyonu, kıt kaynakları rasyonel bir biçimde değerlendirerek istenilen kalite standartlarından ödün vermeden, toplam maliyetlerin minimum seviyeye indirilmesini amaçlar. İşletmelerin yalnızca bugünkü rekabet koşullarında değil, gelecekteki belirsizlik ortamlarında da rekabet avantajı elde etmelerine olanak sağlar. Günümüzün yoğun rekabet ortamında işletmelerin uzun vadede etkin bir şekilde faaliyet gösterebilmeleri ve misyonlarını sürdürülebilir şekilde gerçekleştirebilmeleri, kaynaklarını en etkin biçimde kullanarak maliyetlerini yönetmelerine bağlıdır. Bu bağlamda, maliyet optimizasyonu, işletmeler için stratejik bir araç haline gelmiştir.

Maliyet optimizasyonu, ürün veya hizmetlerin üretimi sürecinde kullanılan hammadde, enerji, iş gücü, makine ve teçhizat gibi üretim faktörlerinin en verimli şekilde kullanılmasını sağlar. Bununla birlikte, her bir girdinin maliyetini düşürmek yerine, üretimin toplam maliyetini asgariye indirecek bir yaklaşımı esas alır. Gerçekleşen durumun geneline bakıldığında, hammadde maliyetlerini azaltmak amacıyla yapılan bir değişiklik, işçilik veya genel giderlerde artışa neden olabilme ihtimali mevcuttur. Maliyet optimizasyonunda sadece tek bir maliyet unsuru değil, tüm süreçlerin bütünleşmiş bir şekilde değerlendirilmesi gerekir.

Bir işletmede maliyet yapısının optimize edilmesi, en az kaynakla en yüksek çıktıyı elde etmeyi sağlayarak, maliyetlerin uzun vadede sürdürülebilir bir sistem içinde

yönetilmesini mümkün kılar. Bu süreç, işletmelerin yalnızca maliyetlerini azaltmakla kalmaz, aynı zamanda üretim süreçlerinin verimliliğini artırır. Daha az kaynakla daha fazla değer yaratma kabiliyeti, işletmelerin hem iç operasyonel süreçlerinde hem de pazardaki rekabetçi pozisyonlarında avantaj elde etmelerine yardımcı olur. Bu da işletmelerin yüksek enflasyon, artan üretim maliyetleri ve kalite düşüklüğü gibi olumsuz ekonomik koşullar karşısında daha dayanıklı hale gelmelerini sağlar.

Maliyet optimizasyonunun bir diğer önemli faydası, işletmelerin pazar değişimlerine hızlı uyum sağlayabilmesidir. Pazarda meydana gelebilecek fiyat dalgalanmalarına karşı maliyetlerini esnek bir şekilde yönetebilen işletmeler, pazar paylarını korurken istedikleri kâr marjını da sürdürebilmektedirler. Bu süreç, müşterilerin talep ettiği kalite standartlarını karşılayarak, hatasız ve düşük maliyetli ürün veya hizmet üretimini mümkün kılmaktadır. Böylelikle, işletmeler hem müşteri memnuniyetini artırır hem de karlılıklarını uzun vadede maksimize eder.

Sistematik bir maliyet optimizasyonu, işletmenin kaynaklarını en rasyonel biçimde kullanarak, verimlilik ve performans artışını destekler. Bu süreçte, işletmeler hem operasyonel hem de stratejik açıdan maliyetlerini optimize ederek, sürdürülebilir büyüme ve başarı elde ederler. Bu da yalnızca mevcut koşullarda değil, gelecekte karşılaşılabilecek zorluklarda da işletmelerin ayakta kalmalarını sağlar.

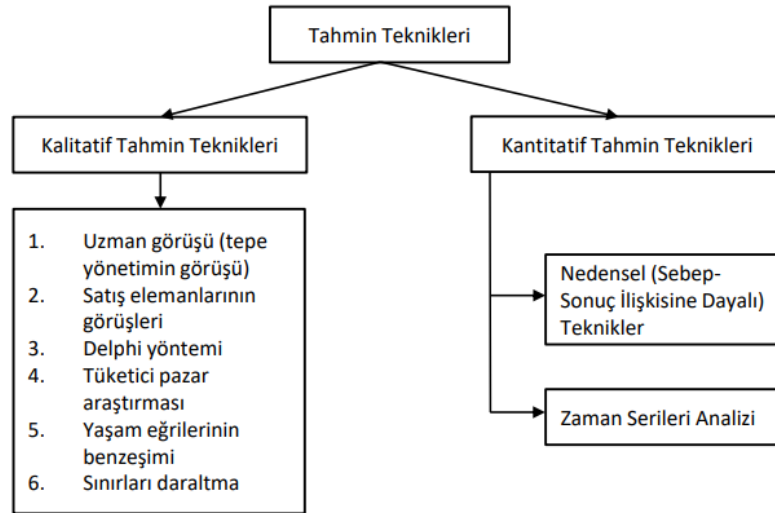
3.5 Tahminleme

Tahmin, belirli bir değişkenin gelecekteki muhtemel değerlerini, belirli varsayımlar altında yaklaşık olarak belirlemeye yönelik bir süreç olarak tanımlanabilmektedir. Zaman serisi analizinden yararlanarak, öngörü, belirli bir değişkenin mevcut ve geçmiş gözlem değerlerini dikkate alarak, varsayımlar yardımıyla tahmin edilen değerlerin sınırlarını belirlemeye yönelik yapılan çalışmalardır. Etkili bir öngörü, doğru kararların alınmasına yardımcı olur ve bu da elde edilecek faydanın maksimum düzeye çıkarılmasına olanak tanır. Bu durum, öngörü modellemelerine olan ilgiyi artırmaktadır (Ataseven, 2013).

Günümüzde işletme yöneticileri, stratejik kararlar ile geleceğe dönük planlamalarını sağlıklı bir şekilde gerçekleştirmek için başarılı tahminleme yapmak zorundadır (Karahana, 2011).

Yapılacak tahmin türü ve tahminin etkili olacağı süre, ürünün özellikleri ve talep biçimlerine bağlı olarak değişir. Eğer ürün talebi genellikle sabitse, tahmin için daha kısa bir süre tercih edilebilmektedir. Eğer tahmin, en az bir talep dalgasını kapsıyorsa, bu, talepteki dalgalanmayı gösterir. Uzun vadeli bir talep eğilimi bekleniyorsa, daha uzun süreli bir tahmin yapılması gereklidir. Bazı ürünlerde ise talep değerleri mevsimsel olarak değişiklik gösterebilmektedir. Böyle durumlarda, talepteki mevsimsel değişimlerin sebeplerinin doğru bir şekilde analiz edilmesi ve mevsimsel tahmin yöntemlerinin uygulanması önemlidir (Yazıcıoğlu, 2010).

Tahmin yöntemleri, Şekil 3.2'de de belirtildiği gibi, kalitatif, kantitatif ve yapay zekâ destekli tahmin teknikleri olmak üzere üç ana kategoriye ayrılmaktadır. Kalitatif yöntemler genellikle bireysel görüşlere dayanırken, kantitatif yöntemler ise matematiksel analizlere odaklanır. Ancak, klasik tahmin yöntemlerinin yeterli olmadığı durumlarda, daha karmaşık veri yapılarının analizini mümkün kılan yapay zekâ destekli yaklaşımlar kullanılabilir.



Şekil 3.2 : Tahmin teknikleri (Url-2).

3.5.1 Kalitatif yöntemler

Kalitatif yöntemler, tahmin süreçlerinde kişi veya grupların görüş ve yargılarına dayanan, genellikle geçmiş verilere ulaşamadığı ya da verilerin sınırlı olduğu durumlarda kullanılan bir yaklaşımdır. Bu yöntemler, geçmiş verilerin geleceği

öngörmede yetersiz veya duyarsız olduğu, uzun vadeli tahmin beklentilerinin bulunduğu ya da mevcut verilerin güvenilirlik ve tutarlılık açısından sorunlu olduğu durumlarda tercih edilir. Subjektif bir doğaya sahip olan kalitatif yöntemler, matematiksel analizlere dayanmaz ve genellikle uzmanların bilgi ve deneyimlerini esas alır. Özellikle yeni ürünlerin veya henüz olgunlaşmamış teknolojilerin gelecekteki performansını tahmin etmek için kullanılır. Bu yöntem, belirsizliklerin yüksek olduğu alanlarda fikir birliği sağlamak ve stratejik kararlar almak için değerli bir araçtır.

3.5.2 Kantitatif yöntemler

Kantitatif yöntemler, geçmiş dönemlerdeki sayısal verilere dayalı olarak tahmin yapılmasını sağlayan matematiksel modellere dayanır. Bu yöntem, geçmiş verilerin varlığını ve gelecekte durumun büyük ölçüde dengede kalacağını varsayar. Objektif ve standart bir yaklaşım sergileyen kantitatif yöntemler, kişisel yargılardan bağımsızdır ve birden fazla veri ve bilgiyi aynı anda dikkate alabilmektedir. Genellikle mevcut ürünler ve teknolojilerle ilgili tahminlerde tercih edilir. Tahminlerin doğruluğu, kullanılan verilerin kalitesine ve güvenilirliğine doğrudan bağlıdır; dolayısıyla iyi yapılandırılmış ve güvenilir verilere dayandığında sonuçlar da daha doğru olur. Matematiksel analizlerin kullanılması, bu yöntemi sistematik ve tekrarlanabilen bir tahmin aracı haline getirir.

3.5.3 Yapay zekâ tabanlı yöntemler

Yapay zekâ destekli teknikler, özellikle karmaşık sorunların çözümünde etkili yöntemler olarak öne çıkmaktadır. Literatürde, talep tahminleri için farklı yapay zekâ algoritmalarının kullanıldığı görülmektedir. En yaygın kullanılanlar arasında YSA, bulanık mantık ve genetik algoritmalar bulunmaktadır. Bu yöntemler, kantitatif teknikler olarak kullanılabilirliği gibi, uzman görüşlerini de hesaba katan yaklaşımlar da mevcuttur. Bu çalışmada, otomotiv tedarik zincirinde talep tahminini çözmek amacıyla YSA kullanılmıştır.

4. MATERYAL VE METOT

4.1 Materyal

Materyal bölümü, bir tezin temel yapı taşlarından biri olup, araştırmada kullanılan veri, araç ve kaynakların açıkça tanımlandığı bölümdür. Bu bölüm, çalışmanın dayandığı temelleri ortaya koyarak bilimsel bir çerçevede ilerlediğini kanıtlar. Araştırmada kullanılan veri setleri, yazılımlar ve diğer materyallerin belirtilmesi, çalışmanın güvenilirliğini artırır. Ayrıca, materyallerin detaylı bir şekilde tanımlanması, araştırmanın tekrar edebilmesini ve başka çalışmalar için kaynak teşkil etmesini sağlar.

Materyal bölümü, araştırmanın şeffaflığını ve yöntemsal tutarlılığını destekleyen önemli bir araçtır. Materyal bölümünde kullanılan araçlar, yöntemlerin seçiminde temel bir rol oynar ve çalışmanın yöntem bölümü ile doğrudan ilişkilidir. Çoklu doğrusal regresyon analizinde kullanılan veri setlerinin türü ve boyutu bu bölümde belirtilmektedir.

Ayrıca materyal bölümü, çalışmanın özgünlüğünü ve rekabet gücünü vurgular. Özellikle modern teknolojiler ve yenilikçi yöntemlerin kullanıldığı araştırmalarda, materyal bölümünde sunulan bilgiler, çalışmanın literatürdeki yerini güçlendirmektedir. Bu bilgiler, başka araştırmacılar için rehber niteliğinde olup, bilimsel iletişimi kolaylaştırır ve literatüre yeni katkılar sunulmasını destekler. Bu nedenle materyal bölümü, bir tezin akademik değerini ve bilimsel geçerliliğini belirleyen kritik bir unsurdur.

4.1.1 Eviews 10.0

Eviews, Windows işletim sistemi üzerinde çalışan bir istatistiksel paket programı olup özellikle ekonometrik analiz için yaygın olarak kullanılmaktadır.

Verilerin yönetilmesi, analiz edilmesi ve tahminlerin yapılması için güçlü araçlar sunar. Ayrıca, grafikler ve tablolar üretme, veri içe/dışa aktarma gibi işlemleri kolaylaştırır. Kopyala ve yapıştır işlemleri, nesne bağlama ve yerleştirme gibi standart Windows teknolojileriyle de desteklenmektedir. EViews, programlama ve komut dili

desteđi sunarak, tekrarlanan grevlerin otomatikleřtirilmesi ya da alıřmaların kaydının tutulabilmesi iin zelleřtirilmiř kod yazılmasına da olanak tanır.

