

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**BASKI ÇOĞALTMA ENDÜSTRİSİNE YÖNELİK OTONOM
TEKLİFLENDİRME VE CİHAZ YÖNETİMİ STRATEJİLERİNİN
DEĞERLENDİRİLMESİ: BİR KARAR DESTEK SİSTEMİNİN TASARIMI**

YÜKSEK LİSANS TEZİ

Deniz Işıl ŞİMŞEK

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

HAZİRAN 2024

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**BASKI ÇOĞALTMA ENDÜSTRİSİNE YÖNELİK OTONOM
TEKLİFLENDİRME VE CİHAZ YÖNETİMİ STRATEJİLERİNİN
DEĞERLENDİRİLMESİ: BİR KARAR DESTEK SİSTEMİNİN TASARIMI**

YÜKSEK LİSANS TEZİ

**Deniz Işıl ŞİMŞEK
(507201151)**

**Endüstri Mühendisliği Anabilim Dalı
Endüstri Mühendisliği Programı**

Tez Danışmanı: Prof. Dr. Emre ÇEVİKCAN

HAZİRAN 2024

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**EVALUATION OF AUTONOMOUS BIDDING AND DEVICE MANAGEMENT
STRATEGIES FOR THE PRINT REPRODUCTION INDUSTRY: THE DESIGN
OF A DECISION SUPPORT SYSTEM**

M.Sc. THESIS

**Deniz Işıl ŞİMŞEK
(507201151)**

Department of Industrial Engineering

Industrial Engineering Programme

Thesis Advisor: Prof. Dr. Emre ÇEVİKCAN

JUNE 2024

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 507201151 numaralı Yüksek Lisans Öğrencisi Deniz Işıl ŞİMŞEK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “BASKI ÇOĞALTMA ENDÜSTRİSİNE YÖNELİK OTONOM TEKLİFLENDİRME VE CİHAZ YÖNETİMİ STRATEJİLERİNİN DEĞERLENDİRİLMESİ: BİR KARAR DESTEK SİSTEMİNİN TASARIMI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Emre ÇEVİKCAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Alp ÜSTÜNDAĞ**
İstanbul Teknik Üniversitesi

Prof. Dr. Hüseyin Selçuk KILIÇ
Marmara Üniversitesi

Teslim Tarihi : 24 Mayıs 2024
Savunma Tarihi : 5 Haziran 2024





Canım Oğlum Aslan ve Sevgili Aileme,



ÖNSÖZ

Bu tez çalışması, Baskı Çoğaltma Endüstrisine Yönelik Otonom Tekliflendirme ve Cihaz Yönetimi Stratejilerinin Değerlendirilmesi: Bir Karar Destek Sisteminin Tasarımı konusuna odaklanmakta olup, İstanbul Teknik Üniversitesi'nde yürütülmüş bir projedir. Bu alandaki teorik ve pratik bilgilerin entegrasyonu, baskı sektörüne özgü tekliflendirme süreçlerinin verimliliğini artırmaya dayalı bir çalışma sunmayı amaçlamaktadır.

Öncelikle, akademik rehberliği ve bilgi birikimiyle bu çalışmanın temel taşlarını oluşturmada destek olan danışmanım Prof. Dr. Emre ÇEVİKCAN'a derin saygı ve minnettarlığımı sunarım. Bilgisi, deneyimi ve yönlendirmeleri, bu çalışmanın her aşamasında bir kılavuz olmuştur.

Ayrıca, bu tez çalışmasının gerçekleştirilmesine olanak tanıyan İstanbul Teknik Üniversitesi'ne ve bu çalışmayı destekleyen Kopitek Kopyalama Sistemleri Ltd. Şti. firmasına teşekkürlerimi sunarım. Onların sağladığı kaynaklar, araştırma ortamı ve teşvik edici atmosfer, bu çalışmanın kalitesini doğrudan etkilemiştir.

Bu süreçte yanımda olan ve her türlü desteği sağlayan aileme ve oğlum Aslan'a teşekkürlerimi ayrıca iletmek isterim.

Son olarak, bu çalışma boyunca edindiğim bilgi ve deneyimlerin, akademik literatüre katkıda bulunmasının yanı sıra, baskı çoğaltma endüstrisindeki karar verme süreçlerinin iyileştirilmesine de yardımcı olacağını umuyorum. Bu tezin, ilgili alanlarda çalışan diğer araştırmacılara ve uygulayıcılara ilham kaynağı olması dileğiyle.

Mayıs 2024

Deniz Işıl ŞİMŞEK
(Endüstri Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1 Tezin Amacı	3
2. LİTERATÜR ARAŞTIRMASI	5
2.1 Baskı Çoğaltma Endüstrisinin Genel Tanımı ve Tarihsel Gelişimi	5
2.2 Dijital Baskı Endüstrisinin Gelişimi	6
2.3 Yapay Zekâ ve Makine Öğrenimi Teknolojileri	9
2.3.1 Yapay zekâ ve makine öğrenimi temelleri.....	9
2.3.2 Makine öğrenmesi algoritmaları modelleri	10
2.3.2.1 Gözetimli öğrenme modelleri	11
2.3.2.2 Gözetimsiz öğrenme modelleri	12
2.3.2.3 Yarı gözetimli öğrenme modelleri	12
2.3.2.4 Pekiştirmeli öğrenme modelleri	13
2.3.3 Endüstriyel uygulamalarda yapay zekâ ve makine öğrenimi.....	13
2.3.4 Baskı endüstrisinde yapay zekâ uygulamaları	15
2.4 Karar Destek Sistemleri.....	16
2.4.1 Farklı endüstrilerde karar destek sistemlerinin kullanımı	18
2.4.2 Baskı destek sistemleri entegrasyonu	19
2.4.2.1 Veri ve bilgi entegrasyonu	21
2.4.2.2 Modellendirme	21
2.4.2.3 Proses entegrasyonu	22
2.4.2.4 Servis ve sunum entegrasyonları.....	23
2.5 Tekliflendirme Süreçlerinde Karar Destek Sistemleri	25
2.6 Dinamik Fiyatlandırma	25
2.6.1 Dinamik fiyatlandırma stratejileri ve modelleri.....	26
2.6.1.1 Stok odaklı modeller	28
2.6.1.2 Veri odaklı modeller	29
2.6.1.3 Açık arttırmaya dayalı modeller.....	31
2.6.1.4 Makine öğrenmesine dayalı modeller	31
2.6.1.5 Tekli öğrenme aracılı modeller	31
2.6.1.6 Çoklu öğrenme aracılı modeller.....	33
2.6.2 Dinamik fiyatlandırmanın avantajları ve zorlukları.....	34
2.7 Literatür İncelemesi Sonuç.....	40
3. METODOLOJİ	41

3.1 Veri Toplama.....	41
3.2 Veri Analizi	42
3.3 Makine Öğrenmesi ve Karar Destek Sisteminin Oluşturulması.....	45
3.3.1 Makine öğrenmesi modeli.....	45
3.3.2 Model girdi katmanı	47
3.4 Model Değerlendirme ve Validasyon.....	48
3.4.1 Çapraz doğrulama	49
3.4.2 Karışıklık matrisi ve sınıflandırma raporu	51
3.5 Tekliflendirme	52
3.5.1 Mesafe bilgileri ve lojistik maliyetlerin hesaplanması.....	53
3.5.2 Maliyet ve fiyatlandırma hesaplamaları	53
4. UYGULAMA: MAKİNE ÖĞRENMESİ DESTEKLİ KARAR DESTEK SİSTEMİ TASARIMI.....	57
4.1 Veri Seti ve Analizi	57
4.1.1 Bağımsız değişken seçimi ve önem sıralaması	67
4.2 Makine Öğrenmesi Algoritma Seçimi.....	68
4.3 Form Tasarımı ve Geliştirme Süreci	70
4.4 Makine Öğrenmesi ve Karar Destek Sisteminin Oluşturulması.....	73
4.4.1 Veri setinin hazırlanması ve ön işleme	73
4.4.2 Modelin eğitimi ve değerlendirilmesi	75
4.4.3 Müşteri verileri ile modelin uygulanması	77
4.4.3 Stok kontrolü ve alternatif ürünlerin değerlendirilmesi	78
4.5 Model Değerlendirme ve Validasyon.....	79
4.5.1 Çapraz doğrulama	79
4.5.2 Karışıklık matrisi ve sınıflandırma raporu	81
4.7 Kullanıcı Tekliflendirme Arayüzü	84
4.7.1 Teklif dokümanının oluşturulması	86
4.8 Gerçek Veri Uygulaması	88
5. SONUÇ VE ÖNERİLER.....	91
5.1. Tezin Ana Bulgularının Özeti	91
5.2. Teorik ve Pratik Katkıları	92
5.3. Limitasyonlar ve Gelecek Araştırmalar için Öneriler:	93
5.3.1. Limitasyonlar	93
5.3.2. Gelecek araştırmalar için öneriler	94
KAYNAKLAR.....	97
EKLER.....	103
ÖZGEÇMİŞ.....	135

KISALTMALAR

AI	: Artificial Intelligence (Yapay Zeka)
AR	: Augmented Reality (Artırılmış Gerçeklik)
B2B	: Business to Business (İşletmeden İşletmeye)
B2C	: Business to Consumer (İşletmeden Tüketicie)
BI	: Business Intelligence (İş Zekası)
CAD	: Computer-Aided Design (Bilgisayar Destekli Tasarım)
CAM	: Computer-Aided Manufacturing (Bilgisayar Destekli İmalat)
CHAID	: Chi-square Automatic Interaction Detector (Ki-kare Otomatik Etkileşim Dedektörü)
CNC	: Computer Numerical Control (Bilgisayar Sayısal Kontrol)
CRM	: Customer Relationship Management (Müşteri İlişkileri Yönetimi)
DSS	: Decision Support Systems (Karar Destek Sistemleri)
ERP	: Enterprise Resource Planning (Kurumsal Kaynak Planlaması)
IaaS	: Infrastructure as a Service (Altyapı Hizmet Olarak)
IoT	: Internet of Things (Nesnelerin İnterneti)
IT	: Information Technology (Bilgi Teknolojisi)
ML	: Machine Learning (Makine Öğrenimi)
PaaS	: Platform as a Service (Platform Hizmet Olarak)
PLM	: Product Lifecycle Management (Ürün Yaşam Döngüsü Yönetimi)
POD	: Print On Demand (Talep Üzerine Baskı)
RPA	: Robotic Process Automation (Robotik Süreç Otomasyonu)
SaaS	: Software as a Service (Yazılım Hizmet Olarak)
SCM	: Supply Chain Management (Tedarik Zinciri Yönetimi)
SLA	: Service Level Agreement (Hizmet Seviyesi Anlaşması)
VR	: Virtual Reality (Sanal Gerçeklik)



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: Literatür taraması.	36
Çizelge 3.1: Veri değişkenleri ve açıklamaları.	42
Çizelge 3.2: Metodoloji akış özeti.	55
Çizelge 4.1: Bağımsız veri değişkenleri ve açıklamaları.	57
Çizelge 4.2: Tanımlayıcı istatistikler.	58
Çizelge 4.3: Korelasyonlar.	60
Çizelge 4.4: Makine modellerini etkileyen değişkenlerin karar ağacı ile incelenmesi.	63
Çizelge 4.5: Karar ağacı modeline ilişkin anlamlılık sonuçları.	66
Çizelge 4.6: Değişken önem sıralaması.	68
Çizelge 4.7: Sınıflandırma algoritma performansları.	68
Çizelge 4.8: Bölünme doğruluk oranı.	76
Çizelge 4.9: Sınıflandırma raporu.	83



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Metodoloji akış şeması.	41
Şekil 4.1: Karar ağacı diyagramı.	62
Şekil 4.2: Rastgele orman algoritması akış şeması.	69
Şekil 4.3: Teklif talep formu.	72
Şekil 4.4: Çapraz doğrulama skoru.	81
Şekil 4.5: Karışıklık matrisi.	82
Şekil 4.6: Kullanıcı tekliflendirme arayüzü.	85
Şekil 4.7: Kullanıcı tekliflendirme akış şeması.	86
Şekil 4.8: Oluşturulan teklif görseli.	87
Şekil 4.9: Uygulama teklif talep formu.	88
Şekil 4.10: Uygulama arayüz formu.	89
Şekil 4.11: Uygulama cihaz teklifi.	90



BASKI ÇOĞALTMA ENDÜSTRİSİNE YÖNELİK OTONOM TEKLİFLENDİRME VE CİHAZ YÖNETİMİ STRATEJİLERİNİN DEĞERLENDİRİLMESİ: BİR KARAR DESTEK SİSTEMİNİN TASARIMI

ÖZET

Tez çalışması dijital baskı endüstrisindeki stratejik karar verme süreçlerini iyileştirme, tekliflendirme sürecini otomatize etme ve sektördeki operasyonel verimlilikle birlikte pazar rekabetçiliğini artırma hedeflerine odaklanmaktadır.

Çalışma, baskı endüstrisinin tarihçesine ve dijital teknolojilerin bu alana etkilerine odaklanarak geniş bir literatür taraması ile başlar. Endüstriyel baskı süreçlerinin gelişimi, dijitalleşmesi ve otomasyonun artmasıyla birlikte, firmaların karşılaştığı zorluklar ve bu zorlukların üstesinden gelmek için yapay zeka ve makine öğrenimi teknolojilerinin potansiyeli detaylandırılmaktadır. Çalışma, otonom tekliflendirme sistemlerinin geliştirilmesi ve cihaz yönetimi stratejilerinin değerlendirilmesine yönelik çözümler sunmayı amaçlamaktadır.

İlk olarak metodoloji bölümünde veri toplama, veri analiz süreçleri, kullanılan makine öğrenimi modelleri, model değerlendirme ve validasyon yöntemleri, ve tekliflendirme süreci açıklanmaktadır. Çalışmada, gerçek zamanlı piyasa ve müşteri verilerini işleyebilen, dinamik tekliflendirme yapabilen ve müşteri ihtiyaçlarına göre özelleştirilmiş çözümler sunan bir karar destek sistemi geliştirilmiştir. Bu sistem, otonom olarak en uygun cihaz seçimini yapabilme ve rekabetçi fiyatlandırma stratejileri oluşturabilme kapasitesine sahiptir.

Uygulama kısmında, firmadan alınan gerçek müşteri verilerinin değerlendirilmesi ve girdilerin belirlenmesi, kullanılacak makine öğrenmesi modelinin detaylandırılması ve değerlendirilmesi, geliştirilen modelin baskı endüstrisi özelinde kullanımı, kullanıcı arayüzü tasarımı, pilot uygulama ve elde edilen sonuçlar değerlendirilmektedir. Kopitek Kopyalama Sistemleri Ltd. Şti. tarafından sağlanan 8600 adet müşteri verisi, CHAID veri analizi yöntemi ile incelenmiştir. CHAID analizi, etkileşimli ağaçlar oluşturarak hangi faktörlerin müşteri tercihlerini en çok etkilediğini belirlemek için kullanılmıştır. CHAID analizinden elde edilen değişkenler, Rastgele Orman algoritması başta olmak üzere 5 farklı makine öğrenimi modeli ile test edilmiştir. Rastgele Orman, Karar Ağaçları Lojistik Regresyon, Destek Vektör Makineleri (SVM), ve K-En Yakın Komşular (KNN) algoritmaları da karşılaştırmalı olarak değerlendirilmiştir. Her bir modelin performansı, doğruluk oranı ile değerlendirilmiştir. Rastgele Orman, özellikle büyük veri setleri ve yüksek boyuttaki verilerde üstün performans gösterdiği için bu uygulama için tercih edilen makine öğrenmesi algoritması olmuştur. Rastgele Orman algoritması ile oluşturulan modelin etkinliği ve güvenilirliği, çapraz doğrulama ve karışıklık matrisleri aracılığıyla ayrıca değerlendirilmiştir. Daha sonra ise modelin sektör özelinde kullanımı adına bir kullanıcı arayüzü geliştirilmiş ve oluşturulan karar destek sisteminin gerçek zamanlı veriler ile uygulaması gerçekleştirilmiştir. Kullanıcı arayüzü, müşteri veri girişlerini kolaylaştırmak ve sistem çıktılarını anlaşılır bir biçimde sunmak üzere tasarlanmıştır.

Bu arayüz, kullanıcılara dinamik tekliflendirme yapma, cihaz seçimleri sunma ve rekabetçi fiyatlandırma stratejileri oluşturma imkânı vermiştir.

Sonuçlar bölümünde, tezin ana bulguları özetlenmekte ve teorik ile pratik katkılar tartışılmaktadır. Tez çalışması, baskı endüstrisindeki karar verme süreçlerini iyileştirmek için makine öğreniminin etkin bir şekilde nasıl kullanılabileceğini göstermektedir. Ayrıca, bu teknolojilerin endüstriyel uygulamalarda nasıl stratejik avantajlar sağlayabileceği üzerinde durulmaktadır. Tez aynı zamanda gelecekteki araştırmalar için önerilerde bulunarak, baskı endüstrisindeki dijitalleşme sürecinin gelişimine katkıda bulunmayı hedeflemektedir.