4.1.2 IBM SPSS Statistics 30.0

SPSS (Statistical Package for the Social Sciences), IBM tarafından geliřtirilmiř bir veri analizi yazılımıdır. SPSS, farklı veri analizi tekniklerini iermektedir. Verilerin sayısal dađılımlarının (adet bazında) incelenmesinde frekans analizi kullanılır. Bu analizle elde edilen verilerin ortalama, standart sapma, mod ve medyan gibi deđerleri hesaplanarak, temel tanımlayıcı istatistikler elde edilir. Frekans analizi ve tanımlayıcı istatistikler, veri analizi iin basit ve yaygın olarak kullanılan yntemlerdir.

SPSS, kullanıcıların byk veri setlerini analiz etmelerine, veri setlerini grselleřtirmelerine ve sonuları raporlamalarına olanak tanır. SPSS, oklu deđiřkenli analiz, korelasyon, regresyon, faktr analizi gibi eřitli istatistiksel yntemleri desteklemektedir.

SPSS, akademik arařtırmalar, pazar arařtırmaları, sađlık arařtırmaları ve diđer birok alanda yaygın olarak kullanılmaktadır. SPSS'in aık kaynaklı bir alternatifi olan PSCP de bulunmaktadır. Bu yazılım, veri analizi ve istatistiksel alıřmalarda nemli bir yer tutar ve birok arařtırma projesinde tercih edilmektedir.

4.1.3 Knime 5.3.3

KNIME, Konstanz niversitesi'nin grsel veri madenciliđi arařtırma grubunun geliřtirdiđi bir yazılım aracıdır. KNIME adı, Konstanz Information Miner ifadesinin kısaltmasıdır.

KNIME, veriyi analiz etme, iřleme, grselleřtirme ve raporlama iřlemlerini iliřkilendirmeler yaparak gerekleřtiren bir veri analiz yazılımıdır. zellikle CRM ve iř zekâsı uygulamalarında veri analizi iin yaygın olarak kullanılır.

KNIME, modler bir iřlem hattı yapısına sahip olup, veri madenciliđi ve makine đrenimi ihtiyalarına ynelik eřitli bileřenler sunar. Bu bileřenler, programda 'node' olarak adlandırılır ve kod yazmaya gerek kalmadan detaylı iřlemler yapılmasını sađlar. Node'lar, sırasıyla alıřtırılır ve iřlemlerin ıktıları konsol aracılıđıyla izlenebilmektedir. Ayrıca, her node'a ait ıktılar ayrı ayrı grntlenebilmektedir.

4.2 Metot

4.2.1 Model verileri

Çalışma kapsamı içerisindeki amaçlardan biri bilinen bir ürüne ait geçmiş maliyet verileri ile geleceğe yönelik tahmin gerçekleştirebilen bir model üretebilmektir. İkinci bir çalışma amacı olarak, aynı ürüne ait geçmiş satış adetleri ile geleceğe yönelik tahmin gerçekleştirebilen bir model daha üretebilmektir. Elde edilmesi amaçlanan bu iki model sonucu tahminlenen ürün maliyet ve satış adetleri ile geleceğe yönelik harcama tutarlarına ulaşılması istenmektedir.

Gerekli analizlerin gerçekleştirilebilmesi için kullanılan X Ürünü Satış Miktarları, Hammadde Ücreti, Hurda Ücreti, Makine Saat Ücreti ve İşçilik Saat Ücreti verileri otomotiv sektöründe faaliyet gösteren bir sac metal parça üretici firmasından tedarik edilmiş gerçek verilerdir. Veri seti 2021 yılı ocak ayı ve 2023 yılı aralık ayı arasındaki aylık verilerden oluşmaktadır. Verilerin genel özellikleri çizelge 4.1’de açıklanmaktadır. Bahsedilen bu veriler tahmin edilmesi amaçlanan veriler olmasından kaynaklı, bağımlı değişkenler olarak tanımlanmaktadır. Bağımlı değişkenler, bağımsız değişkenlerin değişiminden etkilenen ve asıl olarak ilgilenilen değişkenlerdir.

Çizelge 4.1 : Bağımlı değişkenlerin genel özellikleri.

Değişken	Kısaltma	Birim	Veri Aralığı	Kaynak Tanımı	Kaynak
X Ürünü Satış Miktarları	ABSM	Adet	01.2021-12.2023	ÖZEL	Şirket Verileri
X Ürünü Maliyeti	ABML	Türk Lirası	01.2021-12.2023	ÖZEL	Şirket Verileri

Literatür araştırmasında karşılaşılan çalışmalar içerisinde yer alan değişkenler incelenerek, tahminleme sırasında modele etki edeceği düşünülen değişkenlere karar verilmiştir. Bahsedilen bu veriler bağımlı değişken üzerinde etkisi incelenecek olan veriler olmasından kaynaklı bağımsız değişkenler olarak tanımlanmaktadır. Diğer bir deyişle bağımsız değişkenler, modelin açıklayıcı değişkenleridir.

Çalışma içerisinde incelenecek olan değişkenlerin verilerinin toplanması aşamasında çeşitli kaynaklardan yararlanılmıştır. Veri seti 2021 yılı ocak ayı ve 2023 yılı aralık

ayı arasındaki aylık verilerden oluşmaktadır. İlgili verilere ait genel özelliklerin açıklandığı tablo çizelge 4.2 olarak aşağıda yer almaktadır.

Çizelge 4.2 : Bağımsız değişkenlerin genel özellikleri.

Değişken	Kısaltma	Birim	Veri Aralığı	Kaynak Tanımı	Kaynak
USD Satış Fiyatı	USD	Türk Lirası	01.2021-12.2023	TCMB	https://evds2.tcmb.gov.tr
EURO Satış Fiyatı	EUR	Türk Lirası	01.2021-12.2023	TCMB	https://evds2.tcmb.gov.tr
Motorlu Kara Taşıt Sayısı	MKTS	Adet	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Sanayi Üretim Endeksi	SÜE	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Ticaret Satış Hacim Endeksi - Motorlu Kara Taşıtlarının Ticareti Toplam	SMKT	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Sanayi Ciro Endeksi	TSCE	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Dayanıklı Tüketim Mallarına Yönelik Harcama Yapma Düşüncesi Genel	DTMH	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Ekonomik Durum Hanenin İçinde Bulunduğu Mali Durum	GED	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Hanenin İçinde Bulunduğu Mali Durum	MALİ	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Hanenin Maddi Durumu	MADDİ	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
İşsiz Sayısı Beklentisi	İSB	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/

Çizelge 4.2 (devam): Bağımsız değişkenlerin genel özellikleri.

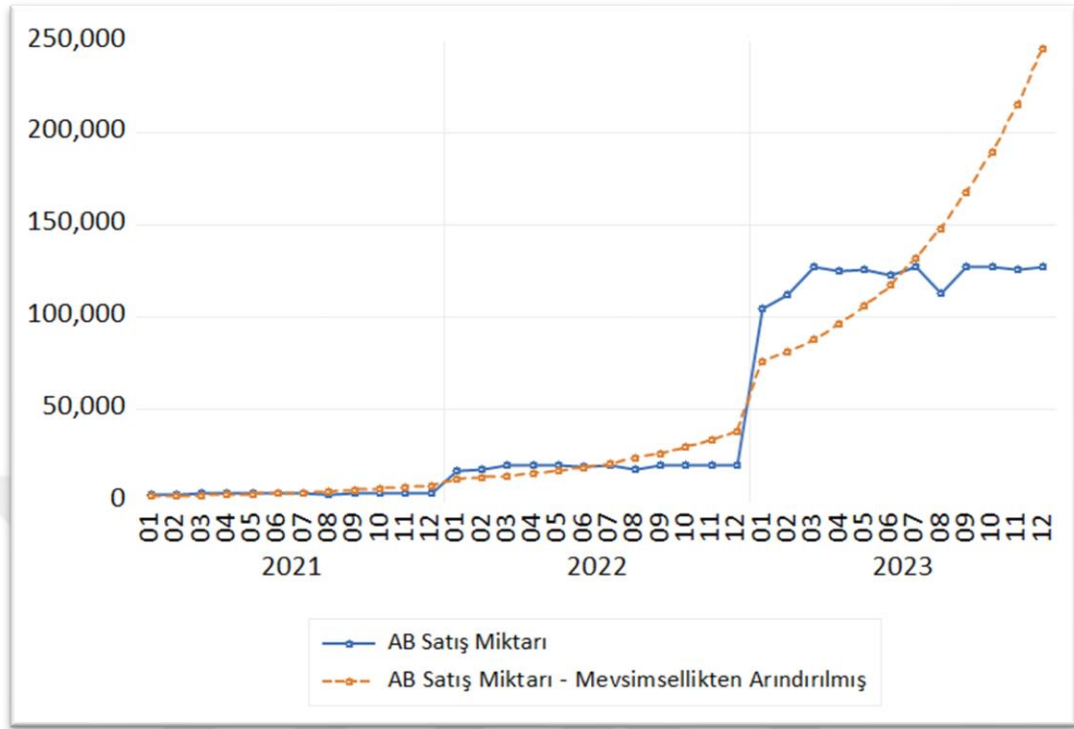
Değişken	Kısaltma	Birim	Veri Aralığı	Kaynak Tanımı	Kaynak
Mevcut Dönemin Tasarruf Etmek İçin Uygunluğu	TEUY	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Otomobil Satın Alma İhtimali	OSAI	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Tasarruf Etme İhtimali	TAEİ	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Tüketici Fiyatlarının Değişimine İlişkin Düşünce	TFDD	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Tüketimin Finansmanı Amacıyla Borç Kullanma İhtimali	TFBK	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Ücretlerin Değişimine İlişkin Beklenti	ÜDİB	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/
Tüketici Güven Endeksi	TGÜE	Endeks	01.2021-12.2023	TÜİK	https://data.tuik.gov.tr/

4.2.2 Verilerin mevsimsellikten arındırılması

Veriler, Eviews 10.0 yazılımının Tramo/Seats modülü kullanılarak mevsimsellik etkilerinden arındırılmıştır. Zaman içerisindeki farklı dönemlere ait değerlerin doğru bir şekilde karşılaştırılabilmesi için mevsimsellikten arındırma işleminin gerçekleştirilmesi gerekmektedir. Tramo/Seats modülü, fark alma işlemleri, otoregresyon ve hareketli ortalama değerlerini otomatik olarak belirleyerek hem zaman serisi tahminlerini üretir hem de mevsimsellik katsayılarının hesaplanmasını sağlar.

Verilerin mevsimsellikten arındırılma işleminden sonra bağımlı değişkenler ve bu değişkenlere ait mevsimsel etkilerden arındırılan veriler grafiklerle görselleştirilmiştir.

Şekil 4.1’de X satış miktarı verileri ve verilerin mevsimsellikten arındırılmış hali gösterilmektedir.



Şekil 4.1 : X satış miktarı verilerine ait mevsimsellikten arındırma grafiği.

4.2.3 Çoklu doğrusal regresyon modeli uygulaması

Çalışmanın bu kısmında çoklu regresyon modelinin uygulanabilmesi için gerekli tüm testler yapılmış ve bu testlerin sonuçlarına dayanarak bağımsız değişkenler ile bağımlı değişken arasındaki ilişki açıklanmıştır.

Çoklu regresyon analizi, IBM SPSS Statistics programı kullanılarak gerçekleştirilmiştir. Analiz sırasında, dört farklı yöntemden biri olan Enter yöntemi tercih edilmiştir. Enter yöntemi, literatürde en sık kullanılan tekniklerden biridir. Bu yaklaşımda, tüm bağımsız değişkenler modele dahil edilerek bağımlı değişkenin açıklama düzeyi incelenmiş ve bağımsız değişkenlerin tek bir adımda bir blok halinde modele eklenip değerlendirilmesi sağlanmıştır.

X ürünlerinin satış miktarları, hammadde maliyeti, hurda maliyeti, makine saatlik ücretleri ve işçilik saatlik ücretlerinin minimum, maksimum, ortalama, standart sapma ve varyans gibi tanımlayıcı istatistiksel değerleri, Çizelge 4.3'te sunulmuştur. Tabloyu oluştururken değişkenler için kısaltmalar kullanılmıştır.

Çizelge 4.3 : Bağımlı değişkenlerin tanımlayıcı istatistik değerleri.

Değişkenler	N	Minimum	Maksimum	Ortalama	Standart Sapma	Varyans
XSM	36	2485,7	245778,2	54841,4	68213,9	4653135005,7
XML	36	35,0	150,3	115,3	35,3	1249,3

XSM değişkeni olan X ürünü satış miktarları, minimum 2485,7 adet ile maksimum 245778,2 adet değerleri arasında değişmektedir. Ortalama değeri 54841,4 adettir. Standart sapması 68213,9 adettir.

XML değişkeni olan X ürünü satış maliyeti, minimum 34,96 TL ile maksimum 150,3 TL değerleri arasında değişmektedir. Ortalama değeri 115,3 TL'dir. Standart sapması 35,3 TL'dir.

Çalışmada kullanılan bağımsız değişkenlerin minimum, maksimum, ortalama, standart sapma ve varyans gibi tanımlayıcı istatistiksel değerleri, Çizelge 4.4'te sunulmaktadır. Çizelgede, değişkenlere ait kısaltmalar yer almaktadır.

Çizelge 4.4 : Bağımsız değişkenlerin tanımlayıcı istatistik değerleri.

Değişkenler	N	Minimum	Maksimum	Ortalama	Standart Sapma	Varyans
USD	36	6,5	28,4	16,3	6,6	43,1
EUR	36	8,8	31,3	17,8	6,7	45,0
MKTS	36	24281077,0	28755121,0	26099998,5	1296234,2	1680223109938,1
SÜE	36	130,3	149,5	141,6	5,4	29,5
SMKT	36	84,2	157,3	121,1	23,9	573,3
TSCE	36	76,4	399,2	211,3	98,9	9779,3
DTMH	36	87,5	99,1	93,1	3,1	9,8
GED	36	36,9	61,3	50,3	6,7	45,3
MALİ	36	67,7	81,9	73,8	3,2	10,3
MADDİ	36	44,5	70,6	59,3	6,4	40,8
İSB	36	63,1	89,4	70,9	5,8	34,2
TEUY	36	56,6	76,1	65,7	5,0	25,1
OSAI	36	9,1	19,3	13,1	2,5	6,0
TAEİ	36	24,4	40,7	31,5	3,7	13,8
TFDD	36	10,6	30,3	19,0	4,6	21,0
TFBK	36	47,4	57,8	51,9	2,2	4,8
ÜDİB	36	98,9	131,9	114,7	10,1	101,9
TGÜE	36	63,4	91,1	76,6	6,4	41,2

4.2.3.1 Değişkenlerin normalliği

Çoklu doğrusal regresyon modelinin oluşturulabilmesi için verilerin normal dağılım göstermesi gerekmektedir. Verilerin normallikten sapması arttıkça, dağılımın daha fazla bozulduğu gözlemlenmektedir. Çarpıklık, dağılımın simetrisini bozan, sağa ya da sola kayma durumunu belirtirken, basıklık ise dağılımın daha sivri ya da daha düz olma durumunu ifade eder. Bu tür analizlerde ortalama, medyan ve standart sapma gibi değerler kullanılmaktadır. Çarpıklık ve basıklık değerlerinin +1,5 ile -1,5 arasında olması, verilerin normal dağılıma uygun olduğunu gösteren bir işarettir (Tabachnick ve Fidell, 2013). Çalışmada kullanılan veri setlerinin normal dağılıma uygunluğunu test edebilmek amacıyla çarpıklık ve basıklık değerleri incelenmiştir. Çizelge 4.5'te bu değişkenlere ait çarpıklık ve basıklık değerleri sunulmaktadır.

Çizelge 4.5 : Değişkenlerin çarpıklık ve basıklık değerleri.

Değişkenler	Çarpıklık	Basıklık
ABSM	1,40	0,99
ABML	0,28	-1,02
USD	0,20	-1,01
EUR	0,42	-0,78
MKTS	0,51	-0,81
SÜE	-0,73	-0,64
SMKT	0,21	-1,54
TSCE	0,26	-1,02
DTMH	0,09	-0,87
GED	-0,14	-0,86
MALİ	0,49	0,15
MADDİ	-0,38	-0,20
İSB	1,27	2,13
TEUY	-0,08	-0,74
OSAI	0,30	-0,28
TAEİ	0,53	0,15

Çizelge 4.5'te gösterilen analiz değerlerine bakıldığında SMKT (Ticaret Satış Hacim Endeksi-Motorlu Kara Taşıtlarının Ticareti) ve İSB (İşsiz Sayısı Beklentisi) değişkenlerine ait çarpıklık ve basıklık değerlerinin, belirtilen -1,5 ve +1,5 kritik değerlerinin dışında kaldığı görülmektedir. Bu nedenle, regresyon modelinin temel

koşullarından biri olan normallik varsayımını karşılamadıkları için SMKT ve İSB değişkenleri modelden çıkarılmıştır.

4.2.3.2 Bağımlı ve bağımsız değişkenler arası korelasyon

Çoklu doğrusal regresyon modelinin oluşturulabilmesi için bir diğer gereklilik, bağımlı ve bağımsız değişkenler arasındaki ilişkinin doğrusal olmasıdır. Bu ilişkinin doğrusal olup olmadığının tespit edilebilmesi için Pearson Korelasyon testi uygulanmıştır.

Korelasyon analizi, iki nicel değişken arasındaki doğrusal ilişkinin gücünü ve yönünü sayısal olarak belirler. Pearson korelasyon katsayısı (r), -1 ile +1 arasında bir değer alır. Katsayının işareti ilişkinin yönünü gösterir: (+) pozitif ilişki (bir değişken arttıkça diğerinin de arttığı ya da bir değişken azalırken diğerinin de azaldığı), (-) negatif ilişki (bir değişken arttıkça diğerinin azaldığı ya da bir değişken azalırken diğerinin arttığı) anlamına gelir. Korelasyon katsayısının mutlak değeri ise iki değişken arasındaki ilişkinin gücünü ifade eder. Katsayının 0 olması, değişkenler arasında doğrusal bir ilişki bulunmadığını; +1 veya -1 olması ise mükemmel doğrusal bir ilişki olduğunu gösterir (Pallant, 2017; Field, 2009).

Pearson Korelasyon analizi sonuçlarının gösterildiği çizelge 4.6'da anlaşıldığı gibi X ürünü satış miktarları bağımlı değişkeniyle p değeri 0,05'in üzerinde çıkan DTMH (Dayanıklı Tüketim Mallarına Yönelik Harcama Yapma Düşüncesi), GED (Genel Ekonomik Durum), MALİ (Hanenin İçinde Bulunduğu Mali Durum), MADDİ (Hanenin Maddi Durumu), TEUY (Mevcut Dönemin Tasarruf Etmek İçin Uygunluğu), OSAI (Otomobil Satın Alma İhtimali), TAEİ (Tasarruf Etme İhtimali), TFBK (Tüketimin Finansmanı Amacıyla Borç Kullanma İhtimali) ve TGÜE (Tüketici Güven Endeksi) değişkenleri olmuştur. Bu da göstermektedir ki X ürünü satış miktarları ile DTMH, GED, MALİ, MADDİ, TEUY, OSAI, TAEİ, TFBK ve TGÜE verileri arasında anlamlı bir ilişki bulunmamaktadır. Dolayısıyla ilgili değişkenler modelden çıkarılmıştır.

Çizelge 4.6 : Pearson Korelasyon testi çıktıları.

Değişkenler	Pearson Correlation	Sig. (2-tailed)
USD	0,895	0,000
EUR	0,925	0,000
MKTS	0,942	0,000
SÜE	0,499	0,002
TSCE	0,898	0,000
DTMH	-0,068	0,695
GED	-0,260	0,126
MALİ	-0,038	0,824
MADDİ	-0,093	0,589
TEUY	0,114	0,507
OSAI	0,041	0,814
TAEİ	-0,038	0,824
TFDD	-0,334	0,046
TFBK	-0,038	0,825
ÜDİB	0,419	0,011
TGÜE	0,095	0,581

4.2.3.3 Çoklu doğrusallık sorunu

Çoklu doğrusal regresyon modeli kurulması sırasında bağımsız değişkenlerin kendi aralarında yüksek bir ilişki olduğunda regresyon sonuçları olumsuz yönde etkilenebilmektedir. Bağımsız değişkenler arasında var olan bu yüksek ilişki çoklu doğrusallık sorunu olarak tanımlanmaktadır. Çoklu doğrusallık, R^2 sınırlarının yüksek olması ve regresyon katsayılarının güvenilirliğinin şüpheli hale gelmesi anlamına gelir (Decoster ve Claypool, 2004; Bryman ve Cramer, 1999). Bağımsız değişkenler arasında yüksek doğrusal ilişki bulunan analizler geçerli olarak kabul edilmez.

Çoklu doğrusallık sorununun ortadan kaldırılabilmesi için değişkenlere ait Varyans Büyütme Faktörü (VIF) değerlerinin analiz edilmesi gerekmektedir. VIF, bir bağımsız değişkenin diğer bağımsız değişkenlerle ne kadar güçlü bir ilişki içinde olduğunu gösteren bir ölçüttür.

VIF değerinin yüksek olması, bağımsız değişkenlerin etkilerinin doğru bir şekilde ölçülemediğini ve standart hata değerlerinin şiştiğini gösterir. Bu durum, tahmin

sonuçlarının istatistiksel anlamlılıklarını yanlış yorumlamaya yol açabilmektedir. Bu nedenle, regresyon modelinin güvenilir olması için VIF değerlerinin düşük tutulması hedeflenir. Çizelge 4.7’de analiz ettiğimiz değişkenlerin VIF ve tolerans değerleri yer almaktadır.

Çizelge 4.7 : Varyans Büyütme Faktörü ve Tolerans parametreleri.

Değişkenler	Tolerans	VIF
USD	0,003	366,048
EUR	0,004	229,955
MKTS	0,013	76,023
SÜE	0,385	2,597
TSCE	0,003	307,396
TFDD	0,502	1,993
ÜDİB	0,557	1,795

Tablo 4.7’de gösterildiği gibi, Varyans Büyütme Faktörü değerleri 10 ‘dan büyük olan USD, EUR, MKTS ve TSCE değişkenleri çoklu doğrusallık sorunu olarak tanımlanan durumu oluşturabilmektedir.

Farklı kaynaklarda bahsedildiği gibi tolerans değerlerinin 0,2 değerinden büyük gelmemesi durumu da çoklu doğrusallık sorunu oluşturabilmektedir. İlgili değişkenler tolerans değerleri bakımından incelendiğinde 0,2 değerinden düşük gelmektedir.

Bu adımda modelden çıkarılması gereken değişkenlerin tespiti için son adım olan, değişkenlerin birbiri arasındaki korelasyon katsayılarının incelemesi gerçekleştirilmiştir. Bağımsız değişkenlerin birbiri arasındaki korelasyon katsayısının 0,8’den yüksek olması durumu çoklu doğrusallık sorunu oluşturabilecektir. Çizelge 4.8’de çalışması sürdürülen değişkenlerin korelasyon katsayıları yer almaktadır.

Çizelge 4.8 : Değişkenlerin Korelasyon katsayıları.

	ABSM	USD	EUR	MKTS	SÜE	TSCE	TFDD	ÜDİB
ABSM	1,000	0,895	0,925	0,942	0,499	0,898	-0,334	0,419
USD	0,895	1,000	-0,996	0,988	0,724	0,998	-0,480	0,489
EUR	0,925	0,996	1,000	0,992	0,705	0,995	-0,450	0,486
MKTS	0,942	0,988	0,992	1,000	0,673	0,987	-0,454	0,478
SÜE	0,499	0,724	0,705	0,673	1,000	0,723	-0,464	0,447
TSCE	0,898	0,998	0,995	0,987	0,723	1,000	-0,469	0,485
TFDD	-0,334	-0,480	-0,450	-0,454	-0,464	-0,469	1,000	-0,593
ÜDİB	0,419	0,489	0,486	0,478	0,447	0,481	-0,593	1,000

Bağımsız değişkenlerden birbiri arasında 0,8'den yüksek bir orana sahip korelasyon katsayısı sağladığı değişkenler çizelge 4.8'de belirtildiği gibi USD, EUR ve TSCE değişkenleridir.

Çoklu doğrusallık sorununun tespiti için yapılan incelemeler sonucunda USD, EUR ve TSCE değişkenlerine ait verilerin VIF ve tolerans değerleri kabul edilen aralıklardan yer almadığı, ayrıca bağımsız değişkenler arası kabul edilen aralıklardaki korelasyon katsayılarına da sahip olmadığı görülmüştür. Belirtilen sebeplerle USD, EUR ve TSCE değişkenlerine ait veriler modelden çıkarılmıştır.

4.2.3.4 Farkların normalliği


Bağımlı değişken olan ABSM değişkeninin regresyon modelinin kurulmasına ait çalışmalar SÜE, TFDD, ÜDİB ve MKTS bağımsız değişkenleri ile tekrardan analiz edilmiştir. Çoklu regresyon modelinin bir diğer gerekliliği, model tarafından tahmin edilen değerlerle gözlemlenen değerler arasındaki farklardan kaynaklanan tahmin hatalarının normal bir dağılım göstermesidir.

Bahsedilen farkların normal dağılımı, Farkların Normalliği olarak da tanımlanmaktadır. Normallik varsayımı, tahmin hatalarının her bir bağımlı değişken değeri etrafında normal bir dağılım göstermesi durumudur (Tabachnick ve Fidell, 2013). Bu varsayımın test edilmesi için, bağımlı değişkenin standartlaştırılmış tahmin

değerleri (ZPRED) ile standartlaştırılmış artık değerler (ZRESID) arasında yapılan histogram dağılımı ve Normal P-P grafiği incelenir. Bu artık değerler, gözlemlenen veriler ile modelin tahmin ettiği değerler arasındaki standartlaştırılmış farkları temsil eder.