Bu araştırma, baskı endüstrisinde faaliyet gösteren firmalara, karar verme süreçlerinde veriye dayalı, dinamik ve etkin çözümler sunma potansiyeli taşımaktadır. Geliştirilen karar destek sistemi, endüstriyel uygulamalarda yenilikçi bir yaklaşım olarak değerlendirilebilir ve baskı sektöründe dijitalleşme trendlerine uyum sağlamak, operasyonel verimliliği artırmak ve pazar rekabetçiliğini güçlendirmek için stratejik bir araç olarak ön plana çıkmaktadır. Özellikle dijital baskı teknolojilerinin sürekli gelişim gösterdiği bir dönemde, bu tür yenilikçi çözümler sektöre büyük değer katabilir ve baskı hizmetlerinin daha etkin ve verimli bir şekilde sunulmasını sağlayacaktır.

EVALUATION OF AUTONOMOUS BIDDING AND DEVICE MANAGEMENT STRATEGIES FOR THE PRINT REPRODUCTION INDUSTRY: THE DESIGN OF A DECISION SUPPORT SYSTEM

SUMMARY

The objective of the thesis was to develop a proposal system that will analyze complex customer and market data given increased efficiency and strategic decision-making in the print industry. That system lets customers choose the suitable device model and provides dynamic pricing strategies. This model employs machine learning to understand better customer behavior and trends in the use of printing devices, which helps make the best selection of devices and setting attractive competitive prices for customers.

The research is to begin with a review of the history of the printing industry and the impacts of digital technologies on this industry. This article is entirely focused on how digitalization is evolving industrial print processes with time. What it is bringing and pushing companies to adopt in the digital age, and how it needs to be solved using new artificial intelligence and machine learning technologies. Literature underpinning the arguments for why printing industry technological enhancements are needed demonstrates how advanced computational tools can revolutionize traditional processes.

The whole methodology section of this study exposes a very holistic approach to handling autonomous bidding and device management within the print reproduction industry, using statistical and machine learning techniques to review and forecast different types of market behavior and machine requirements.

The research will account for massive data collection and involve real-time market data with specific details regarding the customer sourced from the CRM systems of companies serving in the industry. This shall include critical information, such as company profiles, printing volumes, and model preferences of the customers, essential in understanding the customer base to a level of fineness required in seeking detailed market demand patterns.

It is upon this that this thesis tries to see if the influence and levels of importance contributed by independent variables affect the dependent variable, which is the machine model listed, using the CHAID analysis approach. Particularly, this method of analysis is favored because it enables the detection of complex structures and relationships within the dataset. This is widely used in market research, customer segmentation, and medical research, as well as in social sciences. CHAID is mainly used in research where the relationship between categorical independent variables and its effect on the dependent variable is explored. This work depicts various factors concerning the classification of machine models. After completion of the CHAID analysis, inputs for the machine learning were determined, and hence, the model-creation phase is taken up.

The project involved developing a decision support system using machine learning approaches to automate selecting the best model of a machine that the firm's

salesperson uses in matching and estimating rental prices. The following work will attempt to compare these classification algorithms: Decision Trees, Random Forest, Logistic Regression, Support Vector Machines (SVM), and K-Nearest Neighbors (KNN) about the performance of the model built. They chose the Random Forest to train the model because the technique of Random Forest entails bringing together predictions from a large number of decision trees, hence reducing variance compared to a single decision tree model.

It quantified the performance with an accuracy score based on a test set. The generalization and stability were also assessed with the 5-fold cross-validation method. This helps reduce the risk of model overfitting since it shows how the model performs across different subsets of data. All the confusion matrices and classification reports presented very graphic insight into how each model is doing concerning the classes, respectively. They have helped to identify areas where they are strong and confused across classes.

This methodological framework is based on the application of advanced approaches to data analysis and machine learning techniques to better decision-making processes in the field of print reproduction. It focuses mainly on the theoretical and practical implications of being the best, and effective, and efficient in their operations.

The thesis elaborates on practical application using the developed model for machine learning in the printing industry. Through further integration, the use of the model for testing involved the application of real-time customer and market data scenarios.

The model was trained with 80% of the data and tested with the rest. This is standard training for an evaluation method against unseen testing data. In the meantime, it also means that it can be used to point out the prediction ability and generality of the model. At the stage of development, an interface was developed to enable selecting best model, pricing and bid generation. In other words, there is an developed automatic system where users will have the chance to place their data through the web form and get a proposal. At the same time, companies will see the current requests through the interface and then prepare, depending on that, suitable offers for them.

In essence, the model-generated system was used to enhance the company's decision-making processes, more so in the tailoring of dynamic pricing strategies and customer behavior analysis. This can adapt to market conditions and provides room for inclusions in a decision support system that will show practical utility in enhancing operational efficiencies and market responsiveness.

The successfully deployed model has shown to help handle industry-specific challenges and, at the same time, gives the possibility of a competitive edge through rapid adaptation to market changes and strengthening customer relationships. This has placed the decision support system as a handy tool for companies within the print reproduction industry seeking to leverage advanced technologies for strategic advantages. Therefore, this study portrays excellent headway in the aspect of automation of the process of bidding and device management relevant to the print reproduction industry.

This study demonstrates the effective integration of machine learning models into decision-making and operational efficiency enhancements. The paper elaborates on the point that the use of this system has brought improvement to both precision and adaptability to market conditions, where the testing of real-world conditions currently even shows a 90% accuracy rate.

Theoretically, the research would further make the literature richer about digital transformation within industrial processes with the view to showcasing the role that will be played by machine learning. Practically, it will enable the company to gain

more competitive advantages in the market as the developed decision support will allow the adoption of personalized and dynamic pricing strategies, through which customers could have the possibility to be more satisfied.

Some limitations must be noted in the research process. For example, the representativeness of the data set is confined to a particular market segment and time. In the future, the data set should be expanded to even more varied market conditions and possibly even more countries to make the generalizability and robustness of the model better.

This further implies the need for exploring more machine learning models and algorithms that could overcome the constraints faced by currently used models.

It communicated the transformational impact that advanced computational technologies are poised to bring to the print reproduction industry. This will open up further exploration and fine-tuning of machine learning models for decision refinement and strategic planning in the industry. Therefore, called to be addressed in future studies are the identified limitations and further generalizing the applicability of the findings to the broader practices of the industry.



1. GİRİŞ

Baskı sektörünün başlangıcı 15. yüzyıla, Johannes Gutenberg'in hareketli metal tip baskı tekniğini icat etmesine dayanır. Bu devrimci buluş, bilginin daha önce hiç olmadığı bir hızda yayılmasını sağlayarak eğitim, bilim ve kültür alanlarında derin etkiler yaratmıştır. Gutenberg'in matbaası, bilginin demokratikleşmesinde kilit bir rol oynamış ve modern dünyanın şekillenmesine önemli katkılarda bulunmuştur.

Teknolojik ilerlemeler, baskı sektörünün evriminde önemli dönüm noktaları oluşturmuştur. Buhar gücünün ve daha sonrasında elektriğin kullanımı, baskı süreçlerini hızlandırmış ve üretim kapasitesini artırmıştır. 20. yüzyılın sonlarında, dijital baskı teknolojisinin gelişimi ile baskı işlemleri daha da hızlanmış, kişiselleştirilmiş ve esnek üretim imkanları ortaya çıkmıştır. Pazar büyüme dinamikleri ve projeksiyonlar açısından, dijital baskı teknolojilerinin gelişimi, baskı endüstrisinin pazar yapısını önemli ölçüde değiştirmiş ve arttırmıştır. Dijital baskının esnekliği, kısa sürede yüksek kaliteli ve özelleştirilmiş ürünler üretebilme yeteneği, onu pazarın önemli bir segmenti haline getirmiştir. Buna ek olarak, dijital baskının çevresel etkileri, geleneksel baskı yöntemlerine kıyasla daha az olduğundan, sürdürülebilir baskı çözümlerine olan talep de bu teknolojiyi tercih edilir hale getirmiştir.

Günümüz baskı sektörü, dijitalleşme, sürdürülebilirlik ve kişiselleştirme gibi çağdaş trendlerden etkilenmektedir. Ancak COVID-19 pandemisi, baskı sektörü üzerinde beklenmedik etkiler yaratmıştır ve baskı sektöründe talep azalmasına sebep olmuştur. Ticari baskı pazarı, 2022'de 489,63 milyar ABD doları olarak değerlendirilmiş ve 2030 yılına kadar yıllık %2,8'lik bir büyüme oranıyla 598,06 milyar ABD dolarına ulaşması beklenmektedir (Grand View Research, 2023).

Bu negatif etkinin temel nedeni pandemi sırasında birçok firmanın uzaktan çalışmaya geçmesi ve kağıtsız işlemlere yönelmesidir, bu da ticari baskıya olan ihtiyacı azaltmıştır.

Baskı sektörü, teknolojik yenilikler ve değişen tüketici beklentileri karşısında sürekli olarak değişim göstermekte ve kendini yenilemek zorundadır. Baskı çoğaltma endüstrisi, dijital çağın getirdiği yeniliklere uyum sağlamak ve artan rekabet koşullarında ayakta kalmak için sürekli evrim geçirmektedir. Bu endüstri, teknolojik ilerlemelerin ve dijitalleşmenin yükselişiyle birlikte, operasyonel maliyetlerin ve kaynakların etkin yönetimine giderek daha fazla önem vermektedir. Baskı adetlerinin azalması ve müşteri taleplerinin çeşitlenmesi, firmaları daha stratejik ve veri odaklı kararlar almaya itmektedir. Bu bağlamda, doğru cihaz kiralama kararlarının yanı sıra, müşteriye özel tekliflendirme stratejilerinin uygulanması, şirketlerin sürdürülebilirliği ve karlılığı için kritik bir önem taşımaktadır.

Geliştirilmesi planlanan tekliflendirme sistemi, bu zorlukların üstesinden gelmek ve endüstriye özgü ihtiyaçları karşılamak üzere tasarlanmıştır. Sistem, müşteri ve piyasa verilerini makine öğrenimi algoritmaları ve analitik modellerle işleyerek, müşteriler için en uygun baskı çözümlerini ve fiyatlandırmayı belirleyecek bir karar destek sistemi modeli geliştirmeyi hedeflemektedir. Bu sistem, makroekonomik göstergeleri de hesaba katarak, gerçek zamanlı ve dinamik tekliflendirme yapma kabiliyetine sahip olacaktır. Bu yaklaşım, firmaların müşteri beklentilerini daha etkin karşılamasına, operasyonel verimliliği artırmaya ve rekabet ortamında avantaj elde etmesine olanak tanıyacaktır.

Sistemin geliştirilmesi sürecinde makine öğrenmesinden faydalanılmıştır. Ayrıca oluşturulan kapsamlı model, tekliflendirme aşamasında piyasa dinamiklerini, müşteri davranışlarını ve baskı cihazları kullanım trendlerini detaylı bir şekilde anlamasını sağlayacaktır. Bu anlayış, sistemin her bir müşteri için en uygun cihaz seçimini yapabilmesi ve bu seçime uygun, rekabetçi ve müşteri ihtiyaçlarını karşılayacak fiyat teklifleri sunabilmesi için kritik öneme sahiptir.

Bu tezin yapısı, baskı çoğaltma endüstrisinin dijital dönüşümünü ve makine öğreniminin bu dönüşümde nasıl kritik bir rol oynayabileceğini derinlemesine incelemek üzere tasarlanmıştır. Tezin "Giriş" bölümünde, baskı endüstrisinin tarihçesi ve dijital baskının evrimi üzerine genel bir bakış sunulmuştur, ayrıca tezin amaçları yine giriş bölümünde incelenmiştir. "Literatür Araştırması" bölümünde baskı çoğaltma endüstrisinin genel tanımı, tarihsel gelişimi, dijital baskı teknolojilerinin evrimi, yapay zeka ve makine öğrenimi teknolojileri, karar destek sistemleri ve dinamik fiyatlandırma konuları detaylı bir şekilde ele alınmıştır. Bu bölümde,

endüstrinin geçmişten günümüze kadar olan gelişim süreci ve dijital teknolojilerin baskı sektörü üzerindeki etkileri incelenmiştir. “Metodoloji” bölümünde, tezin metodolojik yaklaşımı detaylandırılmıştır. Veri analizi, girdi formu oluşturulması, makine öğrenmesi ve karar destek sisteminin oluşturulması, model değerlendirme ve validasyon aşamaları ve tekliflendirme modeli sunulmuştur. Bu bölümde, araştırmanın nasıl yürütüldüğü ve hangi yöntemlerin kullanıldığı açıklanmıştır. “Uygulama” bölümünde karar destek sisteminin nasıl tasarlandığı ve geliştirildiği detaylı olarak anlatılmıştır. Modelin oluşturulması, form tasarımı ve geliştirme süreci, makine öğrenmesi ve karar destek sisteminin oluşturulması, fiyatlandırma, model değerlendirme ve validasyon süreçleri ve örnek bir uygulama için tasarlanan kullanıcı arayüzü detaylı bir şekilde ele alınmıştır.

“Sonuç” bölümünde ise tezin ana bulgularının özeti, teorik ve pratik katkılar, limitasyonlar ve gelecek araştırmalar için öneriler sunulmuştur. Bu bölümde, araştırmanın sonuçları değerlendirilmiş ve elde edilen bulguların endüstriye olan etkileri ve gelecek çalışmalar için öneriler tartışılmıştır.

1.1 Tezin Amacı

Bu tezin temel amacı, baskı çoğaltma sektörüne yönelik bir tekliflendirme modeli geliştirerek, karmaşık müşteri ve piyasa verilerini analiz edebilme ve bu analizler ışığında hem en uygun cihaz modelini seçme hem de dinamik fiyatlandırma stratejileri sunma kapasitesine sahip bir sistem oluşturmaktır. Geliştirilecek bu model, firmalara maliyet ve zaman açısından önemli tasarruflar sunarken, müşteri memnuniyetini artırma ve pazar rekabetçiliğini güçlendirme potansiyeline sahiptir.

Modelin geliştirilmesi sürecinde, makine öğrenmesinden faydalanılacaktır. Bu sayede müşteri davranışlarının ve baskı cihazların kullanım trendlerini detaylı bir şekilde anlaşılmasını sağlayacaktır. Bu anlayış, arayüzün her bir müşteri için en uygun cihaz seçimini yapabilmesi ve bu seçime uygun, rekabetçi ve müşteri ihtiyaçlarını karşılayacak fiyat teklifleri sunabilmesi için kritik öneme sahiptir.

Model, müşteri ve güncel piyasa verilerini sürekli olarak analiz edecektir. Bu sayede, fiyatlandırma modeli dinamik bir yapıya kavuşacak ve piyasa koşullarındaki değişikliklere hızla uyum sağlayabilecektir. Modelin bu esnek yapısı, firmaların hem

piyasa dalgalanmalarına karşı dayanıklı olmalarını sağlayacak hem de kar marjlarını koruyarak sürdürülebilir bir büyüme elde etmelerine yardımcı olacaktır.

Bir diğer önemli amaç, modelin gerçek veriler üzerinde uygulanabilirliğini sağlamak ve bir kullanıcı arayüzü geliştirmektir. Arayüz geliştirilmesi sürecinde kullanıcı deneyimini ön planda tutulacak ve etkileşimli, kullanıcı dostu bir tasarım oluşturulacaktır. Arayüz, müşterilerin ve firmaların ihtiyaç duydukları bilgileri kolayca girebilmelerini, sistemden aldıkları geri bildirimleri rahatlıkla anlayabilmelerini ve tekliflendirme süreçlerini etkin bir şekilde yönetebilmelerini sağlayacaktır. Bu kullanıcı odaklı yaklaşım, sistemin endüstri genelinde kabul görüp, yaygınlaşmasına önemli katkı sağlayacaktır.

Bu tez çalışması aynı zamanda, baskı endüstrisinin dijital dönüşümüne katkıda bulunmayı ve endüstri liderlerine, karar vericilere piyasa şartları, müşteri tercihleri ve teknolojik gelişmeler hakkında değerli bilgiler sunmayı hedeflemektedir. Bu stratejik bilgiler, firmaların daha bilinçli kararlar almasını, pazar stratejilerini etkili bir şekilde şekillendirmesini ve potansiyel riskleri minimize ederken fırsatları maksimize etmesini sağlayacaktır.