Farkların normalliğini izleyebilmek adına histogram dağılımında verilen verilerin çan eğrisi şeklinde olması beklenmektedir. Grafikte aykırı duran veriler normal dağılımın bozulmasına etki etmekte olabilmektedir. Normal P-P grafiğinde farkların normal dağılımını izleyebilmek için ise verilere ait noktaların, oluşan 45 derecelik çizginin üstünde ya da yakınlarında olması beklenmektedir.

Şekil 4.2’de yer alan histogram dağılımında standartlaştırılmış tahmin ve artık değerlerine ait veriler yer almaktadır. İlgili histogram dağılımında çan eğrisini bozmakta olan bir verinin mevcut olduğu gözükmektedir.



Şekil 4.2 : Standartlaştırılmış tahmin ve artık değerlerinin histogram dağılımı.

Şekil 4.3’te yer alan Normal P-P grafiğinde standartlaştırılmış tahmin ve artık değerlerine ait veriler yer almaktadır. İlgili grafikte yansıtılan verilerin genel olarak, oluşan 45 derecelik çizginin üstünde yer aldığı görülmektedir.



Şekil 4.3 : Standartlaştırılmış tahmin ve artık değerlerinin Normal P-P grafiği.

Farkların normalliği konusunda karar verebilmek adına incelenen iki grafikten ikisinde de uç değer sayılabilecek ve verilerin normalliğine etki edebilecek bir değere rastlanmamaktadır. İlgili grafiklerin incelenmesi sonucu hataların normal dağılıma sahip olduğu yorumlanabilmektedir.

4.2.3.5 Otokorelasyon tespiti

Otokorelasyon varlığı, çoklu doğrusal regresyon modeli kurulması sırasında istenmeyen bir durumdur. Özellikle zaman serisi içeren regresyon modellerinde t anındaki hata değeri ile gecikmeli hata değerleri arasında pozitif bir ilişkinin bulunması, varyansların olduğundan küçük bulunmasına sebep olabilmektedir. Bu durum ise t ve F istatistik değerlerinin ve R^2 değerinin olduğu değerden büyük çıkmasına sebep olabilmektedir. Böylece aslında herhangi bir açıklayıcılığı bulunmayan bir katsayının anlamlı ve yüksek düzeyde bir ilişki değerine sahip çıkması sorunu ile karşı karşıya kalınabilmektedir (Güler, 2021).

Otokorelasyon probleminin tespiti için grafikler, sıra testi, LM testi, Durbin-Watson testi, Wallis testi ve Von-Neumann testi gibi çeşitli yöntemler kullanılabilir. Modellerin veri büyüklüğü, sabit katsayının varlığı ve modelin doğrusal olup olmaması gibi faktörlere bağlı olarak, uygun otokorelasyon testi seçimi değişiklik gösterebilmektedir. Ancak, parametrik sabit katsayıya sahip modellerde genellikle Durbin-Watson testi tercih edilmektedir.

$$d = \frac{\sum_{t=2}^n (c_t - c_{t-1})^2}{\sum_{t=1}^n (c_t)^2} \quad (4.1)$$

(4.1) denkleminde t zamanındaki artık deęerler c ile ifade edilmekte olup, hesaplanan d deęeri Durbin-Watson tablosundaki kritik deęerlerle karřılařtırılmaktadır. Bu baęlamda;

- $0 < d < dL$ aralıęında pozitif otokorelasyon,
- $dL \leq d \leq dU$ aralıęında kararsızlık,
- $dU < d < 4 - dU$ aralıęında otokorelasyonun yokluęu,,
- $4 - dU \leq d \leq 4 - dL$ aralıęında kararsızlık,
- $4 - dL < d < 4$ aralıęında ise negatif otokorelasyon durumu söz konusudur (Yavuz, 2009).

Otokorelasyon varlıęının incelemesi model çıktılarının incelemesi sonucunda analiz kısmında gerekleřtirilecektir.

4.2.3.6 Çoklu doęrusal regresyon modelinin yazılması

oklu doęrusal regresyon modelinin yapılan analizler sonucu elde edilen veriler ile matematiksel olarak ifade edilmesi gerekmektedir. Bu erevede oklu doęrusal regresyon denkleminin yazılması iin detaylara ařaęıda yer verilmektedir.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + c \quad (4.2)$$

(4.2) denklemine gre, n sayıda baęımsız x deęiřkeni kullanılarak y baęımlı deęiřkeni oklu doęrusal regresyon yntemiyle modellenmektedir. Burada β_0 sabit katsayıyı, β_1 , β_2 , ..., β_n ise sırasıyla baęımsız deęiřkenlerin katsayılarını temsil eder. Ayrıca, c hata terimini ifade etmektedir. Denklemden grlebileceęi zere, her bir y gzlem deęeri doęrudan regresyon doęrusu zerinde yer almayabilmektedir. Bu denklem, x deęiřkenleri ile y deęiřkeni arasındaki iliřkiyi optimum hata ile en iyi şekilde aıklayabilmek iin matematiksel bir yntem sunmayı amalamaktadır.

Yapılan analizler sonucu elde edilen oklu doęrusal regresyon modelinin matematiksel olarak ifade edilmesi model ıktılarının incelemesi sonucunda analiz kısmında gerekleřtirilecektir.

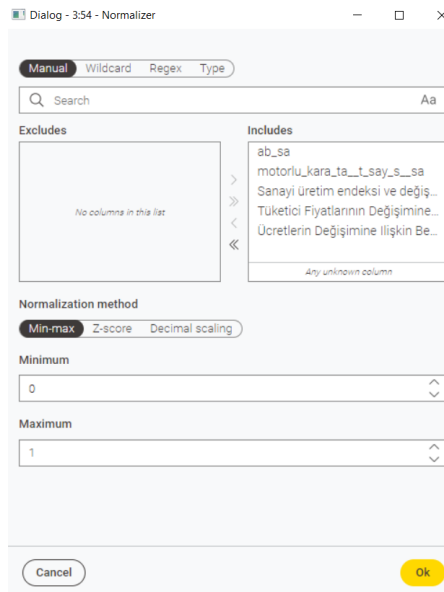
4.2.4 Makine öğrenmesi modellerinin uygulamaları

Makine öğrenmesi modellerinin uygulamaları başlığı altında, Knime 5.3.3 makine öğrenmesi programı üzerinden X ürünü satış miktarları ve X ürünü maliyetlerine ilişkin kurulan tahmin modeli anlatılacaktır.

Çoklu doğrusal regresyon modeli çıktıları ışığında model içerisinde kullanılacak bağımsız değişkenler SÜE, MKTS, TFDD ve ÜDİB olarak seçilmiştir. X ürünü satış miktarları ve X ürünü maliyetleri olmak üzere her iki bağımlı değişken için de aynı bağımsız değişkenlerin çoklu doğrusal regresyon modelinde kullanıldığı görülmektedir.

Knime platformunda geliştirilen modelde, önceki aşamalarda Eviews programı ile mevsimsel etkilerden arındırılan X ürünü satış miktarı, X ürünü maliyeti, SÜE, MKTS, TFDD ve ÜDİB verileri kullanılmaktadır.

Kurulan modelin güvenilirliğini artırmak adına veriler Knime programı içerisinde bulunan “Normalizer” düğümü kullanılarak normalize edilmiştir. Normalizasyon işlemi, verilerin değer aralığının 0 ile 1 arasına çekilmesini ifade eder. Bu işlem sayesinde, farklı ölçeklerdeki veriler ortak bir standarda getirilir ve analizlerde tutarlılık sağlanır. “Normalizer” düğümünün gerçekleştirilen ayarlarına ilişkin görsel şekil 4.4’te yer almaktadır.



Şekil 4.4 : Normalizer düğümü gerçekleştirilen ayarları.

Şekil 4.4'te görüldüğü gibi normalizasyon işlemi min-max yöntemine göre yapılmıştır.

$$X' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4.3)$$

(4.3) denkleminde min-max normalizasyon işlemi gösterilmektedir. Bu formülde X, normalizasyonu yapılacak olan orijinal veri değerini ifade ederken, min(x) ve max(x) sırasıyla veri setindeki minimum ve maksimum değerlerdir. X' ise normalizasyon sonucu elde edilen ve genellikle 0 ile 1 arasında yer alan yeni değeri temsil eder. Bu işlem, tüm veri setindeki değerleri aynı ölçeğe getirerek farklı değişkenler arasında adil bir karşılaştırma yapılmasını sağlar.

4.2.4.1 Eğitim ve test verilerinin belirlenmesi

Makine öğrenmesi modellerinin geliştirilmesi ve doğrulanmasında en kritik adımlardan biri, veri setlerinin eğitim ve test veri kümelerine doğru bir şekilde ayrılmasıdır. Bu işlem, modelin hem öğrenme sürecinde başarılı sonuçlar üretmesini hem de yeni, görülmemiş veriler üzerinde güvenilir tahminler yapabilmesini sağlamak için büyük önem taşır.

Makine öğrenmesi sürecinde veri setlerinin ayrılmasının temel amacı, oluşturulan modelin genelleme kapasitesini ölçmek ve aşırı öğrenme (overfitting) riskini minimize etmektir. Eğitim veri seti, modelin öğrenme sürecinde kullanılır. Model, bu veriler üzerinden belirli örüntüleri ve ilişkileri keşfederek parametrelerini ayarlar. Test veri seti ise modelin performansını, daha önce görmediği yeni veriler üzerinde ölçmek için kullanılır. Bu, modelin yalnızca eğitim verilerine bağlı kalmadan, genel geçer ve uygulanabilir sonuçlar üretip üretmediğini değerlendirmek açısından önemlidir.

Modelde KNIME programı üzerinde verilerin eğitim ve test verileri olarak ayrılmasını sağlayan iki farklı modül kullanılmıştır. Bu modüller "Partitioning" ve "X-Partitioner" modülleridir.

Partitioning modülü, genellikle standart veri bölümlendirme işlemleri ile veri setlerini eğitim ve test kümelerine ayırmak için tercih edilir. Kullanıcı, veri setini rastgele, sıralı veya katmanlı yöntemlerle bölebilmektedir. Ayrıca, kullanıcı veri setinin hangi yüzdesinin eğitim ve hangi yüzdesinin test verisi olarak kullanılacağını da modül içerisinden belirleyebilmektedir.

X-Partitioner modülü ise daha gelişmiş bir veri bölümlendirme işlemi olan k-katlamalı çapraz doğrulama yöntemi için geliştirilmiş bir modüldür. Bu yöntem, veri setini k

adet eşit parçaya böler ve her bir parça sırayla test verisi olarak kullanılırken kalan parçalar eğitim verisi olarak değerlendirilir. Bu süreç, modelin farklı veri kümeleri üzerindeki performansını ölçmek ve aşırı öğrenme riskini azaltmak için tercih edilen bir yöntemdir.

Model içerisinde kullanacak olan eğitim ve test verilerinin model doğruluğunu etkilemesinden kaynaklı iki farklı veri bölümlenme modülünün de model içerisinde test edilmesine karar verilmiştir. Model içerisinde kullanılacak olan veri bölümlenme modüllerinin detayları çizelge 4.9'da yer almaktadır.

Çizelge 4.9 : Veri bölümlere modülleri ve detayları.

Veri Bölümlenme Modülü	Sıralı Örneklem	Rastgele Örneklem
Partitioning	%70 - %30	%70 - %30
X-Partitioner	K=10	K=10

Veri bölümlendirme işlemlerinde yaygın olarak kullanılan yöntemlerden biri, verilerin %70'inin eğitim seti, %30'unun ise test seti olarak ayrılmasıdır. Bu oran, modelin hem öğrenme sürecinde yeterli veriyle beslenmesini hem de doğrulama aşamasında güvenilir sonuçlar vermesini sağlar.

K-katlamalı çapraz doğrulama yönteminde ise veri seti genellikle 10 eşit parçaya bölünür. Bu yöntemle, her seferinde farklı bir parça test verisi olarak kullanılırken geri kalan 9 parça eğitim için kullanılır. Böylece tüm veriler, farklı kombinasyonlarla hem eğitim hem de test aşamalarında değerlendirilmiş olur.

Rastgele veri seçimi, genellikle modelin performansını artırsa da tutarlı ve karşılaştırılabilir sonuçlar elde edebilmek adına sıralı veri bölümlendirme yöntemleri de kullanılmıştır. Bu yaklaşım, aynı eğitim ve test setleri üzerinde daha sağlıklı analizler yapılmasına olanak tanır.

4.2.4.2 Yapay sinir ağları

YSA insan beyninin çalışma prensiplerinin bilgisayar ortamında taklit edilmesi amacıyla geliştirilmiştir. İlk başlarda, beynimizdeki nöronların matematiksel modelleri oluşturulmaya odaklanılmıştır (Yıldırım, 2019). YSA, öğrenme süreçlerini geçmiş deneyimlerden elde edilen verilerle gerçekleştirmektedir. Bu öğrenme

süreçlerinin doğru ve etkili olabilmesi için kullanılan verilerin tutarlı ve doğru olması gerekmektedir.

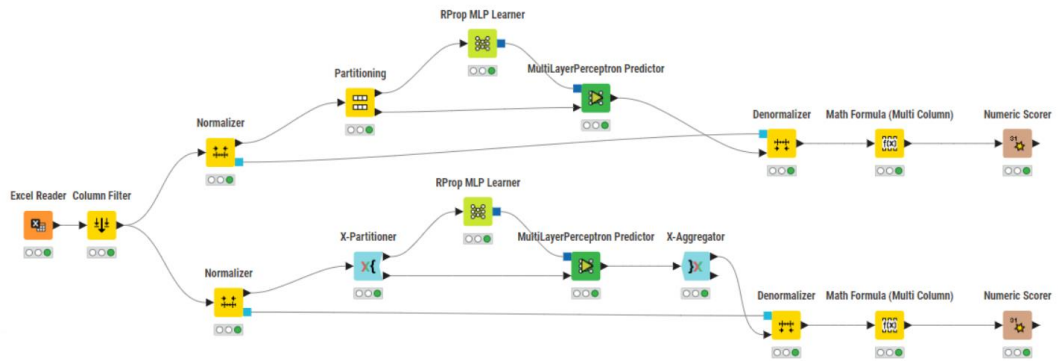
YSA, "kara kutu" olarak da tanımlanır. Bu tanımlama, ağların dışarıdan nasıl çalıştığının genellikle anlaşılmadığı, ancak girdileri alıp bu verileri işleyerek uygun sonuçları ürettikleri anlamına gelir. YSA, çeşitli algoritmalar ve yaklaşımlar kullanarak veri toplama, analiz etme ve bu verilerle kararlar alma sürecini gerçekleştirir (Rizvanche, 2020).

YSA'nın makine öğrenmesi modelinde kullanılacak parametre seçiminde kesin bir yöntem olmadığı için, optimum parametreler belirlenip diğer parametrelerin performans üzerindeki etkilerinin değişmediği aralıklar tespit edilmiştir. Bu tespit, parametrelerin tekrarlı bir şekilde test edilmesiyle gerçekleştirilmiştir. YSA kullanılırken tercih edilen parametreler, verilerin çeşitliliği, boyutu ve karmaşıklık seviyesine bağlı olarak farklılık göstermektedir. Bu uygulama için belirlenen parametreler, çizelge 4.10'da gösterildiği gibi uygulanmaktadır.

Çizelge 4.10 : Yapay sinir ağları parametre gösterimi.

Maksimum İterasyon Sayısı	Gizli Katman Sayısı	Gizli Katmandaki Nöron Sayısı
2.500	1	2
2.500	1	3
2.500	1	5
2.500	1	10
2.500	1	15
2.500	2	2
2.500	2	3
2.500	2	5
2.500	2	10
2.500	2	15

Modelin öğrenme sürecinde en yüksek verimi elde edebilmek için maksimum iterasyon sayısı, yapılan denemeler neticesinde belirlenmiştir. Modelin karmaşıklık seviyesi göz önünde bulundurularak, gizli katman sayısının bir ve iki adet olarak ölçülüp izlenmesine karar verilmiştir. Aynı zamanda modele ait gizli katmandaki nöron sayısının da gizli katman sayısı gibi, yapılan denemeler sonucu vereceği etkiler izlenmiştir. Yöntemin Knime programı üzerinde kurulmuş görüntüsü şekil 4.5'te yer almaktadır.



Şekil 4.5 : MLP yönetiminin Knime programı üzerinde modellenmesi.

Şekilde 4.5'te gösterilen modelin oluşturulması için ilk olarak, "Table Creator" düğümü ile veriler sisteme aktarılmıştır. Ardından, verilerin normalize edilmesi amacıyla "Normalizer" düğümü kullanılarak veriler 0 ile 1 arasında bir skala üzerine çekilmiştir. YSA modelinde kullanılacak değişkenler, "Column Filter" düğümü ile seçilmiş ve ardından veri seti, eğitim ve test setlerine ayrılmak üzere "Partitioning" düğümü ile bölünmüştür. Eğitim süreci, "Rprop MLP Learner" düğümü ile gerçekleştirilmiş ve gerekli parametreler ayarlanmıştır. Model eğitildikten sonra, test verileri "Multi Layer Perceptron Predictor" düğümü ile tahmin edilmiştir. Normalize edilen veriler, "Denormalizer" düğümü ile eski haline getirilmiş ve "Math Formula" düğümü kullanılarak tahmin edilen veriler eski veri aralıklarına dönüştürülmüştür. Son olarak, "Numeric Scorer" düğümü ile modelin doğruluğu ve hata değerleri hesaplanmış, R^2 değeri ve hata oranları elde edilmiştir. Bu adımlar, modelin doğruluğunu ve güvenilirliğini artırmayı amaçlamaktadır.

4.2.4.3 Gradyan arttırılmalı regresyon ağaçları uygulaması

GBRT modeli birden fazla basit regresyon ağacının birleştirilerek daha güçlü bir model oluşturduğu topluluk modelidir. Bu model algoritmanın aşamalı olarak

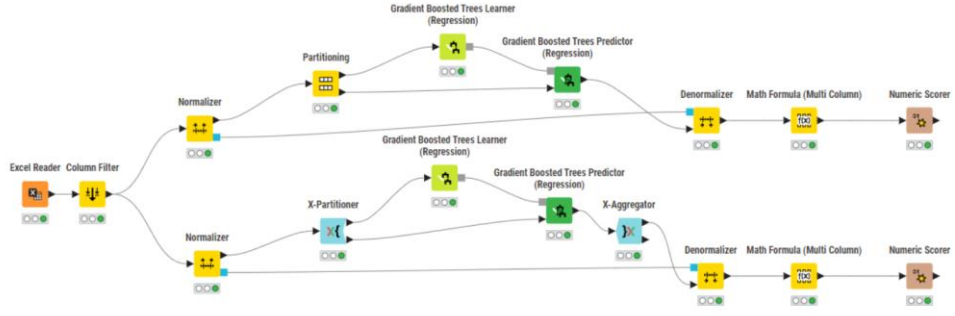
ilerlemesini sağlar. Her adımda, kayıp fonksiyonunun gradyanına dayalı olarak mevcut modelin hatalarını tahmin etmek amacıyla basit bir regresyon ağacı eklenir. Bu işlem, modelin giderek daha doğru ve karmaşık bir yapıya kavuşmasına olanak tanır. Aynı yaklaşım sınıflandırma problemleri için de uygulanabilmektedir. Bu yöntem, zayıf tahmin modellerinin, ardışık iterasyonlarla güçlendirilmesi ilkesine dayanır. Modelin her aşamada öğrenmesinin tekrarlanması, kayıp fonksiyonunun tanımlanmasını ve azaltılmasını amaçlar.

Bu aşamada, parametreler belirlenirken farklı değerlerle yapılan analizler sonucunda, ağaç derinliği dışındaki parametrelerin uygulama için seçilen veri kümesinde tekil ve optimum değerler olduğu gözlemlenmiştir. Makine öğrenmesi yöntemlerinin en önemli dezavantajlarından biri, genellikle optimal parametre aralıklarının belirgin olmaması ve doğru sonuçlara ulaşabilmek için deneme-yanılma yönteminin kullanılması gerekliliğidir. Modele uygun parametrelerin kesin olarak belirlenebilmesi için algoritma tarafından sağlanan net bir çözüm olmadığı için, yapılan analizler sonucunda optimum sonuçları veren parametreler tespit edilmiştir. Ağaç derinliğine ilişkin parametrelerin doğru değerinin seçimi ise elde edilen sonuçlarla açıklanacaktır. Bu uygulama için belirlenen parametreler, çizelge 4.11’de gösterildiği gibi uygulanmaktadır.

Çizelge 4.11 : GBRT parametre gösterimi.

Maksimum Karar Ağacı Sayısı	Öğrenme Oranı	Aykırı Değer Belirleme Oranı (1- Alfa)	Maksimum Ağaç Derinliği
100	0,1	0,05	2
100	0,1	0,05	3
100	0,1	0,05	5
100	0,1	0,05	10
100	0,1	0,05	15

Şekil 5.8’de, GBRT Knime programı üzerinde kurulmuş görüntüsü yer almaktadır. Modüllere ait detaylar bir önceki modelde anlatıldığı şekilde ayarlanmıştır. Bir önceki modelden farklı olarak ayarlanacak olan Gradient Boosted Trees Learner (Regression) modülü için çizelge 4.6’da yer alan parametreler işlenmiştir.



Şekil 4.6 : GBRT yönetiminin Knime programı üzerinde modellenmesi.

4.2.4.4 Ortalama mutlak yüzde hata

Makine öğrenmesi modellerinin doğruluğunu karşılaştırmak için en yaygın kullanılan ölçütlerden biri, MAPE kriteridir. MAPE, tahmin edilen değerlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçmek için kullanılan bir performans metriğidir. Bu kriterin hesaplanması, her bir hata değerinin (yani tahmin edilen değer ile gerçek değer arasındaki fark) gerçek değere bölünmesiyle başlar. Bu orana, her bir gözlem için Mutlak Yüzde Hata (APE) adı verilir. APE, her bir tahminin doğruluğunu yüzdesel olarak ifade eder. MAPE değeri, tüm gözlem noktalarındaki APE değerlerinin aritmetik ortalamasını alarak elde edilir. MAPE için tanımlayıcı matematiksel ifade aşağıda yer almaktadır.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (4.4)$$

(4.4) denlemine göre, y_i gerçek değerler, \hat{y}_i ise tahmin edilen değerlerdir. n ise toplam gözlem sayısını temsil eder.

MAPE'nin en belirgin avantajı, farklı birimlere sahip değişkenler arasındaki karşılaştırmaları kolaylaştırmasıdır. Ayrıca, MAPE, modelin tahminlerinde büyük sapmalar olsa bile, bu sapmaları orantısal olarak değerlendirir, böylece aşırı yüksek veya düşük değerlerin modelin genel performansını aşırı derecede etkilemesi önlenmiş olur. MAPE, veri setindeki yapısal değişikliklere karşı da oldukça dayanıklıdır ve modelin doğruluğunu değerlendirmek için objektif bir ölçüt sunar.

Özellikle farklı büyüklükteki verilerin analiz edilmesinde ve model karşılaştırmalarında, MAPE, model performansının doğru bir şekilde ölçülmesine olanak tanır ve çok farklı veri tipleri için etkili bir doğruluk ölçüsü sağlar.

5. ANALİZ BULGULARI

5.1 Çoklu Doğrusal Regresyon Modeli Bulguları

Çoklu doğrusal regresyon modelinin gereksinimleri önceki adımlarda yerine getirilmiştir. İlgili gereksinimleri sağlayan çoklu doğrusal regresyon modeli kurulmuştur. Modele ait bağımlı değişkenimiz X ürünün satış miktarları ve bağımsız değişkenlerimiz MKTS, SÜE, TFDD ve ÜDİB verilerinden oluşmaktadır. Modele ait analiz sonuçlarının özet verileri çizelge 5.1’de yer almaktadır.

Çizelge 5.1 : X satış miktarı çoklu doğrusal regresyon modeline ait özet veriler.

Model	R	R ²	Düzenlenmiş R ²	Std. Tahmin Hatası	Durbin-Watson
1	0,962	0,926	0,916	19712,361	2,229

Korelasyon katsayısının karesi olarak hesaplanan R² değeri, bağımlı değişkenin bağımsız değişkenler tarafından ne kadarının açıklandığını yüzdesel olarak gösterir. Çoklu doğrusal regresyon modelinde ise R² değeri, Düzenlenmiş R² değeri olarak sunulmaktadır. Çizelge 5.1’de yer alan modele ait Düzenlenmiş R² değeri 0,916 olduğundan, bu durum değişkenlerin bağımlı değişkeni açıklama oranının oldukça yüksek olduğunu göstermektedir.

Çizelge 5.1’de sunulan Durbin-Watson test değeri, modelde otokorelasyonun olup olmadığını belirlemektedir. Bu değer genellikle -1,5 ile +1,5 arasında olması beklenir. Modele ait Durbin-Watson değeri 2,229 olduğu için otokorelasyon sorununun bulunmadığı sonucuna ulaşılmaktadır.

Varyans analizi, modelin anlamlı olup olmadığını değerlendirmek için kullanılmaktadır. Çizelge 5.2’de yer alan anlamlılık değeri, anlamlılık testi için faktörün gösterdiği değeri ifade etmektedir. Bir modelde anlamlılık değerinin 0,05’ten küçük olması, en az bir bağımsız değişkenin bağımlı değişkenle anlamlı bir ilişki içinde olduğunu gösterir. Çizelge 5.2’de yer alan verilere göre modelin anlamlılık

değeri 0,05'ten küçük olduğu için, çoklu doğrusal regresyon modelimizin anlamlı olduğu sonucuna ulaşılmaktadır.