Sonuç olarak, geliştirilecek tekliflendirme arayüzü, baskı çoğaltma endüstrisinde faaliyet gösteren firmalara yenilikçi bir çözüm sunmayı amaçlamaktadır. Bu arayüz, veriye dayalı karar verme süreçlerini otomatikleştirecek, müşteri ihtiyaçlarına hızlı ve etkili bir şekilde yanıt verme kapasitesini artıracak ve firmaların operasyonel verimliliğini ve pazar rekabetçiliğini önemli ölçüde iyileştirecek bir araç olarak tasarlanmıştır. Bu çalışma, baskı endüstrisinin gelecekteki yönünü şekillendirmede önemli bir rol oynayacak ve firmaların stratejik karar alma süreçlerine değerli katkılarda bulunacaktır.

2. LİTERATÜR ARAŞTIRMASI

Baskı çoğaltma endüstrisi, metin ve görsellerin çeşitli yüzeylere aktarılmasını sağlayan teknik ve süreçlerin bütünüdür. Bu endüstri, bilgiyi ve kültürel değerleri yayma, reklamcılık, eğitim materyalleri ve sanatsal ifade biçimlerini kapsayan geniş bir yelpazeye hizmet eder. Baskı teknolojileri, basit elle yapılan baskılardan karmaşık dijital ve ofset baskı yöntemlerine kadar uzanır.

Bu bölüm, baskı çoğaltma endüstrisinde karar destek sistemlerinin ve otomatize tekliflendirme süreçlerinin kullanımı üzerine mevcut literatürü inceleyecek ve değerlendirecektir. Odak noktası, özellikle cihaz kiralama model ve fiyatlandırma kararlarının verilmesi sürecinde yapay zekâ ve makine öğrenimi teknolojilerinin entegrasyonudur. Çalışma, sektördeki uygulamaları, karşılaşılan zorlukları ve bu alandaki potansiyel büyüme alanlarını kapsamlı bir şekilde araştıracaktır. Ayrıca, baskı teknolojilerinin evrimi ve pazarın değişen ihtiyaçları ışığında, bu teknolojik çözümlerin nasıl geliştirildiği ve uygulandığı üzerinde durulacaktır. Bu literatür taraması, araştırma sorularının daha iyi anlaşılmasına ve tezin ilerleyen bölümlerindeki metodolojik yaklaşımın şekillendirilmesinde temel oluşturacaktır.

2.1 Baskı Çoğaltma Endüstrisinin Genel Tanımı ve Tarihsel Gelişimi

Baskı sanatının evrimi, zamanla malzeme ve teknik çeşitliliğinin genişlemesiyle tarihin farklı dönemlerinde önemli dönüşümler geçirmiştir. Başlangıçta, Doğu Asya'da uygulanan ahşap oyma tekniği, baskı dünyasının ilk adımlarını temsil eder. Bu yöntem, zaman içinde taş, metal, çinko ve bakır gibi farklı malzemelerin işlenmesiyle zenginleşerek, baskının hem sanatsal bir ifade aracı hem de kapsamlı bir endüstriye dönüşmesine zemin hazırlamıştır. Johannes Gutenberg'in 15. yüzyılda yüksek baskı teknolojisini geliştirmesi, Avrupa'da baskıcılık alanında bir devrime öncülük etmiştir. Bu yeni sistem, kitapların seri üretimini mümkün kılarak, yazılı bilginin yayılmasını ve Avrupa Aydınlanma döneminin hızlanmasını sağlamıştır (Spilsbury, 2015).

Gutenberg'den sonra, Alois Senefelder'in 18. yüzyılın sonlarında litografiyi bulması, baskı tekniklerinde yeni bir çağ açmıştır. Bu yöntem, yağ ve suyun birbirini itme

prensibine dayalı olarak, düz yüzeylerde yazı ve resimlerin baskısını kolaylaştırmıştır. Litografinin evrimi, ince metal levhaların kullanıldığı ofset baskı tekniğine geçişi sağlamıştır. Ofset baskı, hem maliyet etkinliği hem de üstün kalite sunmasıyla 20. yüzyılın başlarında baskı endüstrisinin gelişiminde önemli bir rol oynamıştır (Senefelder, 1819).

Teknolojinin ilerlemesi ve reklamcılık faaliyetlerinin artması, yazılı ve görsel medyanın etkisini artırarak baskı endüstrisini daha da geniş bir alana yaymıştır. Yüksek tirajlı üretimler, endüstriyel ve ticari baskılar ön plana çıkmış, teknolojik yeniliklerle düşük maliyetli ve hızlı üretim yöntemleri geliştirilmiştir. Bilgisayar teknolojilerinin entegrasyonu, tasarım ve üretim süreçlerinde büyük kolaylıklar sağlamış, otomasyon sistemleri sayesinde çoğaltım teknikleri genişleyerek kaliteli baskıların hızla yapılmasına olanak tanımıştır (Uçar, 2004).

Son yüzyılda matbaacılık, dört renkli baskı sistemleri ve web ofset gibi teknolojilerle daha da ilerlemiş, ticari ve yayıncılık faaliyetleri için önemli bir altyapı sunmuştur. Değişen tüketici talepleri doğrultusunda, ambalaj, etiket ve dijital baskı gibi alanlarda büyük atılımlar yapılmış, yan sektörlerin gelişimiyle yeni istihdam fırsatları yaratılmıştır. Basın, yayın ve reklamcılık alanlarındaki gelişmelerle birlikte, gıda, ilaç ve ambalaj sanayi gibi farklı sektörlerin ihtiyaçları da baskı endüstrisinin büyümesine katkıda bulunmuştur. Web baskı teknolojisinin yaygınlaşması ve dijital baskı yöntemlerinin gelişimi, kişiye özel küçük tirajlı ürünlerin baskısında kalite ve hız açısından yeni standartlar belirlemiştir. Bu dönüşüm, baskı endüstrisinin sürekli yenilik ve gelişim içinde olduğunun bir göstergesidir (Johnson, 1973).

2.2 Dijital Baskı Endüstrisinin Gelişimi

Dijital baskı endüstrisinin evrimi, iletişim teknolojilerindeki ilerlemeler ve dijital yeniliklerin küresel yayılımıyla birlikte hız kazanmıştır. Bu ilerlemeler, sanatsal üretimden endüstriyel uygulamalara kadar geniş bir yelpazede yeni imkanlar sunmuştur. Bilgisayar ve iletişim teknolojilerinin yaygınlaşması, neredeyse tüm sektörlerde dijitalleşmenin etkisini göstermiş ve sanat dünyasına da yeni bir soluk getirmiştir. Grafik tasarım ve görsel sanatlar alanında, dijital teknolojilerin hem tasarım sürecinde hem de nihai ürünün üretiminde kullanılması, baskı endüstrisinde bir dönüşüm yaratmıştır (Tunçel, 2019).

Dijital baskı teknolojileri, materyal ne olursa olsun, hızlı ve yüksek kaliteli baskı imkanı sunarak basım endüstrisinde yeni bir ekosistem oluşturmıştır. Bu sistemler, basılı ve görsel medya, ambalaj, reklamcılık, iç ve dış mekân tasarımı gibi çeşitli alanlarda kullanılmakta ve yenilikçi teknolojileriyle endüstrinin önemli bir parçası haline gelmiştir. İlk dönemlerde küçük çaplı işler için tercih edilen dijital baskı, zamanla geleneksel tekniklerle rekabet edebilir hale gelmiş ve baskı kalitesi ile hızı açısından önemli ilerlemeler kaydetmiştir (Kwon et al., 2020).

Dijital baskı sistemlerinin gelişimi, basım endüstrisinde önemli dönüşümlere yol açmıştır. Bu sistemler, geleneksel yöntemlere kıyasla yeni niş alanlara yönelik yüksek katma değerli ürün ve hizmetler sunma potansiyeline sahiptir. Teknolojik altyapı ve yenilikçi uygulamalarıyla dijital baskı, geleneksel tekniklerin tamamlayıcısı olmanın ötesine geçerek, sektöre yeni fırsatlar sunmaktadır (Tunçel, 2019).

Matbaa ve baskı şirketleri, değişen pazar koşullarına uyum sağlamak amacıyla giderek daha fazla ileri teknolojiye sahip dijital baskı makinelerine yönelmektedir. Bu yönelim, toner ve diğer sarf malzemelerine olan talebi artırmakta ve teknoloji üreticileri arasındaki rekabeti körüklemektedir. Sonuç olarak, daha iyi teknolojilerin geliştirilmesi, ürün çeşitliliğinin ve maliyet etkinliğinin artması gibi olumlu gelişmeler yaşanmaktadır (Tyler, 2005).

Dijital baskı sistemleri, herhangi bir kalıba ihtiyaç duymaksızın, istenilen ebatta ve adette baskı yapabilme esnekliği sunar. Bu, zaman ve maliyet tasarrufu sağlamanın yanı sıra, değişken veri baskısına uygun yapısıyla kişiselleştirilmiş ürünlerin üretilmesine olanak tanır. Dijital baskı, geleneksel yöntemlere kıyasla daha hızlı dönüşüm süreleri ve işlerde tutarlılık sağlayarak, sektörde giderek daha tercih edilen bir yöntem haline gelmiştir.

Küçük ölçekli işletmeler için düşük tirajlı ve özel baskı işleri, pazardaki büyük oyuncularla rekabet edebilme imkânı sunmaktadır. Dijital teknolojilerin gelişimi, e-kitaplar ve dijital yayınlar gibi yeni medya formatlarının ortaya çıkışıyla birlikte, yüksek tirajlı baskı işlerine olan talebin azalmasına yol açmıştır. Bu trend, baskı endüstrisinin geleceğinin dijitalleşme yönünde evrildiğini göstermektedir.

Dijital baskı, ofset baskıyla karşılaştırıldığında, özellikle düşük tirajlı işlerde maliyet avantajı sunmaktadır. Ayrıca, dijital baskı teknolojileri, tasarım değişikliklerine esneklik sağlayarak ve fiziksel girdi süreçlerini ortadan kaldırarak, grafik tasarım ve

sanat alanında yaratıcılığı teşvik etmektedir. Dijital baskı sistemleri, kişiye özel ve özelleştirilmiş üretimler yapabilme kabiliyetiyle, müşterilerin duygusal ve mantıksal ihtiyaçlarını karşılayarak, geleneksel seri üretimlere göre daha yüksek karlılık sunmaktadır (Kwon et al., 2020).

Çağımızda, ekonomik büyümenin temelini oluşturan imalat endüstrisinin yerini, bilgiye, teknolojiye ve hizmetlere dayalı yeni sektörler almıştır. Bu geçiş, post-modern dönemin başlangıcıyla birlikte, dijitalleşme, yenilikçilik ve tasarım odaklı endüstrilerin ön plana çıkmasını sağlamıştır. Dijital içerik üretimi ve hizmetlerin geliştirilmesinde önemli bir rol oynayan basım sektörü, bu dönüşümle birlikte, yaratıcılığı ve dijital inovasyonları destekleyen bir yapıya bürünmüştür. Dijital teknolojilerin 1990'larla birlikte yaşadığı gelişme, sanat alanında da yeni ifade biçimlerinin ve uygulamaların doğuşuna öncülük etmiştir. Dijital araçlar kullanarak sanatını ifade eden sanatçılar, eserlerini dijital ortamda yeniden yaratmış ve dijital baskı tekniklerini eserlerini çoğaltmak için benimsemişlerdir (Tyler, 2005).

Görsel iletişim ve grafik tasarım, dijital dönüşümün etkisiyle, çağımızın ayrılmaz birer parçası haline gelmiştir. Baskı teknikleri, sanat eserlerinin geniş kitlelere ulaşmasında kritik bir role sahip olmuş ve gelişen teknoloji ile global bir endüstriye evrilmiştir. Bilgi teknolojilerine yapılan yatırımlar sayesinde, basım endüstrisi bilgi çağının ihtiyaçlarına uygun olarak gelişimini sürdürmektedir. Küreselleşme ve bilgi iletişim teknolojilerinin yükselişi, 'enformasyon toplumu' kavramının post-endüstriyel dönemde öne çıkmasını sağlamıştır. Kültürel, sanatsal ve sosyal alanları şekillendiren bilişim teknolojileri, sanatçılara ve tasarımcılara yeni araçlar sunarak yaratıcılıklarını genişletmelerine olanak tanımıştır.

Geleneksel iş süreçlerinin yerini yeni iş modelleri ve pazarların alması, teknolojinin ilerlemesiyle sosyal ve kültürel yapıların da dönüşümüne işaret etmektedir. Yaratıcılığın ve bireyselliğin öne çıktığı bu yeni dönem, bilgi ve hizmet odaklı üretimlerin önem kazandığı, müşteri merkezli ve esnek üretim süreçlerinin geliştiği bir ekosistemi beraberinde getirmiştir. Dijital teknolojilerin sağladığı bu dönüşüm, sadece teknik alanlarda değil, ekonomik ve sosyal yapıları da yeniden şekillendirmiştir. Dijitalleşen dünyada, ağ tabanlı iletişim ve etkileşimler, insanlar, makineler ve nesneler arasında yeni bir etkileşim alanı yaratmıştır.

2.3 Yapay Zekâ ve Makine Öğrenimi Teknolojileri

2.3.1 Yapay zekâ ve makine öğrenimi temelleri

Yapay zekâ (YZ), genellikle görsel algı, konuşma tanıma, çeviri, karar verme ve tahmin gibi insan zekâsının gerektirdiği işlevleri yerine getiren bilgisayar sistemlerini tanımlamak için kullanılan geniş bir terimdir. Makine öğrenimi, bu geniş kavramın altında yer alan önemli bir alanı temsil eder. Bu bölüm, önemli öğrenme stratejilerinin temellerine yönelik bir rehber olarak işlev görür. Makine öğrenimi, mevcut verilerden sınıflandırma ve tahmin modelleri oluşturan bir bilgisayar algoritması sınıfını ifade eder. Burada bilgisayar, deneyimlerden öğrenir ve bu deneyimleri performansını geliştirmek için kullanır. Makine öğreniminin ana fikri, kavram öğrenimidir. Kavram öğrenimi, somut örneklerden genel bir kuralı tanımlama yöntemi geliştirmektir. Eğer örnekler, özelliklerine göre tanımlanırsa, bir makine öğrenimi algoritması, bu özellikleri belirli bir çıktıya eşleyen bir fonksiyondur. Bu bölümdeki çoğu örnekte, sınıflandırma önemli bir yapı taşıdır çünkü makine öğreniminin başarabileceği her şeyin temelini oluşturur (Atalay & Çelik, 2017; Rosenblatt, 1957; Sejnowski, 2018).

Büyük veri kümeleri, makine öğrenimi modellerinin etkin bir şekilde öğrenmesi için genellikle şarttır. Makine öğreniminin ana yaklaşımları arasında gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme bulunmaktadır. Gözetimli öğrenme sürecinde, model, insan tarafından sınıflandırılmış ve etiketlenmiş verilerle eğitilir. Gözetimsiz öğrenme ise, etiketlenmemiş veriler üzerinde çalışır ve bu verileri benzerliklerine göre gruplandırmak için çeşitli algoritmaları kullanır. Her iki durumda da, modelin performansı, gerçek sonuçlarla modelin tahminleri arasındaki uyumsuzluğu azaltarak artırılır. Pekiştirmeli öğrenmede, model, çevresel etkileşimlerden yola çıkarak ödül bazında en iyi davranışı belirlemeye çalışır (Sejnowski, 2018).

Derin öğrenme ve sinir ağları en yeni makine öğrenimi formları olarak düşünülse de, bu durum böyle değildir. Modern sinir ağlarının ilkel ataları, Rosenblatt'ın 1957'deki çalışmasıyla başlamıştır (Rosenblatt, 1957). Bu sinir ağları, McCulloch ve Pitt'in bir on yıl önce ortaya koyduğu nöron fonksiyonları teorisine dayanarak geliştirilmiştir. Temel olarak, birbirleriyle bağlantılı katmanlarda yer alan simüle edilmiş nöron dizilerinden oluşur (McCulloch & Pitts, 1943). Her bir katman, bir önceki katmandan alınan girdileri daha karmaşık bir yapıya dönüştürür, bu da algoritmanın

tanımlanamayan bir girdiyi çözümle eşleştirebilmesine imkan verir. "Derin öğrenme" ifadesi, algoritmanın karmaşıklığına ya da düşünme kapasitesini etkileyici bir biçimde taklit etme yeteneğine değinmez; bu terim, birçok doğrusal olmayan işlem biriminin ve bu birimlerin lineer bağlantılarının varlığına işaret eder. Aslen, derin öğrenme lineer cebir, çoklu değişkenli hesaplama ve istatistik gibi alanları içerir. Bu gelişim sürecinde, sinir ağlarıyla eş zamanlı olarak, genelde yüzeyel öğrenme olarak bilinen başka makine öğrenimi modelleri de geliştirilmiştir. Bu modeller, programa büyük bir önceden bilinen örnekler ve tanımlayıcı özellikler içeren veri seti sağlar. En temel senaryoda, eğitim seti iki farklı sınıfa ait nesneler içerir ve programın, bu bilinmeyen örneğin hangi sınıfa ait olduğunu tahmin edebilmesi için bir model geliştirmesi gerekir. Sinir ağlarının öne çıkan bir avantajı, verilerden kendi başlarına özellikler çıkarabilmesi (özellik öğrenimi) olup, yüzeysel öğrenmenin ise programcı tarafından özelliklerin açıkça tanımlanmasını gerektirmesidir. Derin öğrenme, algoritmanın ödül fonksiyonunu maksimize etme yoluyla çevresel değişikliklere yanıt verdiği pekiştirmeli öğrenme için de kullanılabilir (Cohen, 2021).