Çizelge 5.2 : X satış miktarı çoklu doğrusal regresyon modeline ait varyans analizi.

Model	Kareler Toplamı	df	Ortalama Kare	F	Anlamlılık
Regression	150813833099,835	4	37703458274,959	97,030	<0,001
Residual	12045892101,2837	31	388577164,557	-	-
Total	162859725201,119	35	-	-	-

Analiz sonucunda anlamlı bir regresyon modeli, $F(4, 31) = 97,030$, $p < 0,001$ ve bağımlı değişkendeki varyansın %0,916'sını ($R^2_{adjusted} = 0,916$) bağımsız değişkenler tarafından açıkladığı bulunmuştur. Alınan sonuç ile bağımsız değişkenlerin X ürününün satış miktarları bağımlı değişkeni üzerindeki etkileri yorumlanabilmektedir. Buna göre, MKTS bağımsız değişkeni bağımlı değişkeni olumlu ve anlamlı olarak tahmin edebilmektedir, $\beta = 1,119$, $t(31) = 16,235$, $p < 0,001$, $pr^2 = 0,895$. SÜE bağımsız değişkeni bağımlı değişkeni olumsuz ve anlamlı olarak tahmin edebilmektedir, $\beta = -0,231$, $t(31) = -3,374$, $p = 0,002$, $pr^2 = 0,268$. TFDD bağımsız değişkeni bağımlı değişkeni anlamlı olarak tahmin edememektedir, $\beta = 0,091$, $t(31) = 1,439$, $p = 0,160$, $pr^2 = 0,062$. ÜDİB bağımsız değişkeni bağımlı değişkeni anlamlı olarak tahmin edememektedir, $\beta = 0,042$, $t(31) = 0,658$, $p = 0,516$, $pr^2 = 0,014$.

Hesaplamalar sonucu çoklu doğrusal regresyon modeli aşağıda yer almaktadır.

$$X \text{ Satış Miktarları} = -1130013,827 + 0,059 (X_1) - 2895,629 (X_2) + 1360,405 (X_3) + 282,995 (X_4)$$

$$X \text{ Satış Miktarları} = -1130013,827 + 0,059 (\text{MKTS}) - 2895,629 (\text{SÜE}) + 1360,405 (\text{TFDD}) + 282,995 (\text{ÜDİB})$$

X ürününe ait satış miktarlarının tahmin edilmesi için kurulan çoklu doğrusal regresyon modelinin değişkenleri makine öğrenmesi modellerinde verimli sonuçlar alabilmek adına kullanılacaktır.

X ürününe ait satış miktarlarının tahmin edilmesi için takip edilen çoklu doğrusal regresyon modeli kurma aşamaları X ürününün maliyetleri için de uygulanmaktadır.

X ürününün maliyetlerinin tahmin edilmesi için kurulan çoklu doğrusal regresyon modeline ait özet veriler çizelge 5.3'te yer almaktadır.

Çizelge 5.3 : X maliyeti çoklu doğrusal regresyon modeline ait özet veriler.

Model	R	R ²	Düzenlenmiş R ²	Std. Tahmin Hatası	Durbin-Watson
1	0,988	0,977	0,974	5,74728669	0,366

Belirtildiği gibi, çoklu doğrusal regresyon modelinde R² değeri, Düzenlenmiş R² değeri olarak sunulmasından kaynaklı Çizelge 5.3'te yer alan modele ait Düzenlenmiş R² değerine bakılmaktadır. Düzenlenmiş R² değeri 0,974 olduğundan, bağımsız değişkenlerin bağımlı değişkeni açıklama oranının oldukça yüksek olduğu görülmektedir.

Çizelge 5.3'te sunulan Durbin-Watson test değeri, modelde otokorelasyonun olup olmadığını belirlemektedir. Bu değer genellikle -1,5 ile +1,5 arasında olması beklenir. Modele ait Durbin-Watson değeri 2,229 olduğu için otokorelasyon sorununun bulunmadığı sonucuna ulaşılmaktadır.

Çizelge 5.4'te yer alan verilere göre modelin anlamlılık değeri 0,05'ten küçük olduğu için, çoklu doğrusal regresyon modelimizin anlamlı olduğu sonucuna ulaşılmaktadır.

Çizelge 5.4 : X maliyeti çoklu doğrusal regresyon modeline ait varyans analizi.

Model	Kareler Toplamı	df	Ortalama Kare	F	Anlamlılık
Regression	42703,365	4	10675,841	323,204	<0,001
Residual	1023,97	31	33,031	-	-
Total	43727,335	35	-	-	-

Analiz sonucunda anlamlı bir regresyon modeli, $F(4, 31) = 323,204$, $p < 0,001$ ve bağımlı değişkendeki varyansın %0,974'sını ($R^2_{adjusted} = 0,974$) bağımsız değişkenler tarafından açıkladığı bulunmuştur. Alınan sonuç ile bağımsız değişkenlerin X ürününün maliyeti bağımlı değişkeni üzerindeki etkileri yorumlanabilmektedir. Buna göre, MKTS bağımsız değişkeni bağımlı değişkeni olumlu ve anlamlı olarak tahmin edebilmektedir, $\beta = 0,956$, $t(31) = 24,662$, $p < 0,001$, $pr^2 = 0,951$. SÜE bağımsız

değişkeni bağımlı değişkeni anlamlı olarak tahmin edememektedir, $\beta = 0,027$, $t(31) = 0,695$, $p = 0,492$, $pr^2 = 0,015$. TFDD bağımsız değişkeni bağımlı değişkeni anlamlı olarak tahmin edememektedir, $\beta = -0,039$, $t(31) = -1,099$, $p = 0,280$, $pr^2 = 0,038$. ÜDİB bağımsız değişkeni bağımlı değişkeni anlamlı olarak tahmin edememektedir, $\beta = -0,010$, $t(31) = -0,274$, $p = 0,786$, $pr^2 = 0,002$. Hesaplamalar sonucu çoklu doğrusal regresyon modeli de aşağıda yer almaktadır.

$$X \text{ Ürünü Maliyeti} = -613,008 + 0,00002608 (X_1) + 0,174 (X_2) - 0,303 (X_3) - 0,034 (X_4)$$

$$X \text{ Ürünü Maliyeti} = -613,008 + 0,00002608 (\text{MKTS}) + 0,174 (\text{SÜE}) - 0,303 (\text{TFDD}) - 0,034 (\text{ÜDİB})$$

X ürününe ait maliyetlerin tahmin edilmesi için kurulan çoklu doğrusal regresyon modelinin değişkenleri makine öğrenmesi modellerinde verimli sonuçlar alabilmek adına kullanılacaktır.

5.2 Makine Öğrenmesi Modeli Bulguları

Makine öğrenmesi modeli bulguları başlığı altında oluşturulan YSA ve GBRT makine öğrenmesi modellerinin R^2 ve MAPE değerleri karşılaştırılacaktır.

5.2.1 Yapay sinir ağları modeli bulguları

X ürünü satış miktarlarının tahmin edilebilmesi için Knime programı üzerinden oluşturulan YSA modeline ait bulguların incelenebilmesi için veriler çizelge 5.5 ve çizelge 5.6'da yansıtılmıştır.

Veriler iki farklı veri ayrıştırıcısı ile modellenerek hesaplamaları gerçekleştirilmiştir. Veri ayrıştırıcılarından birisi %70'inin eğitim seti, %30'unun ise test seti olarak ayırma işlemi gerçekleştirmektedir. Veri ayrıştırıcılarından bir diğeri ise K-katlamalı çapraz doğrulama yönteminde ile veri setini 10 eşit parçaya bölerek ayırma işlemi gerçekleştirmektedir. Çizelge 5.5'te rastgele veri seçimi ile oluşturulan modelin hesaplanan verileri yer almaktadır.

Çizelge 5.5 : Rastgele veri seçimi ile oluşturulan YSA model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
MLP (2,2,1)	0,98	0,34	0,96	0,25
MLP (2,3,1)	0,87	0,21	0,97	0,19
MLP (2,5,1)	0,87	0,53	0,90	0,23
MLP (2,10,1)	0,93	0,18	0,84	0,22
MLP (2,15,1)	0,92	0,22	0,91	0,19
MLP (2,2,2,1)	0,93	0,22	0,98	0,25
MLP (2,3,3,1)	0,97	0,16	0,92	0,21
MLP (2,5,5,1)	0,98	0,23	0,93	0,23
MLP (2,10,10,1)	0,98	0,08	0,97	0,15
MLP (2,15,15,1)	0,80	0,35	0,96	0,14

Çizelge 5.6’da sıralı veri seçimi ile oluşturulan modelin hesaplanan verileri yer almaktadır. Çizelge 5.6’da da daha önceden belirtildiği şekilde iki farklı veri ayrıştırıcısı kullanılmıştır.

Çizelge 5.6 : Sıralı veri seçimi ile oluşturulan YSA model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
MLP (2,2,1)	0,93	0,88	0,94	0,24
MLP (2,3,1)	0,94	0,25	0,93	0,25
MLP (2,5,1)	0,84	0,33	0,95	0,18
MLP (2,10,1)	0,86	0,45	0,93	0,21
MLP (2,15,1)	0,89	0,35	0,91	0,22
MLP (2,2,2,1)	0,91	0,29	0,91	0,42
MLP (2,3,3,1)	0,97	0,33	0,93	0,27
MLP (2,5,5,1)	0,97	0,21	0,91	0,22
MLP (2,10,10,1)	0,97	0,20	0,96	0,23
MLP (2,15,15,1)	0,87	0,31	0,95	0,15

YSA ile oluşturulan makine öğrenmesi modellerine ait çıktı verileri incelenmiştir. Daha önceden de belirtildiği gibi MAPE değeri doğru bir karşılaştırma gerçekleştirebilmek için incelenen bir veridir.

Çizelge 5.5 ve çizelge 5.6'da yer alan veriler karşılaştırıldığında en küçük MAPE değerine sahip olan modelin rastgele veri seçimi ile hesaplanan MLP (2,10,10,1) olarak ifade edilen model olduğu sonucuna varılmıştır. Rastgele veri seçiminde verilerin %70'inin eğitim seti, %30'unun ise test seti olarak kullanılmıştır. MLP (2,10,10,1) modelinin MAPE değeri 0,08 ve R^2 değeri 0,98 olduğu için modelin yüksek olumlulukta sonuç verdiği anlaşılmaktadır.

5.2.2 Gradyan arttırmalı regresyon ağaçları modeli bulguları

X ürünü satış miktarlarının tahmin edilebilmesi için Knime programı üzerinden oluşturulan GBRT modeline ait bulguların incelenebilmesi için veriler çizelge 5.7 ve çizelge 5.8'de yansıtılmıştır.

Veriler iki farklı veri ayrıştırıcısı ile modellenerek hesaplamaları gerçekleştirilmiştir. Veri ayrıştırıcılarından birisi %70'inin eğitim seti, %30'unun ise test seti olarak ayırma işlemi gerçekleştirmektedir. Veri ayrıştırıcılarından bir diğeri ise K-katlamalı çapraz doğrulama yönteminde ile veri setini 10 eşit parçaya bölerek ayırma işlemi gerçekleştirmektedir. Çizelge 5.7'te rastgele veri seçimi ile oluşturulan modelin hesaplanan verileri yer almaktadır.

Çizelge 5.7 : Rastgele veri seçimi ile oluşturulan GBRT model çıktıları.

Model	%70, R^2	%70, MAPE	K=10, R^2	K=10, MAPE
GBRT (2)	0,98	0,15	0,96	0,14
GBRT (3)	0,98	0,11	0,96	0,12
GBRT (5)	0,97	0,13	0,96	0,14
GBRT (10)	0,85	0,14	0,94	0,16
GBRT (15)	0,97	0,15	0,95	0,13

Çizelge 5.8'de sıralı veri seçimi ile oluşturulan modelin hesaplanan verileri yer almaktadır. Çizelge 5.8'de daha önceden belirtildiği şekilde iki farklı veri ayrıştırıcısı kullanılmıştır.

Çizelge 5.8 : Sıralı veri seçimi ile oluşturulan GBRT model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
GBRT (2)	0,97	0,11	0,92	0,18
GBRT (3)	0,97	0,10	0,92	0,18
GBRT (5)	0,93	0,11	0,89	0,19
GBRT (10)	0,94	0,11	0,89	0,18
GBRT (15)	0,94	0,11	0,89	0,18

GBRT ile oluşturulan makine öğrenmesi modellerine ait çıktı verileri incelenmiştir. Çizelge 5.7 ve çizelge 5.8’de yer alan veriler karşılaştırıldığında en küçük MAPE değerine sahip olan modelin sıralı veri seçimi ile hesaplanan GBRT (3) olarak ifade edilen model olduğu sonucuna varılmıştır. Sıralı veri seçiminde verilerin %70’inin eğitim seti, %30’unun ise test seti olarak kullanılmıştır. GBRT (3) modelinin MAPE değeri 0,10 ve R² değeri 0,97 olduğu için modelin yüksek olumlulukta sonuç verdiği anlaşılmaktadır.