2.3.2 Makine öğrenmesi algoritmaları modelleri

Makine öğrenimi algoritmaları dört temel kategori altında incelenir: Gözetimli öğrenme, Gözetimsiz öğrenme, Yarı gözetimli öğrenme ve Pekiştirmeli öğrenme:

- **Gözetimli Öğrenme:** Bu yöntem, belirli giriş-çıkış çiftlerinden yola çıkarak, girişleri çıkışlara bağlayan bir fonksiyon öğrenme sürecidir. Etiketlenmiş eğitim verilerini kullanarak, belirli hedeflere ulaşmak için bir fonksiyon tahmin eder. "Sınıflandırma" ve "regresyon" gözetimli öğrenmenin en yaygın iki uygulamasıdır. Örneğin, bir metin parçasının veya ürün incelemesinin duygusunu tahmin etmek bu kategoride değerlendirilir.
- **Gözetimsiz Öğrenme:** İnsan müdahalesine gerek kalmadan etiketlenmemiş veri kümelerini analiz eder. Genelde veri içindeki örüntüleri, gruplamaları ve yapıları keşfetmek için kullanılır. Kümeleme, yoğunluk tahmini ve boyut indirgeme gözetimsiz öğrenmenin başlıca görevlerindendir.
- **Yarı Gözetimli Öğrenme:** Hem etiketli hem de etiketlenmemiş verileri kullanarak çalışan, gözetimli ve gözetimsiz öğrenmenin birleşimi olarak kabul edilir. Etiketli verilerin kısıtlı olduğu, etiketlenmemiş verilerin ise bol miktarda bulunduğu durumlarda yarı gözetimli öğrenme faydalıdır.

- **Pekiştirmeli Öğrenme:** Yazılım ajanlarının ve makinelerin belirli bir durumda en iyi davranışı keşfetmesini sağlayan bir makine öğrenimi türüdür. Ödül ya da ceza mekanizmasına dayalıdır ve amacı, çevresel etkileşimlerden elde edilen bilgilerle ödülü maksimize etmek ya da riski minimize etmektir. (Sarker, 2021)

Bu öğrenme türleri, verinin niteliği ve amaçlanan sonuca bağlı olarak, çeşitli uygulama alanlarında etkili modeller oluşturmak için önem arz eder. Makine öğrenimi algoritmaları, veriye dayalı uygulamaların zekâ ve yeteneklerini geliştirmek için kullanılabilir.

2.3.2.1 Gözetimli öğrenme modelleri

Makine öğreniminin temel adımları eğitim ve değerlendirme olmak üzere iki kısımdan oluşur. Eğitim sürecinde, model algoritmayı kullanarak eğitim verilerindeki örneklerden özellikleri öğrenir ve bir tahmin modeli geliştirir. Değerlendirme sürecinde ise, bu model test veya gerçek dünya verileri üzerinde tahminler yapmak için kullanılır ve modelin çıktısı, sonuçları etiketleyerek nihai sınıflandırılmış veya tahmin edilmiş verileri sunar. Gözetimli öğrenme, modelin belirlenen bir sınıflandırma düzenini öğrenmesi gerektiğinde en yaygın kullanılan yöntemdir. Bu yöntemde, model belirli bir girdiye karşılık gelen çıktıyı tahmin etmek üzere eğitilir, burada girdi-çıkı çiftleri önceden belirlenmiş ve etiketlenmiştir. Gözetimli öğrenme, belirli hedeflere ulaşılmasını amaçlayan bir yaklaşım altında gerçekleşir ve en sık "sınıflandırma" (verileri ayırmak) ve "regresyon" (verilere uyum sağlamak) olmak üzere iki ana göreve ayrılır. Örneğin, bir ürün yorumunun duygusunu tahmin etmek, gözetimli öğrenmenin bir uygulamasıdır. Gözetimsiz öğrenme, insan müdahalesine gerek kalmadan etiketlenmemiş veri kümeleri üzerinde çalışır ve verilerdeki yapıları veya grupları keşfetmek için kullanılır. Yarı gözetimli öğrenme, hem etiketlenmiş hem de etiketlenmemiş veriler üzerinde çalışarak, bu iki yöntemin birleşimi olarak kabul edilir. Pekiştirmeli öğrenme, bir ajanın çevresel sinyallerden ödül veya ceza alarak en iyi davranışı öğrenmesine dayanır. Bu öğrenme türü, karmaşık sistemlerin optimizasyonu veya otomasyonunu artırmak için güçlü bir araçtır. Her bir makine öğrenimi tekniği, öğrenme kabiliyetlerine bağlı olarak, belirli veri türleri ve hedef sonuçlar göz önünde bulundurularak çeşitli uygulama alanlarında etkili modellerin oluşturulmasında önemli bir rol oynayabilir (Nasteski, 2017).

2.3.2.2 Gözetimsiz öğrenme modelleri

Gözetimsiz öğrenme, yapay sinir ağlarının girdi desenlerini analiz ederek bu desenlerin genel yapısını yansıtacak biçimde öğrenmesini ifade eder. Bu yaklaşım, etiketlenmemiş verileri kullanarak altta yatan yapıları ortaya çıkarmaya çalışır ve öğrenme süreci herhangi bir dış denetim olmaksızın gerçekleşir. Algoritmalara geniş kapsamlı veri setleri sunulur; bunlar, belirli bir çıktı beklenmeden, her gözlemin özelliklerine dayanır. Gözetimsiz öğrenme, özellikle veri setlerini renk, boyut ve şekil gibi temel özelliklere göre gruplandırmak için kullanılır. Bu süreç, ağın kendi kendine örgütlenmesini ve girdi verilerinden önemli bilgileri bağımsız bir şekilde öğrenmesini sağlar, dolayısıyla bu yöntem kendiliğinden örgütlenen veya uyarlanabilir öğrenme olarak da adlandırılır (Dike vd., 2018; Yusof vd., 2017).

Eğitim verileri, sistem tarafından kategorilere ayrılarak işlenir ve bu süreç, giriş katmanında başlar; çıktı katmanındaki düğümler arasındaki rekabet, en yüksek değere sahip düğümün seçilmesiyle sonuçlanır. Gözetimsiz öğrenme, veri kümeleme ve ilişkilendirme gibi algoritmalar için özellikle faydalıdır. Ancak, ileri beslemeli sinir ağlarında bu yaklaşımın uygulanması, düşük hız, yüksek hafıza karmaşıklığı ve düşük doğruluk gibi sorunlarla karşı karşıya kalabilir. Bu sorunların nedenleri üzerine yapılan çalışmalar (Asadi vd., 2017), gözetimsiz öğrenmenin hem makine öğreniminde hem de gerçek dünya uygulamalarında nasıl kritik bir role sahip olduğunu ortaya koymaktadır. Gözetimsiz öğrenmenin başlıca meydan okuması, etiketlenmemiş veriler içerisindeki gizli yapıları keşfetmektir (Dike vd., 2018).

2.3.2.3 Yarı gözetimli öğrenme modelleri

Yarı gözetimli öğrenme, etiketlenmiş ve etiketlenmemiş verilerin bir arada kullanılmasını içeren bir makine öğrenimi yaklaşımıdır ve bu yöntem, gözetimsiz öğrenme ile tam gözetimli öğrenme arasında bir konumda bulunur. Bu yaklaşım, özellikle sınırlı miktarda etiketlenmiş verinin yanı sıra bol miktarda etiketlenmemiş veri kullanılarak öğrenme doğruluğunu önemli ölçüde artırabilir. Etiketlenmiş verilerin elde edilmesi genellikle uzman bir insan müdahalesi gerektirirken, etiketlenmemiş verilerin toplanması daha ekonomiktir. Bu durum, etiketleme işlemiyle ilişkili yüksek maliyetler nedeniyle tam etiketli bir eğitim seti oluşturmanın zor olduğu durumlarda yarı gözetimli öğrenmenin pratik değerini artırır. Yarı

gözetimli öğrenme, makine öğrenimi araştırmalarında teorik bir ilgi alanı olmasının yanı sıra, insan öğrenme modeli olarak da incelenmektedir (Learning, 2006).

2.3.2.4 Pekiştirmeli öğrenme modelleri

Pekiştirmeli öğrenme, ajanların etkileşimli bir ortam içinde kendi deneyimlerinden öğrenmelerini sağlayan bir makine öğrenme stratejisidir. Bu yöntem, önceden belirlenmiş örneklerin sunulduğu gözetimli öğrenmeden farklı olarak, ajanın çevresiyle olan etkileşimine dayanır. Pekiştirmeli öğrenme problemleri genellikle bir Markov Karar Süreci olarak tanımlanır ve ardışık karar alma süreçlerini kapsar. Temelde, bir pekiştirmeli öğrenme problemi Ajan, Çevre, Ödül ve Politika olmak üzere dört ana unsuru içerir. Bu yöntem, Model Tabanlı ve Modelden Bağımsız olmak üzere iki ana kategori altında incelenebilir. Model Tabanlı yaklaşımlar, çevrenin modeli üzerinden eylemlerin sonuçlarını gözlemleyerek optimal davranışı öğrenme sürecidir. Örneğin, AlphaZero ve AlphaGo gibi sistemler bu kategoriye girer. Modelden Bağımsız yaklaşımlar ise, Markov Karar Sürecinin geçiş olasılıkları ve ödül fonksiyonlarına başvurmadan ilerler. Q-öğrenme, Derin Q Ağı ve Monte Carlo Kontrolü gibi yöntemler bu kategoriye örnektir. Politika ağı, Model Tabanlı yaklaşımlar için gereklidir ancak Modelden Bağımsız yaklaşımlarda gerekli değildir ve bu iki öğrenme biçimi arasındaki temel ayrım noktasını oluşturur. Monte Carlo yöntemleri, rastgele örnekleme üzerine kurulu hesaplama teknikleridir ve belirli bir sorunu çözmek için rastgeleliği kullanır. Q-öğrenme, ajanın hangi koşullar altında hangi eylemi yapacağını öğrenmesini sağlayan bir modelden bağımsız pekiştirmeli öğrenme algoritmasıdır. Derin Q-Öğrenme, başlangıç durumunun nöral ağa girildiği ve tüm olası eylemlerin Q-değerlerinin çıktı olarak verildiği bir süreçtir. Pekiştirmeli öğrenme, çeşitli gerçek dünya problemlerinin çözümünde kullanılabilecek temel bir makine öğrenme yaklaşımıdır ve oyun teorisi, kontrol sistemleri, işletme yönetimi, simülasyon optimizasyonu, üretim ve lojistik gibi pek çok alanda uygulanabilir (Sarker, 2021).

2.3.3 Endüstriyel uygulamalarda yapay zekâ ve makine öğrenimi

Yapay zeka, bilgisayar simülasyon sistemleri üzerinden üretim modelleri oluşturarak, acil durumlarda uygun önlemlerin alınmasını sağlayan geniş çaplı veri analizlerini gerçekleştirir. Bu yaklaşım, üretim sistemlerinin kesintisiz çalışmasını destekler, üretim şirketlerinin sermaye kaybı riskini azaltır ve üretim verimliliği ile doğruluğunu

önemli ölçüde artırır. Son birkaç yıl içinde, bu prensiplerin gelecek endüstri üretimlerine entegre edilmesine yönelik önemli araştırmalar yapılmıştır. Geçmiş on yıllar incelendiğinde, makine tasarımlarındaki artan karmaşıklık nedeniyle makine arızalarının arttığı gözlemlenmiştir. Makinelerin performansının ömür boyu güncel kalabilmesi için uygun durum izleme ve problem teşhisi gerekmektedir. Son yıllarda, makine arıza teşhisi üzerine yapılan araştırmalar önemli ölçüde artmıştır (Prim, 2006).

Mekanik tasarım, üretim ve otomasyon gibi süreçler, önemli miktarda veri işlemeyi gerektirir. Modelleme ve gösterim süreçlerinde, hesaplamalar için çok sayıda formül gerekmektedir. Eğer süreç tamamen manuel hesaplamalara dayanıyorsa, hataların oluşma olasılığı yüksektir ve bu durum, düzeltilmesi zaman alıcı olabilir. Bu nedenle, yapay zekanın bilgileri ayırt etme ve sınıflandırma kapasitesi, hesaplama gücünü artırarak sonraki hataların veya başarısızlıkların önlenmesine yardımcı olur. Sorun tanımlama doğruluğunu artırmak için, kaydedilen titreşim sinyalinin gürültüyü ayıklamak amacıyla istatistiksel faktör kullanılır (Turgut et al., 2019).

Yapay zekâ ayrıca mekanik arızaları tespit edebilir. İlk olarak, veriler makineler tarafından kontrol edildikten sonra sisteme girilir, böylece Arıza Tespitinde Uzman Sistem Teorisi yöntemi devreye girer. Akıl yürütme makinesi daha sonra, gerekli teşhis verilerini toplamak ve uzman yargılarını sunmak için ileri çıkarım motorunu kullanır. Son olarak, tarihteki en benzer durumları bulmak için zeki arama kullanılır ve ardından mekanik sorunların tanımlanması için tarihi örnekler temel alınarak benzerlik tahmin edilir. Yapay zeka teknolojilerinin ekipman korumasında da faydaları görülebilir. İlk olarak, gerçek ekipmanın işleyişi hakkında veriler toplanır ve ardından, personelin bakım için bilgilendirilmesini sağlayacak sorun veya uyarılar verebilecek bir eğitim modeliyle karşılaştırılır. Yapay zeka, sistem güvenliğini korumanın yanı sıra süreçlerdeki aksamaları azaltır ve üretim verimliliğini artırır (Nasiri et al., 2017).

Kalite kontrol departmanı, bir şirketin itibarı için çok önemlidir. Her ürün tespit edilir ve geri bildirim alır. Ancak, genel olarak bakıldığında, manuel tespitin tutarlı olamayacağı ve ürün çeşitliliği göz önüne alındığında, aynı kişinin zaman ve fiziksel veya mental durumuna bağlı olarak farklı test standartları uygulayabileceği kabul edilir. Dolayısıyla, kitlesel üretim ürünleri söz konusu olduğunda, manuel tespit zordur. Ancak, yapay zekâ tespiti, süreci hızlandırabilen ve daha tutarlı kalite denetimleri gerçekleştirebilen bir yaklaşımdır. Geleneksel üretim işletmelerinde,

tekrarlanan tehlikeli üretim süreçleri nedeniyle güvenlik temel ve çok önemli bir husustur. Yapay zekâ sayesinde, çalışma ortamının güvenliğini değerlendiren benzersiz analitik sistemlerle, sistem arızası veya tehlike durumlarında çalışanların alması gereken ek adımlar konusunda uyarılar yapılabilir. Yapay zekâ, bilgisayar görüşü kullanarak, yerindeki çalışanların güvenlik standartlarına uyup uymadığını analiz edebilir, böylece endüstride güvenlik koşullarını büyük ölçüde iyileştirebilir (Cohen, 2021).

Ürün geliştirme ve üretim sürecinde, yapay zekâ, yoğun veri depolama ve işleme kapasitesiyle, müşterilerin doğru ürünü bulmalarına yardımcı olabilir ve üretim sürecinde en hassas ürünlerin üretilmesine katkıda bulunabilir. Ayrıca, yapay zekâ, uzun mesafelerde bakım sağlayabilir, arızaları ele alabilir ve ürün güncellemeleri yapabilir.

2.3.4 Baskı endüstrisinde yapay zekâ uygulamaları

Yapay zekâ, baskı endüstrisinde devrim yaratma potansiyeline sahip bir teknolojidir. Bilgisayar biliminin bu dalı, makinelerin insan zekâsını simüle etmesine olanak tanır ve makine öğrenimi, veri analizi ve robotik ile birleşerek baskı sürecinin çeşitli yönlerinde yenilikler sunar. Bu yenilikler arasında baskı kalitesinin iyileştirilmesi, kişiselleştirme, öngörücü bakım, görevlerin otomatikleştirilmesi ve tedarik zinciri optimizasyonu yer alır.

Baskı kalitesi, yapay zekâ tarafından yönlendirilen algoritmaların yardımıyla önemli ölçüde artırılabilir. Algoritmalar, her baskı işi için çözünürlüğü ve renk dengesini optimize ederek, daha keskin ve canlı baskılar elde edilmesini sağlar. Kişiselleştirme, yapay zekâ sistemlerinin, basılı materyallerin alıcısı hakkında toplanan verileri analiz ederek içeriği buna göre özelleştirmesiyle mümkün hale gelir. Bu, işletmelerin hedef kitleleriyle daha etkili bir şekilde iletişim kurmasını sağlar (Javaid et al., 2022).