5.2.3 Makine öğrenmesi modellerinin karşılaştırılması

Bir önceki bölümlerde X ürünün satış miktarlarına ilişkin gerçekleştirilen makine öğrenmesi modellerinden alınan çıktılar incelenmiştir. YSA ve GBRT yöntemleri ile gerçekleştirilen modellerin MAPE değerlerinin karşılaştırılması ile yöntemlerin kendi içinde en iyi sonucu veren parametreleri belirlenmiştir. X ürünün satış miktarlarına ilişkin kurulan makine öğrenmesi modellerinin aşamaları X ürünün maliyetleri için gerçekleştirilen makine öğrenmesi modeline de uygulanmıştır. Kurulan modellerde denenen parametreler X ürünün maliyeti için izlenmiştir. Aşağıda bulunan çizelgede X ürününü maliyetlerine ilişkin YSA ve GBRT yöntemleri ile oluşturulan modellerin çıktıları yer almaktadır. Çizelge 5.9’da X ürünü maliyeti için rastgele veri seçimi ile gerçekleştirilen modellerin çıktıları yer almaktadır.

Çizelge 5.9 : Rastgele veri seçimi ile X maliyeti için oluşturulan model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
MLP (2,2,1)	1,00	0,03	0,98	0,04
MLP (2,3,1)	0,95	0,06	0,99	0,04
MLP (2,5,1)	0,98	0,06	0,99	0,03
MLP (2,10,1)	0,86	0,11	0,98	0,05
MLP (2,15,1)	0,94	0,07	0,97	0,05
MLP (2,2,2,1)	0,99	0,04	0,99	0,03
MLP (2,3,3,1)	0,98	0,04	0,98	0,05
MLP (2,5,5,1)	0,96	0,09	0,99	0,04
MLP (2,10,10,1)	1,00	0,03	0,97	0,05
MLP (2,15,15,1)	0,96	0,06	0,99	0,03
GBRT (2)	0,97	0,04	0,99	0,04
GBRT (3)	0,96	0,05	0,99	0,04
GBRT (5)	0,99	0,04	0,98	0,05
GBRT (10)	0,98	0,04	0,99	0,05
GBRT (15)	0,97	0,05	0,98	0,05

Çizelge 5.10’da X ürünü maliyeti için sıralı veri seçimi ile gerçekleştirilen modellerin çıktıları yer almaktadır.

Çizelge 5.10 : Sıralı veri seçimi ile X maliyeti için oluşturulan model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
MLP (2,2,1)	1,00	0,03	0,98	0,05
MLP (2,3,1)	1,00	0,02	0,94	0,08
MLP (2,5,1)	0,96	0,08	0,98	0,06
MLP (2,10,1)	0,99	0,04	0,96	0,08
MLP (2,15,1)	0,85	0,13	0,97	0,08
MLP (2,2,2,1)	0,99	0,03	0,99	0,04
MLP (2,3,3,1)	1,00	0,02	0,98	0,06

Çizelge 5.11 (devam): Sıralı veri seçimi ile X maliyeti için oluşturulan model çıktıları.

Model	%70, R ²	%70, MAPE	K=10, R ²	K=10, MAPE
MLP (2,5,5,1)	0,97	0,05	0,95	0,07
MLP (2,10,10,1)	1,00	0,02	0,98	0,06
MLP (2,15,15,1)	0,98	0,06	0,97	0,07
GBRT (2)	0,99	0,04	0,97	0,07
GBRT (3)	0,99	0,03	0,97	0,07
GBRT (5)	0,99	0,04	0,96	0,07
GBRT (10)	0,99	0,04	0,96	0,07
GBRT (15)	0,99	0,04	0,96	0,07

Çizelge 5.9 ve çizelge 5.10’da yer alan veriler karşılaştırıldığında YSA ile oluşturulan modellerde en küçük MAPE değerine sahip olan modelin sıralı veri seçimi ile hesaplanan MLP (2,10,10,1) olarak ifade edilen model olduğu sonucuna varılmıştır. Sıralı veri seçiminde verilerin %70’inin eğitim seti, %30’unun ise test seti olarak kullanılmıştır. MLP (2,10,10,1) modelinin MAPE değeri 0,02 ve R² değeri 0,997 olduğu için modelin yüksek olumlulukta sonuç verdiği anlaşılmaktadır. GBRT ile oluşturulan modellerde en küçük MAPE değerine sahip olan modelin sıralı veri seçimi ile hesaplanan GBRT (3) olarak ifade edilen model olduğu sonucuna varılmıştır. Sıralı veri seçiminde verilerin %70’inin eğitim seti, %30’unun ise test seti olarak kullanılmıştır. GBRT (3) modelinin MAPE değeri 0,03 ve R² değeri 0,99 olduğu için modelin yüksek olumlulukta sonuç verdiği anlaşılmaktadır.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, X ürününün satış miktarları ve maliyetlerinin tahmin edilmesi amacıyla çoklu doğrusal regresyon ve makine öğrenmesi modelleri kullanılmıştır. Elde edilen sonuçlar, iki yöntem arasında önemli farklılıklar olduğunu ve belirli değişkenlerin satış ve maliyet tahminlerinde etkili olduğunu ortaya koymuştur.

Çoklu doğrusal regresyon modeliyle yapılan analizler sonucunda, satış miktarları üzerinde etkili olan bağımsız değişkenler Motorlu Kara Taşıt Sayısı (MKTS), Sanayi Üretim Endeksi (SÜE), Tüketici Fiyatlarının Değişimine İlişkin Düşünce (TFDD) ve Ücretlerin Değişimine İlişkin Beklenti (ÜDİB) olarak belirlenmiştir. Satış miktarları modeli için elde edilen Düzenlenmiş R^2 değeri 0,916 olup, bu değer modelin yüksek bir açıklayıcılığa sahip olduğunu göstermektedir. Özellikle, MKTS, satış miktarlarını olumlu ve anlamlı bir şekilde etkilerken ($\beta = 1,119$, $p < 0,001$), SÜE satışları olumsuz ve anlamlı bir şekilde etkilemiştir ($\beta = -0,231$, $p = 0,002$). Diğer değişkenler olan TFDD ve ÜDİB'in ise satış miktarları üzerinde anlamlı bir etkisi tespit edilmemiştir. Maliyet tahminine yönelik oluşturulan modelin Düzenlenmiş R^2 değeri 0,974 olarak hesaplanmış ve bu da modelin oldukça güçlü bir açıklayıcılığa sahip olduğunu ortaya koymuştur. MKTS, maliyet üzerinde olumlu ve anlamlı bir etkiye sahipken ($\beta = 0,956$, $p < 0,001$), diğer değişkenlerin (SÜE, TFDD, ÜDİB) maliyet üzerinde anlamlı bir etkisi bulunmamıştır.

GBRT modelleri, farklı ağaç derinlikleri ile test edilmiştir. Modellerin doğruluk oranları ve hata oranları karşılaştırılmış, her iki bağımlı değişken için de en iyi performans GBRT (3) yapısında elde edilmiştir. Sıralı veri seti ile %70 eğitim- %30 test oranıyla yapılan analizlerde, X ürünü satış adetlerine ait R^2 değeri 0,97 ve MAPE değeri 0,10 olarak hesaplanmıştır. X ürünü maliyetlerine ait R^2 değeri de 0,99 ve MAPE değeri 0,03 olarak hesaplanmıştır.

Çalışma içerisinde en iyi sonucu veren YSA modelleri ise, farklı katman ve nöron sayılarıyla test edilmiştir. Modellerin doğruluk oranları ve hata oranları karşılaştırılmış, her iki bağımlı değişken için de en iyi performans MLP (2,10,10,1) yapısında elde edilmiştir. %70 eğitim- %30 test oranıyla yapılan analizde, X ürünü

satış adetlerine ait modele veri akışı rastgele, X ürünü maliyetlerine ait modele veri akışı sıralı olarak gerçekleşmiştir. X ürünü satış adetlerine ait modelin R² değeri 0,98 ve MAPE değeri 0,08 olarak hesaplanmıştır. X ürünü maliyetlerine ait modelin R² değeri 0,997 ve MAPE değeri 0,02 olarak hesaplanmıştır. YSA modelleri, çoklu doğrusal regresyon modellerine ve GBRT modellerine kıyasla daha düşük hata oranlarına ve daha yüksek doğruluk değerlerine ulaşarak daha başarılı tahminler sunmuştur. Model çıktı verileri çizelge 6.1’de yansıtılmıştır.

Çizelge 6.1 : Bağımlı değişkenlerin en iyi sonuç veren tahmin modelleri.

Bağımlı Değişken	Model	%70, R ²	%70, MAPE	Veri Seçimi
X ürünü Satış Adetleri	MLP (2,10,10,1)	0,98	0,08	Rastgele Seçim
X ürünü Maliyetleri	MLP (2,10,10,1)	0,99	0,02	Sıralı Seçim

Bu analizlerin gerçekleştirilmesinde farklı yazılımlar kullanılmıştır. Verilerin mevsimsellikten arındırılması için Eviews yazılımı tercih edilmiştir. Çoklu doğrusal regresyon analizleri SPSS programı kullanılarak yapılmış, makine öğrenmesi ve YSA modelleri ise Knime platformu üzerinden oluşturulmuştur. Bu yazılımlar sayesinde veri işleme, modelleme ve analiz süreçleri daha sistematik ve güvenilir bir şekilde yürütülmüştür.

Elde edilen bulgular ışığında, X ürününün satış ve maliyet tahminlerinde MKTS ve SÜE gibi değişkenlerin önemli olduğu sonucuna varılmıştır. Bu değişkenlerin düzenli olarak takip edilmesi ve analiz edilmesi, daha doğru üretim ve maliyet planlamalarının yapılmasına katkı sağlayacaktır.

YSA modelleri, doğrusal olmayan ilişkileri daha başarılı bir şekilde yakalayıp daha doğru tahminler sunmaktadır. Bu nedenle, işletmelerin yalnızca geleneksel regresyon yöntemleriyle yetinmeyip Yapay Zekâ ve Makine Öğrenmesi modellerini aktif bir şekilde kullanmaları önerilmektedir. YSA modelleri, özellikle büyük ve karmaşık veri setleri üzerinde daha güçlü sonuçlar verebilmektedir ve bu da işletmelerin karar alma süreçlerine önemli katkılar sağlayabilmektedir.

SÜE’nin satışlar üzerindeki olumsuz etkisi dikkate alınarak, sanayi üretiminde yaşanan dalgalanmalara karşı alternatif pazarlama ve satış stratejileri geliştirilmesi önerilmektedir. Ayrıca, maliyet tahmininde belirleyici olan MKTS’ye yönelik sektörel analizlerin yapılması, maliyet optimizasyonu açısından faydalı olacaktır.

Gelecek alıřmalarda, bu arařtırmada anlamlı bir etki gstermeyen TFDD ve DİB gibi deęiřkenlerin farklı dnemlerde veya geniřletilmiş veri setleriyle tekrar incelenmesi nerilmektedir. Ayrıca, farklı makine ğrenmesi algoritmaları (Destek Vektr Makineleri, Karar Aęaları vb.) kullanılarak model performansları karřılařtırılabilir ve tahmin doęrulukları artırılabilir.

Bu alıřmanın sınırlılıkları arasında, belirli bir zaman aralıęında toplanan verilerin kullanılması yer almaktadır. Uzun vadeli verilerle yapılacak alıřmalar, modelin genellenebilirlięini artırılabilir. Ayrıca, politik, evresel ve kresel ekonomik faktrler gibi dıřsal deęiřkenlerin de modele dahil edilmesi, daha kapsamlı ve gereki sonular elde edilmesine olanak saęlayacaktır.

Sonu olarak, bu alıřma hem geleneksel istatistiksel yntemlerin hem de modern makine ğrenmesi yaklařımlarının retim ve maliyet planlama srelerinde nasıl etkin bir Őekilde kullanılabileceęini gstermiřtir. Elde edilen sonular, iřletmelerin daha doęru tahminlerde bulunmasına ve stratejik karar alma srelerine katkı saęlamasına yardımcı olacaktır.