Yapay zekâ ayrıca, baskı makinelerinin bakımında da kullanılabilir. Makineler, kendilerini izleyebilir, potansiyel arızaları önceden tahmin edebilir ve sorunlar büyümeden bakım yapılmasını planlayabilir. Bu, maliyetleri düşürürken üretim süreçlerinin kesintisiz devam etmesini sağlar. Ayrıca, yapay zeka, baskı öncesi hazırlık gibi tekrarlayan görevleri otomatikleştirerek, insan kaynaklarının daha yaratıcı işlere odaklanmasına olanak tanır.

Tedarik zinciri optimizasyonu, yapay zekanın baskı endüstrisine sunduğu bir diğer önemli katkıdır. Yapay zeka, malzeme talebini tahmin ederek ve envanter yönetimini iyileştirerek, gereksiz stok tutma maliyetlerini azaltır ve atığı önler.

Baskı endüstrisinde yapay zekanın uygulamaları geniş bir yelpazeye yayılır. Değişken Veri Baskısı (DVB), kişiselleştirilmiş pazarlama materyallerinin üretiminde yapay zekanın kullanıldığı bir alandır. Yapay zeka, her bir alıcı için benzersiz baskılar oluşturarak, markaların müşteri etkileşimini artırmasına yardımcı olur. Renk düzeltme ve iyileştirme, yapay zekanın baskı kalitesini artırdığı bir başka alandır. Yazılımlar, her baskının renklerini gerçek zamanlı olarak analiz edip ayarlayarak, yüksek kaliteli sonuçlar elde edilmesini sağlar. Kalite kontrol, yapay zekanın baskı sürecindeki hataları otomatik olarak tespit edebilmesiyle önemli ölçüde iyileştirilmiştir. Bu, üretim maliyetlerinin düşürülmesine ve atığın azaltılmasına katkıda bulunur. Yapay zeka ayrıca, baskı sürecinin tamamını, baskı öncesi hazırlıktan sonrasına kadar otomatikleştirebilir, işgücü maliyetlerini azaltır ve üretim verimliliğini artırır (Denicola et al., 2021).

Baskı endüstrisinde yapay zekanın getirdiği zorluklar ve fırsatlar dengeli bir şekilde değerlendirilmelidir. Yapay zekâ sistemlerinin uygulanması maliyetli olabilir ve işgücü piyasasında dönüşümlere neden olabilir. Ancak, yapay zekâ, baskı süreçlerini daha verimli hale getirerek, kişiselleştirilmiş ürünler sunma ve sürdürülebilirlik gibi yeni gelir akışları yaratma fırsatları sunar. Yapay zekâ, baskı endüstrisinin rekabet avantajı kazanmasına ve küresel pazarlara erişimini genişletmesine olanak tanıyarak, sektördeki yenilik ve yaratıcılığı teşvik eder.

2.4 Karar Destek Sistemleri

Karar Destek Sistemleri (KDS), karar verme süreçlerinde çözüm bulma amacı güden etkileşimli bilgisayar bazlı bilgi sistemleridir. Bu sistemlerin temeli, 1950'lerin sonu ve 1960'ların başında Carnegie Teknoloji Enstitüsü'nde Herbert A. Simon ve ekibinin yaptığı organizasyonel karar verme üzerine teorik incelemeler ve aynı dönemde MIT'de Thomas J. Gerrity ve meslektaşlarının etkileşimli bilgisayar sistemleri üzerine yürüttüğü teknik çalışmalara dayanır. Simon'un karar verme süreci modeli, problem tespiti (istihbarat), alternatiflerin geliştirilmesi (tasarım) ve seçim yapılması aşamalarını içerir ve bu model, karar verme süreçlerinin temel bir çerçevesi olarak geniş çapta benimsenmiştir (Bhatt & Zaveri, 2002; Lee & Huh, 2006).

1970'ler ve 1980'ler boyunca KDS arařtırmaları ve uygulamaları önemli bir evrim geirmiş ve bu dönemde KDS, bilgi sistemleri alanında öne ıkan konulardan biri haline gelmiştir. Bu sistemler, organizasyonların her seviyesindeki karar vericilere destek olacak şekilde tasarlanmıştır ve problem yapılandırma, operasyonel yönetim, finansal yönetim ve stratejik karar alma gibi geniş bir yelpazede yardımcı olacak şekilde geliştirilmişlerdir (Hess et al., 2000).

Karar Destek Sistemlerinin yanı sıra, Grup Karar Destek Sistemleri (GKDS) ve Yönetici Bilgi Sistemleri (YBS) gibi kavramlar da ortaya ıkmıştır. GKDS, ekip bazında problem özme süreçlerinde fikir oluřturma, deęerlendirme ve iletişim desteęi sunarken; YBS, KDS'nin kullanım alanını bireysel veya küçük grup düzeyinden kurumsal düzeye taşımıştır ve kritik başarı göstergeleri, ayrıntılı raporlama ve rekabeti analiz gibi geniş bir bilgi yelpazesi sunmuřtur (Hamřioęlu, 2018). Ancak, 1990'lara gelindięinde, geleneksel KDS'ye olan ilginin azaldığı ve yeni zorluklarla karşı karşıya kaldığı görölmüřtür. Bu durum, izole ve baęımsız KDS'lerin sınırlılıklarından kaynaklanmaktadır. KDS üzerine yapılan alıřmalar, yapay zekâ, operasyon arařtırmaları, organizasyon teorisi ve yönetim bilgi sistemleri gibi farklı disiplinlerden gelen katkılarla daha da zenginleşmiş ve derinleşmiştir.

KDS'nin gelişimi, karar verme süreçlerinin daha etkin ve verimli hale getirilmesinde önemli bir rol oynamaktadır. Karar verme süreçlerindeki bu evrim, organizasyonların karşılařtıkları karmařık problemleri özmede ve stratejik kararlar almada daha donanımlı hale gelmelerine olanak tanımaktadır (Anameri, 2005).

KDS ilgili ana zorluklar arasında řunlar bulunmaktadır;

- Veri tabanından veri ambarı ve Çevrimii Analiz İşleme (OLAP)'ye, ana bilgisayardan istemci/sunucu mimarisine ve tek kullanıcı modelinden Dünya apında Ağ erişimine doęru yařanan teknoloji deęişimleri;
- ERP (kurumsal kaynak planlaması), SCM (tedarik zinciri yönetimi) ve CRM (müşteri ilişkileri yönetimi) gibi dięer bilgi sistemlerinin de ele aldığı, daha dinamik iş ortamı ve zekâ ile artan baęlantı;
- Karar vericiler üzerinde büyük biliřsel yük oluřturan karar durumlarının artan karmařıklığı, kullanıcının kararlarla ilgili görevleri yerine getirebilmek için önemli bilgi birikimine ve girişimde bulunma yetisine sahip olmasını gerektirir. (Gupta et al., 2007)

Yukarıda belirtilen zorlukların arkasında yatan ortak anahtar mesele, geleneksel problem çözme karakterizasyonunun, karar vericilerle sistemler arasında daha şeffaf bir etkileşim sağlamak, kararların verimliliğini ve etkinliğini artırmak, aynı zamanda işbirlikçi destek ve sanal takım çalışması için, yeni teknolojiler, iş ortamları ve zekâ ile uyumlu hale getirilerek genişletilip entegre edilmesi gerekliliğidir. "Bağımsız" KDS eleştirileri ve KDS'nin iş zekâsı ve modern teknolojilerle yakından bağlantılı hale getirilmesi gerekliliği dile getirilmişken, birçok araştırmacı bu gereksinimleri ele almayı hedefleyen entegre yaklaşımların yolculuğuna başlamıştır (Van Der Meer et al., 2012).

2.4.1 Farklı endüstrilerde karar destek sistemlerinin kullanımı

Günümüzdeki teknolojik ilerlemeler, iş dünyasının dinamiklerini dönüştürmekte ve işletmelerin operasyonel süreçlerini daha etkin bir şekilde yönetmelerine olanak tanımaktadır. Bu gelişmeler sayesinde, işletmeler karar alma süreçlerini hızlandırabilmekte, operasyonel verimliliklerini artırabilmekte, maliyetleri optimize edebilmekte ve piyasadaki rekabetçi konumlarını güçlendirebilmektedirler. Teknolojik sistemlerin işletmelere sunmuş olduğu belki de en kritik avantaj, veriye erişim ve bilgi yönetimi alanında sağladıkları kolaylıklardır. Karar verme süreçleri, doğru ve zamanında erişilen veri ve bilgiler olmadan etkili bir şekilde yürütülemez. Bu sebeple, işletmeler sürekli olarak hem iç hem de dış çevrelerinden bilgi akışı sağlamak zorundadırlar. Teknolojiye yatırım yapan işletmeler, bu hayati veri ve bilgilere hızla erişebilme avantajına sahiptirler (Faulin et al., 2012; Rathee et al., 2020).

Ancak, toplanan bu değerli bilgilerin işlenmesi ve işletme stratejilerine dahil edilmesi gerekmektedir. İşte bu noktada, Yönetim Bilgi Sistemleri (YBS) devreye girer. YBS, verileri toplama, saklama, işleme, yeni bilgi üretme, paylaşma ve karar vermeyi destekleme gibi fonksiyonlara sahip sistemler olarak tanımlanabilir. YBS, işletme yöneticilerinin zamanında ve etkili karar almalarını sağlayacak stratejik bilgiler sunar. YBS'nin temel bileşenleri arasında; veri, veri ambarı, bilgi ve veri madenciliği bulunmaktadır. Veri, işlemlerin kaydı olarak tanımlanırken, bilgi işlenmiş ve kullanıcıya anlam ifade eden veri olarak görülebilir. Veri ambarı, karar verme süreçlerinde yöneticilere destek olan, entegre ve zaman odaklı bir veri deposudur. Veri

madenciliği ise, görünürde birbirleriyle ilişkisi olmayan veriler arasındaki bağlantıları bulma ve bu bulguları anlamlı hale getirme sürecidir (Anameriç, 2005).

Karar Destek Sistemleri (KDS), 1960'larda gelişmeye başlayan ve yöneticilere karar verme süreçlerinde yardımcı olan sistemlerdir. Bu sistemler, karar verme sürecinde gerekli olan tüm verileri toplar, düzenler ve analiz eder. Bu özellikleri sayesinde, işletmeler için değerli bilgiler sunarak, belirli alanlardaki trendleri öngörebilen ve insan zekasıyla bütünleşebilen önemli bir araç haline gelmiştir. KDS'nin gelişimi, bilgisayar tabanlı karar verme analizleri üzerine yapılan çalışmalarla başlamış ve zamanla bireysel karar destek sistemleri, grup karar destek sistemleri gibi farklı alt dallara ayrılarak gelişimini sürdürmüştür. Bu sistemler, günümüzde veri analizleri ve analitik çözümleri kapsayacak şekilde evrilmiştir (Hamşioğlu, 2018).

KDS, etkileşimli bilgisayar sistemleri olarak, yarı yapısal ve yapısal olmayan problemlerin çözümünde karar vericilere destek olur. Bu sistemler, kullanıcıların verilere kolayca ulaşmalarını, veriyi özetlemelerini ve analiz etmelerini sağlar. Ayrıca, işletme yöneticilerine istatistiksel analiz yöntemleri, grafikler, modeller ve raporlar sunarak, karar alma süreçlerinde büyük bir yardımcıdır. Bu tanımlar ve açıklamalar ışığında, KDS'nin iş dünyasında stratejik kararlar alma, işletme hedefleriyle uyum sağlama ve fonksiyonel alanlar arasında koordinasyon kurma konusunda kritik bir role sahip olduğu açıktır.

2.4.2 Baskı destek sistemleri entegrasyonu

Karar alma süreçlerinin giderek daha karmaşık ve dağınık hale gelmesiyle, geleneksel tek işlevli veya bireysel kullanıcıya odaklanmış Karar Destek Sistemlerinin (KDS) sunduğu destek, sadece basit hazır raporlardan zenginleştirilmiş ve zeki ajan tabanlı çözümlemelere, önerilere ve değerlendirmelere doğru büyük bir dönüşüm yaşamıştır. Bu dönüşüm, Entegre Karar Destek Sistemlerinin (EKDS) yeni teknolojilerle, iş süreçleriyle ve dinamik iş ortamlarıyla bütünleşerek genişletilip geliştirilmesi sonucunda gerçekleşmiştir. Bu bölümde, EKDS'nin çok katmanlı ve birden fazla açıdan entegrasyonu ele alınmaktadır. Entegrasyon, genellikle yanlış anlaşılan bir kavram olsa da bileşenlerin (modeller, hizmetler, araçlar, yöntemler, alt sistemler gibi) birbirleriyle olan ilişkilerinin bir özelliği olarak geniş çapta kabul görmüştür. Yani, entegrasyon, tekil bir unsura ait bir özellikten ziyade, o unsurun çevresiyle kurduğu ilişkilerin bir sonucudur (Ding et al., 2009; Halfawy et al., 2008).

EKDS bağlamında, entegrasyon, sistem bileşenlerinin birbiriyle ne derece uyum içinde olduğunu ifade eder. Bu uyum, veri formatlarından, fonksiyon paylaşımına, kullanıcı arayüzü standartlarına ve EKDS'nin diğer yapısal unsurlarına kadar uzanabilir. Geleneksel olarak, bir KDS'nin üç temel bileşeni olduğu kabul edilir: veri yönetimi, model yönetimi ve diyalog yönetimi. Bu üçlü, sırasıyla, veri tabanı yönetim sistemleri (DBMS), model tabanı yönetim sistemleri (MBMS) ve karar verme süreçlerinin etkileşimli sorgulama, raporlama ve görselleştirme işlevlerini kolaylaştıran kullanıcı arayüzleri şeklinde temsil edilmektedir (Shim et al., 2002).

Zamanla, bu geleneksel yapı, karar alma ortamlarını ve teknolojik yenilikleri hesaba katan modern EKDS'ye evrilmiştir. Bu modern sistemler, sadece temel bileşenlerin içeriğini zenginleştirmekle kalmamış, aynı zamanda karar verme süreçlerine entegre edilen yeni teknolojileri ve iş çevrelerini de dikkate almıştır. Bu evrim, karar vericiler ile sistemler arasındaki etkileşimin daha açık ve etkili hale gelmesini amaçlamakta ve karar verme süreçlerinin verimliliğini ve etkililiğini artırmayı hedeflemektedir.

Geleneksel veri erişim anlayışı, birden fazla kaynaktan veri ve bilgi alımını mümkün kılan veri ambarlarıyla zenginleştirilerek genişletilmiştir. Bu yüzden, Entegre Karar Destek Sistemleri'nde (EKDS) birden çok kaynak arasında veri ve bilginin entegre edilmesi büyük bir önem taşır. EKDS'de, model bileşeni nicel analiz modelleri üzerinden işletme modellerine (ERP, SCM ve CRM gibi) kadar genişletilmiştir. EKDS içinde model entegrasyonu, nicel analizlerle çözümlenen modellerin yanı sıra kalitatif modelleri de içermelidir. Karar önerileri ve değerlendirmeler sağlamak amacıyla OLAP, veri madenciliği, yapay zeka ve uzman sistemler gibi yeni işlevler eklenmiştir. Bu, işlev ve hizmetlerin birleştirilip paylaşılmasını mümkün kılacak hizmet entegrasyonu konusunu ön plana çıkarır. EKDS, bütün olarak karar vericilere, sistemlerle etkileşimi kolaylaştıracak şekilde düşük bilişsel yük sunmalıdır; bu, sunum entegrasyonu etkili bir biçimde sağlandığında mümkündür. Karar verme süreci, süreç birimleri arasında uygun etkileşim sağlandığında ve süreç birimlerinin kısıtları, koşulları ve amaçları arasındaki uyum korunduğunda daha iyi bir performans gösterebilir. Bu durum, süreçlerin nasıl entegre edileceği sorununu gündeme getirir (Shim et al., 2002).

2.4.2.1 Veri ve bilgi entegrasyonu

Veri ve bilgi entegrasyonunun amacı, bir Karar Destek Sisteminde (KDS) bileşenler tarafından veri ve bilginin nasıl işlendiğine ve dönüştürüldüğüne bakılmaksızın, tutarlı kararlar için tutarlı bilgiler elde etmektir. İlk olarak, veri ve bilgi entegrasyonu, veri ve bilginin farklı şekillerde temsil edilse veya başka veri ve bilgilerden türetilse bile, sistem bileşenlerinin “aynı” veri ve bilgiyi kullanmasını yansıtmalıdır. Yani, iki farklı bileşen arasındaki veri ve bilgi entegrasyonu, birbirinden bağımsız veri ve bilgi ile uğraştıklarında ilgili değildir. İkincisi, Entegre Karar Destek Sistemlerinde (EKDS) veri ve bilgi entegrasyonu, farklı kaynaklardan gelen veri ve bilgilerin kullanımını ele almalıdır (Liu et al., 2008).

Veri ve bilgi entegrasyonunun çeşitli özellikleri literatürde belirlenmiştir. Bunlar arasında veri ve bilgi alışverişi, tutarlılık, tekrarsızlık, birlikte çalışabilirlik ve senkronizasyon bulunur. Her özelliğin ana karakteristikleri özetlenmiştir. KDS için veri ve bilgi entegrasyonu geniş çapta araştırılmış ve raporlanmıştır. Tarım Mühendisliği KOBİ'leri için bilgi entegrasyonuna yönelik bir karar destek metodolojisi geliştirilmiştir. Literatürde genellikle bilgi entegrasyonu konusunda yapılanlar hakkında bilgi verildiği, ancak neden yapıldıkları konusunda yeterince açıklama yapılmadığına dair önemli bir noktaya değinilmiştir. Davenport, şirketlerdeki bilgi entegrasyonunun rekabet avantajlarını nasıl güçlendireceği veya zayıflatacağı, şirket kültürünü nasıl etkileyeceği ve bilgi yönetiminin nasıl uygulanacağı gibi konuları dikkate alması gerektiğini savunur. Çeşitli kaynaklardan gelen verileri entegre eden optimizasyon tabanlı EKDS'nin uygulanması tartışılmıştır. Karar vericilerin farklı bilgi türlerini (hem içsel hem de dışsal) ve çeşitli formlarda mevcut olan verileri birleştirebilmesi için KDS'ye bilgi yönetimi sürecinin entegrasyonunun önemi de tanınmıştır. İnsani yardım ve afet yardımı karar verme desteğinde çoklu bilgi kaynaklarını entegre eden bir bilgi yönetimi çerçevesi sunulmuştur (Cohen, 2021; Zhang et al., 2002).

2.4.2.2 Modellendirme

Modellerin merkezi rolü ve modellerin yönetimi için mekanizmaların sağlanması, bir Karar Destek Sistemi'ni (KDS) daha geleneksel bilgi işlem sistemlerinden ayıran özellikler olarak kabul edilir. Bir model, olası bir kararın etkisini araştırmamıza olanak tanıyan gerçekliğin bilgisayar temsili olarak tanımlanır. Pratikte, bir KDS'nin

uygulama, bakım ve esneklik avantajları için tek büyük bir model yerine birden fazla model oluşturması gerektiği kanıtlanmıştır. Model entegrasyonu, mantıksal olarak birleştirilerek geniş ve birleşik bir model oluşturmak için ayrı ayrı geliştirilmiş alt modellerin entegre edilmesi sürecidir. Entegre modeller, rasyonel karar verme süreçlerini desteklemek için sıklıkla gereklidir (Liu et al., 2010).

Model entegrasyonu üzerine yapılan erken dönem incelemeler, model entegrasyonunun temelini oluşturmuştur. Belirli uyumluluğa sahip iki modelin birleştirilmesini sağlayan projeksiyon ve birleştirme olmak üzere iki işlem tanımlanmış ve uygulanmıştır. Projeksiyon işlemi, daha büyük bir modelden diğer uygulamalarda kullanılmak üzere istenen alt modeli çıkarır. Birleştirme işlemi ise, belirli uyumluluğa sahip iki modeli birleştirir. Çevresel yönetim, ürün geliştirme, pazarlama ve sağlık hizmetleri gibi birçok senaryoda KDS için çoklu model entegrasyonu uygulanmıştır (Zhang et al., 2002).

Farklı veri kümeleriyle farklı problemler için modellerin yeniden kullanımına yönelik birçok entegrasyon çerçevesi önerilmiş olmasına rağmen, çeşitli modeller ve veri kümeleri karşısında problem çözme algoritmalarının, yani çözücülerin yeniden kullanımı aracılığıyla esnek karar verme desteğine odaklanan çalışmalar daha azdır. Model tabanlı sonuçların bir EKDS'ye entegrasyonunun özellikle faydalı olduğu gözlemlenmiştir. Model tabanlı EKDS kullanan yöneticilerde, model tabanlı olmayan yöneticilere kıyasla belirginlik etkileri, aşırı güven ve diğer yanlılıklar azaltılmıştır (Liu et al., 2010).

2.4.2.3 Proses entegrasyonu

Thomas ve Nejme tarafından 1992'de, süreç entegrasyonunu anlamak için üç boyut tanımlanmıştır: süreç birimi, süreç olayı ve süreç kısıtlaması. Süreç birimi, bir sonuç üreten iş birimidir. Süreç olayı, süreç adımı sırasında ortaya çıkan ve ilişkili bir eylemin gerçekleşmesine yol açabilecek bir durumdur. Süreç kısıtlaması, sürecin bazı yönleri üzerinde kısıtlamalar getirir.

Bir Entegre Karar Destek Sistemi (EKDS) içindeki iki bileşenin, sürece ilişkin varsayımları tutarlı olduğunda süreç açısından iyi entegre edildikleri kabul edilir. Süreç adımı entegrasyonu açısından, hedeflerinin süreç adımının tutarlı bir ayrıştırmasının bir parçası olması ve bu hedeflerin gerçekleştirilmesinin diğer bileşenlerin kendi hedeflerine ulaşmalarını sağlaması gerekir. Olay entegrasyonu

aısından, bileşenler olay bildirimlerini tutarlı bir şekilde üretebilir ve işleyebilir (bir bileşen bir olayın meydana geldiğini belirttiğinde, başka bir bileşen o olaya yanıt verir). Bileşenler, tanıdıkları ve saygı gösterdikleri kısıtlamaların aralığı hakkında benzer varsayımlar yaptıklarında kısıtlama entegrasyonu aısından iyi entegre edilmiş sayılırlar (Saridakis & Dentsoras, 2006).

EKDS uygulamaları için süreç entegrasyonuna dair literatür çoğunlukla mühendislik tasarımı ve üretim alanında yoğunlaşmıştır. Liu ve Young (2004) tarafından, müşteri sipariş işlemleri, ürün tasarımı ve imalat süreçlerinin küresel bir üretim ortamında sorunsuz bir şekilde entegre edilebilmesi için bilgi modeli aracılığıyla tutarlı olay bildirimi tartışılmıştır (Liu & Young, 2004). Daha önce Rodgers ve diğerleri tarafından 1999'da sunulan Webcadet sistemi, tasarımcıların tüm tasarım aşamalarında, kavramsal tasarımdan detaylı tasarıma kadar tutarlı tasarım kriterleri ve kısıtlamalarını karar analizi için kullanmalarına olanak tanır. Bu yaklaşımın eksikliği, işbirlikçi karar alma sürecinde tasarım bilgisinin anlaşılması ve yapılandırılması ile ilgilenmemesidir (Rodgers et al., 1999).

Üretim sistemlerinde, karar destek ve operasyonel süreçlerin uygun şekilde entegre edilmesi vurgulanmıştır. Böyle bir entegre üretim sisteminde, planlama ve analiz yeteneklerine sahip bir EKDS, iş kararlarını bilgi tabanlarına yazar ve bunlar daha sonra CAD/CAM/CAPP sistemleri tarafından tasarım kararları almak için kısıtlamalar ve koşullar olarak kullanılır, ardından CNC'ler, robotlar ve üretim atölyesindeki diğer cihazlar tarafından yürütölen süreçleri desteklemek için talimatlar olarak kullanılır. Böylece, iş zekası, şirketin genel hedeflerine ulaşmak için tüm süreç adımlarında rehber olarak tutarlı bir şekilde kullanılır (Zare Mehrjerdi, 2009).

2.4.2.4 Servis ve sunum entegrasyonları

Servis entegrasyonu, entegre bir karar destek ortamında işlevsel kombinasyonların esnekliğini destekleme konusunda kritik bir rol oynar. Her bileşen tarafından sunulan işlevlerin, diğer tüm bileşenlere uygun olduğunda erişilebilir olması ve bileşenlerin, işlevlerini kullanacak bileşenleri önceden bilmelerine gerek kalmaması idealdir. Bu durum, servislerin hem sunulması hem de kullanımı aısından iki önemli bakış aısıyla incelenebilir: Bir yandan bileşenler, ortamdaki diğer bileşenler tarafından talep edilen ve kullanılan hizmetleri sunarken; diğer yandan, bileşenler, ortamdaki diğer bileşenler tarafından sunulan hizmetleri uygun bir şekilde kullanır. Bileşenlerin işlevselliklerini

paylaşabilmeleri için, gerçekleştirilecek işlemleri etkileşimli bir şekilde iletebilmeleri esastır, bu da işlemlerin veri ve bilgi gerektirdiği anlamına gelir; dolayısıyla bileşenler, veri ve bilgiyi veya bunların referanslarını da iletmelidir (Linthicum, 2004).

Bu nedenle, servis entegrasyonu, veri ve bilgi entegrasyonunun doğal bir tamamlayıcısı olarak işlev görür. Veri ve bilgi entegrasyonu, veri ve bilginin nasıl temsil edileceği, dönüştürüleceği ve saklanacağıyla ilgilenirken, servis entegrasyonu kontrol aktarımı ve hizmetlerin nasıl ortaklaşa kullanılacağıyla ilgili konulara odaklanır. Servis entegrasyonu ile model entegrasyonu arasındaki ilişki de önemlidir. Sistemin analiz yeteneklerinin içsel temsili olan modeller, sistemin işlevlerinin temellerini sağlar. Modeller, belirli karar alma durumlarıyla ilişkilendirildiğinde ve karar vericilere (yani EKDS kullanıcılarına) açıklandığında, hizmetlere dönüşürler. Model entegrasyonu ile servis entegrasyonu arasındaki ayrım, sistemin görünümü ve karar alma durumlarıyla olan ilişkisine dayanır. Model entegrasyonu, çeşitli modeller arasındaki uyumluluğa yoğunlaşırken, servis entegrasyonu, sağlayıcı ve kullanıcı perspektiflerinden işlevlerin birleştirilmesine odaklanır. Model entegrasyonu, EKDS kullanıcıları için genellikle görünmezken, EKDS geliştiricilerinin odak noktasında yer alır (Bag et al., 2021).

Sunum entegrasyonunun amacı, kullanıcıların bilişsel yükünü azaltmak ve bireysel bileşenler, alt sistemler ve tüm Entegre Karar Destek Sistemi (EKDS) ortamı için geçerli olmaktır. Bu, görünüm ve davranış entegrasyonunun yanı sıra etkileşim paradigması entegrasyonu aracılığıyla sağlanabilir. Görünüm ve davranış entegrasyonu, kullanıcıların bir bileşenle etkileşim kurarken öğrendiklerini başka bir bileşenle etkileşime geçirirken ne kadar kolaylık yaşadıklarını, bileşen ekran görünüşü ve etkileşim davranışlarının benzerliklerini ele alarak sorar. Bileşenler, bir kullanıcının biriyle olan deneyimlerinin ve beklentilerinin diğerlerine uygulanabildiği görünüm ve davranış entegrasyonu açısından iyi entegre edilmiş olarak kabul edilir (Liu et al., 2010).

Ayrıca, etkileşim paradigması, farklı bileşenlerin öğrenme ve kullanım engellemesini en aza indirmek için benzer metaforlar ve zihinsel modelleri ne ölçüde kullandığını ele alır. Bu anlamda, iyi entegre edilmiş bir EKDS, aynı metaforları ve zihinsel modelleri kullanmalıdır. Açıktır ki, bir EKDS bir metafor ile birçok metaforun kullanımı arasında bir denge kurmalıdır. Tek bir metafor bazı durumlar için uygunsuz veya kötü uyumlu olabilir, ancak çok fazla metafor, bileşenler arasında deneyim aktarımını

zorlaştırabilir. Örneğin, kullanıcılar iki farklı navigasyon metaforu kullanan iki bileşeni kullanmaları gerektiğinde kafa karışıklığı yaşayabilirler. Bu nedenle, sunum entegrasyonu açısından, EKDS kullanıcıları ile sistemler arasındaki etkileşimi kolaylaştırmak amacıyla ortak bir görünüm ve hissiyat sunan bir kullanıcı arayüzünün sağlanması büyük önem taşır (Lam et al., 2004; Linthicum, 2004).

2.5 Tekliflendirme Süreçlerinde Karar Destek Sistemleri

Birçok işletme, iş stratejilerini, müşteri ihtiyaçlarına özgü çeşitlilik gösterebilen ve mühendislikten siparişe yöntemiyle sunulan ürün konseptleri üzerine inşa etmektedir. Bu tür ürün konseptleri, işletmeler arası pazarda sıkça rastlanır ve basit bileşenlerden karmaşık ürünlere kadar geniş bir yelpazeyi kapsar. Bu ürünleri temin eden firmalar, genellikle birden fazla teklif hazırlama sürecine dahil olur ve rekabetçi fiyatlarla, kısa ürün teslimat süreleri sunarken aynı zamanda firma karlılığını korumak adına tasarım otomasyonunu hayata geçirmek zorundadırlar. Bu, ürün konseptinin süreç odaklı bir bakış açısıyla ele alınmasını ve mühendislik bilgisi (örneğin, mekanik tasarım, üretim mühendisliği, maliyet mühendisliği) içeren varyant tasarımlar için bir ürün platformunun tanımlanmasını içerir (Goodwin et al., 2002).

Ürün tasarımı, süreç planlama ve maliyet tahmininin sistem içinde entegre edilerek otomatize edilmesi, az çaba ile kısa zamanda tasarım önerileri üretmeyi mümkün kılar. Çeşitli ürün varyantlarının değerlendirilmesi, ürün ve tekliflerin teslim süresinin kısaltılmasına olanak tanırken, tutarlı tasarım hesaplamalarını da sağlar. Otomasyon için uygun bir alan olan teklif hazırlama, ürün tasarımının temel prensiplerini, süreç planlamayı ve maliyet tahminini kapsar. Teklif sürecine tasarım otomasyonu entegrasyonunun sağlayacağı faydalar göz ardı edilemez. Ancak, bu entegrasyonun nasıl başarılabacağı konusu daha karmaşık soruları beraberinde getirir. Bu çalışmanın temeli ve amacı, belirlenen endüstriyel sorunlara ve ihtiyaçlara dayanarak şekillenmiş bir araştırma projesinden kaynaklanmaktadır (Elgh, 2012).

2.6 Dinamik Fiyatlandırma

Dinamik fiyatlandırma, işletmelerin veri yönetimine dayalı bir yaklaşım olarak, üretimden pazarlama stratejilerine kadar geniş bir etki alanına sahiptir. Bu yaklaşım, piyasa dinamikleri ve yönetsel ihtiyaçlar doğrultusunda esneklik göstererek,

iřletmelerin d nemsel gelirlerini maksimize etmelerine ve rakip stratejilere  evik tepkiler geliřtirmelerine imkan tanır .  retim s re lerindeki yeniliklerin yanı sıra, arz ve talebin y netilmesinde fiyatlandırma y ntemleri stratejik bir  nem tařır. İřletmeler, m mk n olan en d ř k envanter maliyetiyle maksimum karlılıđı hedeflerken, talebin dođru zaman ve řekilde karřılanmasını ama lar. Literat rde, iřletmelerin kar marjlarını etkileyen sorunlardan birinin, envanter y netimi ile fiyatlandırma stratejilerinin koordinasyonsuz ele alınması olduđuna dikkat  ekilir. Bu iki stratejinin entegre edilmemesi, arz-talep dengesizliđine ve iřletme performansında d ř řlere sebep olabilir. Arz ve talebin dengelenmesi, envanter ve fiyatlandırma stratejilerinin uyumlu, esnek ve birbirlerini tamamlayıcı řekilde tasarlanmasına bađlıdır (Avunduk & K   yılmaz, 2020).

Dinamik fiyatlandırma, sabit fiyatlandırmanın aksine,  r n veya hizmet fiyatlandırmasında piyasa taleplerine dinamik bir řekilde uyum sađlar.  zellikle internet tabanlı ticaret yapan iřletmeler, piyasa taleplerine zamanında yanıt vermek i in bu stratejiden faydalanır. Dinamik fiyatlandırma, dođru kapasitenin uygun m řteriye ve zamana tahsis edilmesinde, veri y netim sistemlerinin ve stratejik fiyatlandırma uygulamalarının birleřtirilmesi anlamına gelir. Bu yaklařım, iřletmelerin piyasa kořullarına hızla adapte olmalarını sađlayarak, rekabet avantajı elde etmelerine yardımcı olur (Zhang, 2013).