KAYNAKLAR

- Ajah, I. A., Nweke, H. F.** (2019). Big Data and Business Analytics: Trends, Platforms, Success Factors and Applications. *Big data and Congitive Computing*, 3(2), 32.
- Al-Tawal, D. R., Arafah, M., Sweis, G. J.** (2021). A model utilizing the artificial neural network in cost estimation of construction projects in jordan. *Engineering, Construction and Architectural Management*, 28(9), 2466-2488.
- Ataseven, B.** (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Aylak, B. L., Oral O., Yazici, K.** (2021). Yapay Zeka ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı. *ECJSE*, 8(1), 74–93.
- Buchmeister, B., Palcic, I., Ojstersek, R.** (2019). DAAAM International Scientific Book. *DAAAM International*, 18(1), 081-098.
- Bryman, A., Cramer, D.** (1999). *Quantitative data analysis with SPSS release 8 for Windows. A guide for social scientists*. London, England : Routledge.
- Cabena, P., Hadjinian, P., Stadler, R., Verhees, J. ve Zanasi, A.** (1998). *Discovering Data Mining: From Concept To Implementation*. New Jersey, ABD.: Prentice Hall.
- DeCoster, J., Claypool, H. M.** (2004). A Meta-Analysis of Priming Effects on Impression Formation Supporting a General Model of Informational Biases. *Personality and Social Psychology Review*, 8(1), 2–27.
- Demir, Ö., Acar, M.** (1992). *Sosyal Bilimler Sözlüğü*, İstanbul, Türkiye: Ağaç Yayıncılık.
- Du-Harpur, X., Watt, F. M., Luscombe, N. M., Lynch, M. D.** (2020). What is AI? Applications of artificial intelligence to dermatology. *British Journal of Dermatology*, 183(3), 423-430.
- Ediz, Ç., Turan, A. H.** (2020). Çok Değişkenli Üretim Planlama Kararlarında Bilişim Teknolojisi Uygulamaları. *Uluslararası İktisadi Ve İdari İncelemeler Dergisi*, 1(1), 19-30.
- El-Sawalhi, N. I., Shehatto, O.** (2014). A neural network model for building construction projects cost estimating. *Journal of Construction Engineering and Project Management*, 4(4), 9–16.
- Erzurum Çiçek, Z. İ.** (2020). *Trafik Uygulamalarında Veri Analitiği ve Optimizasyon*, (Doktora tezi). Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Eskişehir.
- Esin, A.** (1988). *Yöneylem Araştırmasında Yararlanılan Karar Yöntemleri*. Ankara, TR.: Gazi Kitabevi.

- Ever, D., Demircioğlu, E. N.** (2022). Yapay Zekâ Teknolojilerinin Kalite Maliyetleri Üzerine Etkisi. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 31(1), 59-72.
- Field, A.** (2009). *Discovering Statistics Using SPSS*, London, England: Sage Publications.
- Genç, Ö., Akbıyıklı, R., Ateş, V.** (2022). Baraj Yapılarındaki Yaklaşık Maliyet Belirsizliklerinin Yapay Zeka Teknikleriyle Tahmini. *7. Uluslararası 19 Mayıs Yenilikçi Bilimsel Yaklaşımlar Kongresi*, Samsun, Türkiye: Mayıs 19-20.
- Gökırmak, U.** (2006). *Endüstri İşletmelerinde Maliyet Optimizasyonu ve Performans Yükseltimi*, (Yüksek lisans tezi). Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Guidici, P., Figini, S.** (2003). *Applied Data Mining Statistical Methods for Business and Industry*. West Sussex, England : Wiley.
- Güler, K.** (2019). *Türkiye'deki Altın ve Döviz Fiyatlarının Değişiminin Ekonomik Veriler Kullanılarak Yapay Zekâ ile Tahmini ve Kriz Öngörüsü*, (Yüksek lisans tezi). Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Yalova.
- Güler, Ö.** (2021). *Makine Öğrenmesi Yöntemleriyle Türkiye'de Turizm Gelirine Etki Eden Parametrelerin Belirlenmesi ve Değerlendirilmesi*, (Yüksek lisans tezi). Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Gültekin, M.** (2019). *Makine Öğrenmesi Tabanlı Yazılım Maliyet Tahmini Yöntemlerinin Karşılaştırmalı Analizi*, (Doktora Tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Günaydın, H. M., Doğan, S. Z.** (2004). A neural network approach for early cost estimation of structural systems of buildings. *International Journal of Project Management*, 22(7), 595–602.
- Gür, Y. E., Ayden, C., Yücel, A.** (2019). Yapay zekâ alanındaki gelişmelerin insan kaynakları yönetimine etkisi. *Fırat Üniversitesi Uluslararası İktisadi ve İdari Bilimler Dergisi*, 3(2), 137-158.
- Janiesch, C., Zschech, P., Heinrich, K.** (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Karahan, M.** (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları ile Ürün Talep Tahmini Uygulaması*, (Doktora tezi). Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.
- Kavakiotis, I., Tsave, O., Salifoglou, A., Maglaveras, N., Vlahavas, I., Chouvarda, I.** (2017). Machine Learning and Data Mining Methods in Diabetes Research. *Computational and Structural Biotechnology Journal*, 15(1), 104–116.
- Koçak, A., Yıldız, A.** (2022). Üretim Planlama ve Kontrol Süreçlerinde Dijital İkiz Teknolojisinin Kullanılması: Tekstil Sektöründe Bir Uygulama. *Gazi University Journal of Science Part C: Design and Technology*, 10(4), 711-732.

- Kranda, Y. T.** (2021). *Mobil Kablosuz Ağların Optimizasyonunda Yapay Zekâ Yöntemlerinin Kullanılarak Operasyonel Verimliliğin Artırılması*, (Doktora tezi). İstanbul Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Lee, S. M., Lee, D., Kim, Y.S.** (2019). The quality management ecosystem for predictive maintenance in the Industry 4.0 era. *International Journal of Quality Innovation*, 5(1), 1-11.
- Li, B. H., Hou, B. C., Yu, W. T., Lu, X. B., Yang, C. W.** (2017). Applications of artificial intelligence in intelligent manufacturing: a review. *Frontiers of Information Technology & Electronic Engineering*, 18(1), 86-96.
- Markovics, D., Mayer, M.J.** (2022). Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction, *Renewable and Sustainable Energy Reviews*, 161 (1), 1-17.
- Marzouk, M., Elkadi, M.** (2016). Estimating water treatment plants costs using factor analysis and artificial neural networks. *Journal of Cleaner Production*, 112(1), 4540–4549.
- Mutlu, M.** (2024). *Derin Pekiştirmeli Öğrenme Tabanlı Enerji Maliyeti Optimizasyonu*, (Yüksek lisans tezi). Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bursa.
- Namlı, E.** (2012). *Proje Yönetimi Kapsamında Risk Tabanlı ve Yapay Zekâ Destekli Bir Maliyet Tahmin Modeli*, (Doktora tezi). İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Okan Gökten, P.** (2018). Karanlıkta Üretim: Yeniçağda Maliyetin Kapsamı. *Muhasebe Bilim Dünyası Dergisi*, 20(4), 880-897.
- Olgun, S.** (2009). *Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri ve Yapay Zekâ Tabanlı Bir Talep Tahmini Modelinin Uygulanması*, (Yüksek lisans tezi). İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Olgun, S.** (2020). *Yazılım Projelerinin Yönetiminde Maliyet Tahmini İçin Derin Öğrenme Tabanlı Yeni Bir Yaklaşım*, (Doktora tezi). İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Özcan, B., Kayapınar, K., Adem, K.** (2023). Gelişen Teknoloji ile Bankacılık Sektöründe Veri Analitiği: Müşteri Kaybı Tahmini İçin Makine Öğrenmesi Yaklaşımları. *Uluslararası Sivas Bilim ve Teknoloji Üniversitesi Dergisi*, 2(1), 74-84.
- Özcan, E. C.** (2013). *Elektrik Üretim Planlamasında Çok Amaçlı Optimizasyon Yaklaşımı: Türkiye Örneği*, (Doktora tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Özer, D., Aksoy, B.** (2024). Yapay Zekâ Uygulaması İle Güneş Paneli Sistemi Enerji Üretimi Tahmini. *Yalvaç Akademi Dergisi*, 9(2), 138-151.
- Pakım, B.** (2020). *Görsel Sanatlarda Yapay Zekâ ve Yaratıcılık İlişkisi*, (Yüksek lisans tezi). Dokuz Eylül Üniversitesi, Güzel Sanatlar Enstitüsü, İzmir.
- Pallant, J.** (2017). *SPSS kullanma klavuzu SPSS ile adım adım veri analizi*. (S. Balcı ve B. Ahi Çev.). Ankara, Türkiye: Anı Yayıncılık.

- Panch, T., Szolovits, P., Atun, R.** (2018). Artificial Intelligence, Machine Learning and Health Systems. *J Glob Health*, 8(2), 1–8.
- Reese, H.** (2017). Understanding the differences between AI. *Machine Learning and Deep Learning*. 13(1), 1-12.
- Rizvanche, S.** (2020). *Talep Tahmininde Makine Öğrenmesi ve Zaman Serileri Temelli Bir Karar Destek Sistemi*, (Yüksek lisans tezi). Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Eskişehir.
- Sarıgül, U.** (2019). *Ağaç Bazlı Panel Endüstrisinde Mdf Hammadde Karışımının Belirlenmesi ve Maliyet Optimizasyonu*, (Yüksek lisans tezi). Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Schniederjans, M. J., Schniederjans, D. G., Starkey, C. M.** (2014). *Business Analytics Principles, Concepts, and Applications: What, Why, and How*. New Jersey, ABD.: Pearson Education.
- Serçemeli, M.** (2018). Muhasebe ve Denetim Mesleklerinin Dijital Dönüşümünde Yapay Zekâ. *Journal of Turkish Studies*, 13(30), 369-386.
- Somuncu, S., Oral, C.** (2024). Yapay Sinir Ağı ve ANFIS kullanılarak Meteorolojik Verilere Bağlı Güneş Enerjisi Tahmini. *OKU Fen Bilimleri Enstitüsü Dergisi*, 7(4), 1685-1701.
- Stancheva-Todorova, E. P.** (2018). How Artificial Intelligence Is Challenging Accounting Profession. *International Scientific Publications*, 12(1), 126-141.
- Şeker, K.** (2019). *Savunma Sanayinde Prototip Ürün Devreye Alınmasında Modelleme ve Maliyet Optimizasyonu*, (Yüksek lisans tezi). Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Şimşek Can, G.** (2021). *Havacılık Endüstrisinde Yapay Sinir Ağları ile Ürün Ağaçlarındaki Değişimlere Bağlı Maliyet Tahmini*, (Yüksek lisans tezi). Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Karabük.
- Tabachnick, B. G., Fidell, L. S.** (2013). *Using Multivariate Statistics*, Boston, Massachusetts, ABD.: Pearson Education.
- Tang, S., Wu, S., Gao, J.** (2019). An Optimal Model based on Multifactors for Container Throughput Forecasting. *Journal of Civil Engineering*, 23(9), 4124- 4131.
- Walk, J., Kühl, N., Saidani, M., Schatte, J.** (2023). Artificial intelligence for sustainability: Facilitating sustainable smart product-service systems with computer vision. *Journal of Cleaner Production*, 402(1), 136748.
- Wu, Z., Luo, G., Yang, Z., Guo, Y., Li, K., Xue, Y.** (2022). A comprehensive review on deep learning approaches in wind forecasting applications. *CAAI Transactions on Intelligence Technology*, 7(2), 129-143.
- Yazıcıoğlu, N.** (2010). *Yapay Zekâ ile Talep Tahmini*, (Yüksek lisans tezi). Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.
- Yıldırım, A.** (2019). *Talep Tahmin Yöntemlerinin Karşılaştırmalı Analizi: Gıda Sektöründe Bir Uygulama*, (Yüksek lisans tezi). İstanbul Kültür Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.

Yıldız, A. (2022). Büyük Veri'nin V'leri ve Veri Analitiği. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 51(1), 361-378.

Url-1 <<http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf>>, İleri Algoritma Analizi: 5 Yapay Sinir Ağları, erişim tarihi 18.05.2020.

Url-2 <<https://avesis.ktu.edu.tr/avnies/yayinlar?themeId=1/>>, Tahmin Teknikleri Ders Notu 1, erişim tarihi 26.02.2024.



ÖZGEÇMİŞ

Ad-Soyad : Senanur İPEK

ÖĞRENİM DURUMU:

- **Lisans** : 2017, Pamukkale Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2025, Bursa Teknik Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Tezli Yüksek Lisans Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- **04.2024 — Devam Ediyor**
Profil Sanayi ve Tic. A.Ş. - Satış ve İş Geliştirme Uzmanı
- **10.2023 — 04.2024**
Profil Sanayi ve Tic. A.Ş. - Proses ve Tekliflendirme Mühendisi
- **08.2022 – 10.2023**
Ayaz Kauçuk Plastik Ve Kalıp Makina San.Tic.Ltd.Şti - Planlama Sorumlusu
- **08.2022 – 10.2023**
Ayaz Kauçuk Plastik Ve Kalıp Makina San.Tic.Ltd.Şti - Üretim Planlama Mühendisi

AKADEMİK ÇALIŞMALAR:

- **Lisans Tezi - 2021**
“Türkiye’deki Limanların Toplam Konteyner Trafiklerinin Makine Öğrenmesi ile Tahmin Edilmesi”
Pamukkale Üniversitesi, Mühendislik Fakültesi, Denizli.