2.6.1 Dinamik fiyatlandırma stratejileri ve modelleri

Fiyat belirleme yaklařımlarında yařanan yenilik,  r nlerin tanıtım ve satıř y ntemlerini k kten deđiřtirmeye y nelik b y k bir potansiyel sunmaktadır. G n m zde, satıcılar kiřisel m řteri teklifleri sunarak ve en uygun anı belirleyip dođru m řteriye  zel fiyatlar teklif ederek pazarlama stratejilerini geliřtirmeye odaklanmıřtır. Bu evrimin arkasında, internet ve  eřitli dijital ađlar vasıtasıyla ekonominin dijitalleřmesi gibi fakt rler bulunmaktadır. M řteriler artık  r nleri ve fiyatları hızla karřılařtırabilme avantajına sahip olup, bu da onlara daha iyi pazarlık yapma g c  vermektedir. Aynı zamanda, teknolojinin sađladıđı olanaklar sayesinde satıcılar, m řterilerin satın alma davranıřları ve tercihleri hakkında kapsamlı veriler toplayarak, tekliflerini kiřiselleřtirebilmektedir. Eskiden, fiyat deđiřiklikleriyle iliřkili y ksek men  maliyetleri, fiyat g ncellemelerinin t keticilere ulařmasını uzun s reler alabilirdi. Ancak ađ teknolojisinin geliřimi bu s re ve maliyetleri minimize etmiřtir.

Elektronik ticarete alıcı ve satıcıların etkileşimi sonucu oluşan dinamik fiyatlar, piyasa değerlerinin daha gerçekçi bir şekilde yansıtılmasını sağlamaktadır. Kısacası, e-ticaret alanında meydana gelen iki temel gelişme, sabit fiyat uygulamalarından dinamik fiyatlandırmaya geçişte kritik bir rol oynamıştır: (1) İşlem maliyetlerindeki azalma, zaman ve mekan kısıtlamalarının ortadan kalkması, arama maliyetlerinin düşmesi ve fiyat güncellemelerinin daha kolay yapılabilmesi gibi etmenlerle desteklenmiştir. (2) Artan piyasa dinamikleri ve talep dalgalanmaları, daha geniş bir müşteri kitlesi, artan rekabet ve bilgi bolluğu gibi sonuçlar doğurmuştur. Dinamik fiyatlandırma, fiyat belirsizliğini artırırken, işletmeler bu değişken internet pazarında sabit fiyat stratejilerinin yetersiz kaldığını gözlemlemiştir (Bichler et al., 2002).

Dinamik fiyatlandırma, tüketicilerin bir ürün veya hizmete atfettikleri değere dayalı olarak fiyatların sürekli ayarlanması sürecidir. Bu yaklaşım, literatürde esnek fiyatlandırma ve kişiselleştirilmiş fiyatlandırma gibi çeşitli adlar altında ele alınmıştır (Narahari et al., 2005). Dinamik fiyatlandırmanın iki temel bileşeni vardır: (1) fiyat çeşitliliği ve (2) fiyat farklılaştırması. Fiyat çeşitliliği, mekânsal veya zamansal olabilir. Mekânsal fiyat çeşitliliğinde, farklı satıcılar aynı ürünü farklı fiyatlarla sunar. Zamansal fiyat çeşitliliğinde ise, bir mağaza belirli bir ürün için zaman içinde, satış zamanına ve arz-talep durumuna göre fiyatı değiştirir. Dinamik fiyatlandırmanın diğer önemli bileşeni olan fiyat farklılaştırması veya fiyat ayrımcılığı ise, aynı ürün için farklı tüketicilere farklı fiyatların uygulanmasıdır. Burada üç tür fiyat ayrımcılığı mevcuttur:

- Birinci derece ayrımcılık: Burada, üretici farklı ürün birimlerini farklı fiyatlarla satarken, bu fiyatlar bireyden bireye değişiklik gösterebilir. Her bir ürün birimi, onu en yüksek değerlendiren kişiye, bu kişinin ödemeye razı olduğu en yüksek fiyattan satılır. Üretici, her müşterinin maksimum ödeme istekliliğini belirleyebilirse, pazardaki tüm tüketici fazlasını elde edebilir.
- İkinci derece ayrımcılık: Aynı zamanda doğrusal olmayan fiyatlandırma olarak da bilinen bu yöntemde, üretici farklı ürün birimlerini farklı fiyatlarla satar, ancak aynı miktarda ürünü satın alan her birey aynı tutarı öder. Bu, satın alınan ürün miktarına bağlı olarak fiyatların değiştiği, ancak satın alan kişiye göre değişmediği anlamına gelir.
- Üçüncü derece ayrımcılık: Üretici, ürünleri farklı insanlara farklı fiyatlarla satar, ancak bir kişiye satılan her ürün birimi için aynı fiyat uygulanır. Fiyat

farklılaştırması, tüketicilerin değerlendirmelerindeki farklılıklardan yararlanarak gerçekleştirilir. (Varian, 1996)

Elmaghraby ve Keskinocak'a göre, dinamik fiyatlandırma yöntemleri iki ana kategoriye ayrılır: Sabit fiyat mekanizmaları ve fiyat keşif mekanizmaları. Sabit fiyat mekanizmalarında, ürün veya hizmet belirlenen bir fiyattan satılırken, fiyat keşif mekanizmalarında fiyatlar bir teklif süreci ile belirlenir. Bu çalışmada, dinamik fiyatlandırma terimini geniş bir kapsamda ele alıyoruz; bu, tüketicilere yönelik fiyatların dinamik bir şekilde ayarlanmasını, farklı fiyatlandırmayı, fiyat çeşitliliğini, dinamik sabit fiyatları ve fiyat keşfini içerecektir (Elmaghraby & Keskinocak, 2003).

2.6.1.1 Stok odaklı modeller

Perakende sektöründe, stok durumlarına dayalı dinamik fiyatlandırma üzerine yapılan araştırmalar dikkate değer bir ilgi görmüştür. Bu alanda yapılan ilk çalışmalar arasında Varian ve Salop ile Stiglitz'in öncü çalışmaları bulunmakta, Elmaghraby ve Keskinocak, Swann ve Chan, Shen, Simchi-Levi ile Swann ise stokları optimal fiyat belirlemede esas alınan geleneksel perakende pazarları modelleri üzerine kapsamlı bir literatür incelemesi sunmuşlardır. Bu bulguların büyük bir kısmı, çoğu perakendecinin elektronik ticarete adım atması sayesinde e-ticaret pazarları için de geçerlidir (Narahari et al., 2005).

Elmaghraby ve Keskinocak, perakendecinin karşı karşıya kaldığı dinamik fiyatlandırma problemi türünü etkileyen üç ana pazar özelliğini belirlemişlerdir:

- Stok yenilenmesinin olup olmaması (R/NR): Belirlenen zaman diliminde, satıcının sabit bir stok miktarına dayalı fiyat kararları verip vermeyeceği veya stokun talebi karşılamak üzere zamanla yenilenebileceği.
- Talebin zamanla bağımlı mı bağımsız mı olduğu: Müşterilerin bir ürüne olan talebi zaman içinde değişebilir.
- Müşterilerin miyop mu yoksa stratejik mi olduğu (M/S): Müşterilerin satın alma davranışları, satıcının zaman içindeki kararlarını etkiler. Miyop müşteriler, fiyatı değerlemelerinin altında olduğunda satın alma yaparken, stratejik müşteriler satın alma kararlarında gelecekteki fiyat değişimlerini hesaba katarlar. (Elmaghraby & Keskinocak, 2003)

Bu yazarlar, mevcut pazarların çoğunun üç kategori altında sınıflandırılabileceğini öne sürmüşlerdir: NRIM (stok yenilenmesi yok–bağımsız talepler–miyop müşteriler),

NRIS (stok yenilenmesi yok–bağımsız talepler–stratejik müşteriler) ve RIM (stok yenilenmesi var–bağımsız talepler–miyop müşteriler). NRIM durumu genellikle moda giyim veya tatil ürünleri için geçerliken, RIM durumu gıda maddeleri, taze ürünler ve ilaç gibi ürünlerde görülür. NRIS durumu ise tipik olarak işletmeler arası tedarik süreçlerinde karşımıza çıkar.

Gallego ve van Ryzin, belirli bir zaman ufku boyunca stokastik talebe dayalı envanterlerin optimal dinamik fiyatlandırmasını incelemişlerdir. Yaptıkları varsayımlar şunlardır: (1) Pazar monopolistiktir, (2) satış süresi sınırlıdır, (3) mağaza sınırlı sayıda stokla başlar ve satış süresi boyunca yeniden stok yapılmaz, (4) talep fiyatla ters orantılıdır ve (5) satılmayan ürünlerin bir hurda değeri vardır. Talebi, p fiyatında $\lambda(p)$ yoğunluğu ile bir Poisson süreci olarak modelleyerek, firma zaman t 'de p_t fiyatını belirleyerek talebin yoğunluğunu kontrol eder. Uygun varsayımlar altında, daha fazla stok ve/veya satış için kalan süre arttıkça beklenen gelirlerin arttığını; belirli bir zamanda, envanter arttıkça optimal fiyatın azaldığını; tersine, belirli bir envanter seviyesi için, daha fazla satış süresi olduğunda optimal fiyatın yükseldiğini göstermişlerdir. Türetilen optimal fiyatlandırma politikaları, zamanla fiyatların sürekli güncellenmesini önermektedir, ancak bu her zaman pratik olmayabilir. Yazarlar, daha sabit fiyatlarla çalışan ve fiyatların izin verilen belirli bir fiyat setinden seçilmesi gerektiği durumlar için sezgisel fiyatlandırma politikalarını araştırmışlardır. Bu araştırmalar, dinamik fiyatlandırma stratejilerinin ve modellerinin, özellikle stok odaklı modellerin, perakende ve e-ticaret pazarları için nasıl uygulanabileceğine dair değerli içgörüler sunmaktadır (Gallego & Van Ryzin, 1994).

2.6.1.2 Veri odaklı modeller

E-ticaret platformları aracılığıyla elde edilen müşteri verilerinin varlığı, gelir artırıcı stratejiler için yeni kapılar aralamıştır. Amazon.com, yahoo.com gibi e-ticaret siteleri ve önde gelen üretim ve hizmet şirketlerinin özel pazar yerleri, müşteriler hakkında geniş veri havuzları biriktirir ve bu verileri gelirlerini ve kârlılıklarını artırmak için kullanabilirler. Bu bağlamda, müşteri verilerini en iyi şekilde kullanmak üzere gelişmiş veri madenciliği algoritmaları üzerinde çalışılmaktadır. Raghavan tarafından bu özel sayıda sunulan veri madenciliği yaklaşımları üzerine yapılan inceleme bu konuya ışık tutmaktadır. Müşteri verileri ve veri madenciliği algoritmalarının

bulunurluđu, dinamik fiyatlandırma gibi alanlarda önemli bir etkiye sahiptir (Raghavan & Hafez, 2000).

Bu örneklerden ilki, geleneksel olarak müşteri verilerine dayanan gelir veya verim yönetimidir. Havayolu ve konaklama sektörleri bu teknikleri başarıyla benimsemiştir. Boyd ve Bilegan, merkezi rezervasyon ve gelir optimizasyon sistemleri tarafından etkinleştirilen dinamik, otomatik satışların başarılı bir e-ticaret modelini örneklendiren gelir yönetimi tekniklerini incelemiştir (Boyd & Bilegan, 2003).

Morris ve arkadaşları, havayolu sektöründeki dinamik fiyatlandırma yaklaşımlarını, müşteri tercihlerindeki örüntüleri analiz ederek araştırmışlardır. Sunulan iki yenilikçi satıcı fiyatlandırma stratejisi, Java tabanlı pazar simülasyon aracı Arena ile test edilmiştir. Bu simülasyon, artış gösteren, azalan ve sabit kalmış müşteri talepleri altında rezervasyon fiyatlandırma stratejisi ile koltuk açma stratejisini baz alınan durumla kıyaslamıştır. Bulgular, simülasyonda belirlenen rezervasyon fiyatlarının, satılan koltuk sayısına göre ayarlanmasının, talebi etkin bir şekilde takip ettiğini ve gelirleri başlangıç durumuna kıyasla artırdığını ortaya koymuştur. Öte yandan, talep düzeyine göre ayarlanan koltuk açma stratejisi, havayolu tekliflerinde gelir artışı sağlamada etkisiz kalmıştır (Narahari et al., 2005).

Dalgalanma gösteren müşteri taleplerine karşı hem rezervasyon fiyatını hem de günlük serbest bırakılan koltuk sayısını daha doğru ayarlayarak gelir optimizasyonuna ulaşmayı amaçlayan yeni stratejilerin simülasyonu gerçekleştirilmiştir. Ford Motor Şirketi, müşterilerin ekstra ücret ödemeye istekli oldukları özellikleri belirleyerek, tüketicileri daha pahalı araçları tercih etmeye yönlendiren bir fiyatlandırma stratejisi geliştirmiş ve bu sayede gelir ve karlarında belirgin bir yükseliş sağlamıştır. Rusmevichientong, Salisbury, Tuuss, Van Roy ve Glynn, General Motors'un Auto Choice Adviser web sitesi üzerinden toplanan tüketici tercihleri verilerini kullanarak, gelirleri maksimize edecek dinamik fiyatları bulan bir veriye dayalı yaklaşım geliştirmişlerdir. Web sitesinden alınan verilerle, yazarlar gelir optimizasyonu problemi oluşturmuşlar ve problem NP-zor olarak belirlenmiştir. Yazarlar, amaç fonksiyonunun süper-modüler olduğu durumlar için etkili bir sezgisel çözüm yöntemi geliştirmişlerdir. General Motors, otomobiller için gelirleri maksimize edecek dinamik fiyatlamaları belirlemek amacıyla Auto Choice Adviser web sitesinden toplanan verileri kullanacakları bir modeli uygulamaya almaya hazırdır (Narahari et al., 2005).

2.6.1.3 Açık arttırmaya dayalı modeller

Açık artırmalar, dinamik fiyatlandırma için doğal bir model oluşturur. Bir açık artırmanın sonucu, arz-talep özelliklerine bağlı olarak belirlenir ve dolayısıyla, açık artırımla belirlenen fiyatlar, teklif verenler gerçek değerlemelerini açıkladığı sürece, gerçek piyasa koşullarına dayalı olabilir. Açık artırma mekanizmaları, gerçek değerleri açıklama özellikleri ile tasarlanabilir ve açık artırmalar teorisi, dinamik fiyatlandırma alanına büyük katkılar sunabilir. Açık artırmalar, yüksek oranda Pareto etkinliği sağlar ve dengeye hızlı bir şekilde yakınsar (Bichler et al., 2002). Bu özellikler, büyük şirketlerin, gelirlerinin önemli bir kısmına bağlı oldukları tedarikçilerden doğrudan veya dolaylı malzemeler satın aldığı bir ortamda oldukça cazip olacaktır. Açık artırmalar, fiyat müzakerelerinin uygulanmasında şu anda muhtemelen en popüler mekanizmadır.

2.6.1.4 Makine öğrenmesine dayalı modeller

Makine öğrenimi, e-ticaret alanındaki dinamik fiyatlandırma süreçlerine yenilikçi bir yaklaşım sunarak, bu alanda giderek daha fazla tercih edilen bir modelleme aracı haline gelmiştir. Piyasa koşullarının anlık olarak değişkenlik gösterdiği, talep ve arzın sürekli dalgalanma içinde olduğu modern pazar ortamlarında, sistemlerin gelecekteki tüm gelişmelerini öngörmek neredeyse imkansızdır. Ayrıca, bir satıcının elindeki bilgiler kısıtlıdır; örneğin, rakiplerin fiyatlandırma stratejileri hakkında eksiksiz bilgilere erişimi olmayabilir. Öğrenme tabanlı modeller sayesinde, eldeki tüm verileri değerlendirerek fiyatlandırma stratejisini mevcut piyasa koşullarına en uygun şekilde adapte etmek mümkün hale gelir. Dinamik fiyatlandırma için veri odaklı yaklaşımlar, dinamik fiyatları tespit etmek üzere makine öğrenimi tekniklerinden faydalanabilir. Bu konsept üzerine odaklanan literatür, hem tekil öğrenen ajan modellerini hem de birden fazla öğrenen ajanın etkileşimini inceleyen modellere ayrılmıştır, bu da dinamik fiyatlandırmanın farklı yönlerini ve karmaşıklıklarını aydınlatmaktadır (Narahari et al., 2005).

2.6.1.5 Tekli öğrenme aracılı modeller

Brooks ve arkadaşlarının çalışmasında, elektronik ürünler için tek satıcılı pazarlarda iki farklı fiyatlandırma stratejisinin (her ikisi de makine öğrenimine dayalı) performansı karşılaştırılmaktadır. İlk strateji, tek parametrelili bir fiyatlandırma modeli kullanırken, ikincisi iki parametrelili bir fiyatlandırma modeli kullanmaktadır. İki

parametrelili öğrenmeye dayalı dinamik fiyatlandırma stratejisinin, tek parametrelili öğrenmeye dayalı olanı açıkça geride bıraktığı gösterilmiştir. Çalışma, kısmi bilgi ile bir model için optimal fiyatların belirlenmesine yönelik analitik yöntemler türetmektedir. Simülasyonlar, satıcının müşteri değerlemeleri konusunda belirsiz olduğu ve optimal fiyatları kademeli olarak öğrendiği dinamik bir modeli incelemek için kullanılmıştır (Brooks et al., 1999).

Gupta, Ravikumar ve Kumar, teklif verenlerin geliş modeli ve bireysel fiyat-talep eğrileri hakkındaki belirsizliklerin olduğu bir durumda, toplam beklenen geliri maksimize etmek amacıyla bir fiyat azaltma dizisi bulma problemi olan, web tabanlı çok birimli bir Hollanda açık artırmasını ele almışlardır. Bu karar problemi, belirsiz, durağan olmayan bir açık artırma ortamında tek bir ajanın pekiştirmeli öğrenme (RL) olarak modellenmiştir. Bağımsız teklif veren değerlendirmeleri varsayımı altında, yazarlar, iskonto edilmemiş getirilerle sonlu ufuklu bir Markov karar süreci modeli geliştirmiş ve bunu bir Q-öğrenme algoritması kullanarak çözmüşlerdir (Bag et al., 2021).

Carvalho ve Puterman, talep fonksiyonu bilindiğinde durumun basit bir stokastik maksimizasyon problemine indirgendiği, ancak talep fonksiyonu bilinmediğinde, perakendecinin fiyatlandırma kararlarını yönlendirmek için belirsiz öncül bilgilere güvenmek zorunda kaldığı, bir malın fiyatını belirleyerek toplam beklenen geliri optimize etmeye çalışan bir perakendecinin problemi ele alınmıştır. Bu çalışmada, parametreleri bilinmeyen parametrik bir model ele alınmıştır. Örneğin, satışın t günü sonrasında, bir satıcı önceki $t-1$ günlerde belirlediği fiyatları bilmekte ve önceki $t-1$ günlerdeki talepleri gözlemleyebilmektedir. Model, talebin fiyatın doğrusal bir fonksiyonu olduğu basit bir log-lineer regresyon modelidir. Satıcı, talep fonksiyonunun parametreleri hakkında bilgi edinebilir ve belirli bir zaman ufku boyunca gelirleri maksimize etmek için fiyatları belirleyebilir. Çeşitli fiyatlandırma kuralları incelenmiş ve karşılaştırılmıştır. Tek satıcılı ortamda incelenen bir adım ileriye bakma kuralının oldukça sağlam performans gösterdiği gösterilmiştir (Carvalho & Puterman, 2003).

Leloup ve Deveaux, bir web mağazası ele alarak Rothschild'in (1974) dinamik fiyatlandırma modelini web mağazasının fiyatlandırma problemine uygulamışlardır. Simülasyonlar kullanılarak, tüm satıcıların belirli bir pazarda optimal fiyatlandırma politikasını takip ettiğinde ortaya çıkabilecek fiyat dinamikleri incelenmiştir (Leloup

& Deveaux, 2001). Raju, Narahari ve Ravikumar, rekabetin olmadığı elektronik perakende pazarlarına bakmıştır. Satıcı, standart bir envanter politikasına göre yenilenen ürünlerin envanterine sahiptir. Sistemdeki öğrenen ajan satıcıdır ve ortamdan öğrenmek için pekiştirmeli öğrenme kullanır. Sorun, satıcının performans metriğini (uzun vadeli iskontolu kâr veya birim zaman başına uzun dönem ortalama kâr) optimize eden dinamik fiyatları belirlemektir. Müşterilerin geliş süreci, müşteri değerlemeleri, envanter yenileme politikası ve yenileme kurşun zamanı dağılımı hakkında (makul) varsayımlar altında, sistem bir Markov karar süreci haline gelir, bu da RL algoritmalarının kullanılmasını sağlar. Sorunu çözmek için Q-öğrenme algoritması kullanılmıştır. Model ve çözüm metodolojisi, envanter politikasının takip ettiği optimal yeniden sipariş miktarını ve optimal yeniden sipariş noktasını hesaplamak için de kullanılabilir (Narahari et al., 2005).

2.6.1.6 Çoklu öğrenme aracılı modeller

Makine öğreniminin, e-ticarete dinamik fiyatlandırma için kritik bir araç haline gelmesiyle, birden fazla öğrenen ajanı içeren modellerin önemi artmıştır. Ravikumar, Saluja ve Batra'nın çalışması, iki satıcının, bilgili ve bilgisiz olmak üzere iki tür alıcıya hizmet etmek için rekabet ettiği bir servis pazar ortamını incelemektedir. Her iki satıcı da RL-tabanlı uyumlu davranışı benimsemiş ve genel toplam bir Markov oyunu olarak sistemi modellemiştir. Aktör-eleştirmen tipi bir RL düzeni öneren bu çalışma, yakınsama üzerine deney sonuçları sunmaktadır (Sundar & Ravikumar, 2003).

Hu'nun çalışması, simüle edilmiş bir pazarda üç farklı fiyatlandırma algoritması (veya fiyatlandırma ajanı) üzerine odaklanır. İlk ajan, aldığı geri bildirimlere dayanarak optimal bir eylem öğrenirken, ikinci ajan Q-değerleri üzerine öğrenerek uzun vadeli optimal değerleri keşfeder. Üçüncü ajan, Nash dengesi değerlerini temsil eden Q-değerleri hakkında bilgi edinerek daha sofistike bir Nash Q-öğrenme algoritması kullanır. Bu üçüncü ajan, diğerlerinden daha üstün performans sergileyerek, gelecekteki ödülleri ve diğer ajanların varlığını dikkate alan öğrenme yöntemlerinin etkinliğini kanıtlar (Hu & Zhang, 2002).

Greenwald, Kephart ve Tesuaro, her bir satıcının fiyat belirleme stratejisi kullanan bir fiyatbot tarafından yönetildiği çok satıcılı bir ortamda stratejik fiyatbot dinamiklerini inceler. Dört farklı fiyat belirleme stratejisi – oyun teorik fiyatlandırma, myoptimal fiyatlandırma, türevi takip etme ve Q-öğrenme – bilgi ve hesaplama gereksinimleri

açısından karşılaştırılmıştır. Homojen ayarlarda, türevi takip etme yaklaşımı diğerlerinden üstün bulunmuşken, heterojen fiyatbotlarının bulunduğu bir pazarda, Q-öğrenme stratejisi en iyi performansı göstermiştir (Greenwald et al., 1999).

Kephart ve Tesauro, iki identik, rekabetçi fiyatbotun stratejik olarak bir ürün fiyatlandırıdığı model bir pazarda çoklu ajan Q-öğrenmesinin yönlerini araştırır. İki temelde farklı çözüm gözlemlenmiş; biri tam, durağan ve sıfır Bellman hatası içeren simetrik politikalar, diğeri ise pseudo-yakınsak, asimetrik ve küçük fakat sıfır olmayan Bellman hatası içeren bir çözümdür (Kephart & Tesauro, 2000).

Dasgupta ve Das, alıcıların shopbot ve satıcıların fiyatbot kullandığı, çoklu satıcı ve alıcıdan oluşan çok ajanlı bir ekonomide fiyat dinamiklerini inceler. Dinamik fiyatlandırma için geliştirilen bir öğrenme tabanlı model optimizatör algoritması, basit bir türevi takip algoritmasından daha üstün performans sergiler, bu da makine öğreniminin rekabet veya işbirliği teşvik edilmesinde ve gelir maksimizasyonunda önemli bir rol oynayabileceğini gösterir (Dasgupta & Das, 2000).

2.6.2 Dinamik fiyatlandırmanın avantajları ve zorlukları

Rekabet bazlı fiyatlandırma stratejisinin tercih edilmesinin birçok avantajı bulunmakla birlikte, bu yöntemin öne çıkan faydalarından bazıları özellikle dikkat çekicidir. İlk olarak, bu yaklaşımın uygulanış kolaylığı şirketler için büyük bir avantaj sağlar. Rakiplerin kamuoyuna açıklanan fiyatları kolayca takip edilebilir ve benzer ürünler sunulduğunda, bu fiyatlandırma stratejisini benimsemek, diğer stratejilere göre daha az maliyetli ve zaman alıcıdır. Bu, şirketlerin pazar araştırması ve fiyat optimizasyonu için harcanan kaynakları azaltmalarına olanak tanır (Vidrova et al., 2019).

Ayrıca, rekabet bazlı fiyatlandırma düşük risk taşır. Rakiplerin belirlediği fiyatlar piyasa tarafından zaten kabul görmüş ve test edilmiş olduğundan, benzer ürünler sunan diğer şirketler bu fiyatları güvenle kullanabilir. Bu yöntem, bir ürünün fiyatını belirlerken karşılaşılabilecek belirsizlikleri azaltır (Fisher et al., 2018).

Rekabet bazlı fiyatlandırma, aynı zamanda piyasada bir denge fiyatının oluşumuna katkıda bulunur. Çoğu perakende satıcının bu yöntemi kullanması durumunda, pazar genelinde stabil bir fiyat seviyesine ulaşılabilir. Bu, tüketiciler için fiyatların şeffaflığını artırır ve pazarın genel sağlığı açısından olumlu bir etki yaratır (Aalto, 2019).

Dinamik fiyatlandırma stratejisi, fiyat hassasiyetine sahip müşterileri tatmin eder. Araştırmalar, tüketicilerin satın alma kararlarında fiyatın önemli bir faktör olduğunu göstermektedir. Rekabetçi bir fiyatlandırma stratejisi kullanmak, müşterilerin fiyat karşılaştırmaları yapmasını kolaylaştırır ve bu da müşteri memnuniyetini ve sadakatini artırabilir. Bu strateji, şirketlerin pazarda rekabet edebilirliğini sürdürmelerine ve uzun vadede büyümelerine olanak tanır. Rekabet bazlı fiyatlandırma stratejisinin kullanılabilmesinin mümkün olduğu durumlar, farklı firmalar tarafından aynı müşterilere satılan ürünlerin büyük ölçüde aynı olmasıyla sınırlıdır. Bunun aksine, ürünler sadece kısmen benzer ve tam olarak aynı değilse, bir üründen diğerine fiyatın aktarılması zordur. Bu nedenle, işletmeler, rakipleri tanımlama, ürünler arasında uygunluk kurma ve veri toplama ile analiz etme gibi birçok zorlukla karşı karşıya kalır (Popescu & Wu, 2007).

Rakiplerin tanımlanması, fiyat analizi yapabilmek için bir şirketin öncelikle kimlerle rekabet ettiğini bilmesi gerektiği anlamına gelir. Sorun şu ki, rekabet çeşitli biçimler alabilir- çevrimiçi bir perakendeci ile çevrimdışı bir perakendeci bazı durumlarda rakip olabilir, ancak diğerlerinde olmayabilir. Örneğin, çevrimiçi ve çevrimdışı kitap satıcılarının aynı müşterilere hizmet verdikleri için rakip oldukları söylenebilir. Ancak, çevrimiçi ve çevrimdışı gıda satıcıları hedef pazarları tam olarak aynı olmadığı için gerçekten rakip olarak görülemez. Bu nedenle, rekabetçi bir fiyat belirleyebilmek için bir firma ilgili rakiplerini dikkatlice tanımlamalıdır.

Ürünlerin uygunluğunun tanımlanması, klasik ekonomiye göre, iki ürün bir tüketicinin bir ürün miktarını diğer bir ürünün miktarıyla değiştirebildiği ve ürün faydasında herhangi bir kayıp yaşamadığı durumda uygun olarak kabul edilir. Ancak, rakiplerinin ürünleriyle kıyaslandığında uygunluğu tanımlamak zor bir görev olabilir. Örneğin, son Apple iPhone ile son Samsung Galaxy'nin uygun olup olmadığı sorusu zor bir sorudur. Uygunluğun tanımlanması, rekabetçi fiyatlandırmanın karmaşık bir parçasıdır.

Uygun ürünler ve rekabet tanımlandıktan sonra, bir sonraki adım ilgili fiyatlandırma verilerini toplamaktır. Çoğu rakibin fiyatları İnternet'te gösterilir. Bir şirket, fiyat takip yazılımlarını da kullanabilir. Fiyat bilgisi elde etme sıklığının iyi tanımlanması gerekmektedir çünkü bu, bir iş sektöründen diğerine büyük ölçüde değişiklik gösterir.

Çizelge 2.1: Literatür taraması.

Çalışma (Yazar, Yıl)	Konusu	Amacı	Yöntem	Uygulama Var mı?
Aalto, H. (2019)	E-ticarette Rekabet Bazlı Dinamik Fiyatlandırma	E-ticaret ortamlarında rekabet bazlı dinamik fiyatlandırmanın etkinliğini analiz etmek	Kavramsal analiz ve kantitatif modelleme	Evet
Anameriç, H. (2005)	Yönetim Bilgi Sistemlerinin Yönetim Fonksiyonları Üzerine Etkisi	Yönetim bilgi sistemlerinin yönetim fonksiyonları üzerindeki etkisini incelemek	Kavramsal inceleme	Hayır
Asadi, R., Kareem, S. A., Asadi, M. ve Asadi, S. (2017)	Verimsiz Kümeleme için Denetimsiz İleri Beslemeli Sinir Ağı Yöntemi	Verimsiz kümelemeyi etkin bir şekilde gerçekleştirmek için denetimsiz bir yöntem önermek	Denetimsiz öğrenme ve sinir ağları	Evet
Atalay, M. ve Çelik, E. (2017)	Büyük Veri Analizinde Yapay Zeka ve Makine Öğrenmesi Uygulamaları	Büyük veri analizinde AI ve makine öğrenmesi tekniklerinin uygulamalarını araştırmak	Literatür incelemesi ve vaka analizi	Evet
Avunduk, H. ve Küçükyılmaz, S. (2020)	Dinamik Fiyatlandırma Stratejisi	Dinamik fiyatlandırma stratejilerinin avantajlarını ve uygulama alanlarını incelemek	Kavramsal inceleme	Hayır
Bag, S., Gupta, S., Kumar, A. ve Sivarajah, U. (2021)	B2B Pazarlamada Bilgi Oluşumu ve Karar Verme için Yapay Zeka Çerçevesi	B2B pazarlamada bilgi oluşturma ve rasyonel karar verme süreçlerini iyileştirmek için yapay zeka tabanlı bir çerçeve geliştirmek.	Kavramsal analiz, vaka çalışması	Evet
Bhatt, G. D. ve Zaveri, J. (2002)	Örgütsel Öğrenmede Karar Destek Sistemlerinin Etkin Rolü	Karar destek sistemlerinin örgütsel öğrenme süreçleri üzerindeki etkisini ve katkısını analiz etmek.	Literatür incelemesi, teorik çerçeve	Hayır
Bichler, M. et al. (2002)	B2B Elektronik Ticarete Esnek Fiyatlandırma Uygulamaları	B2B elektronik ticarete esnek fiyatlandırma stratejilerinin çeşitli uygulamalarını ve etkilerini incelemek.	Vaka analizi, modelleme	Evet
Boyd, E. A. ve Bilegan, I. C. (2003)	E-Ticaret ve Gelir Yönetimi	E-ticaret ortamlarında gelir yönetimi stratejilerinin uygulanması ve etkilerini incelemek.	Kantitatif analiz, modelleme	Evet
Brooks, C. H., Fay, S., Das, R., MacKie-Mason, J. K., Kephart, J. O. ve Durfee, E. H. (1999)	Elektronik Mal Pazarında Otomatik Strateji Aramaları	Elektronik ürün pazarlarında fiyatlandırma ve pazarlama stratejilerinin otomasyonu üzerine bir inceleme.	Simülasyon, deney	Evet
Carvalho, A. X. ve Puterman, M. L. (2003)	Dinamik Fiyatlandırma ve Güçlendirme Öğrenimi	Dinamik fiyatlandırma stratejileri ve güçlendirme öğreniminin birleştirilmesi yoluyla firmaların performansını artırmayı incelemek.	Modelleme, simülasyon	Evet
Cohen, S. (2021)	Makine Öğreniminin Temelleri: Stratejiler ve Teknikler	Makine öğreniminin temel prensip ve tekniklerini sunmak ve uygulama alanlarını tartışmak.	Teorik inceleme, literatür incelemesi	Hayır
Dasgupta, P. ve Das, R. (2000)	Sınırlı Rakip Bilgisi ile Dinamik Fiyatlandırma	Çoklu ajan ekonomilerinde sınırlı rakip bilgisi olan ortamlarda dinamik fiyatlandırma stratejilerini incelemek. KOBİ'lerin uluslararasılaşma, dijitalleşme ve sürdürülebilirlik konularında ne kadar hazır olduğunu ve bu üç büyüme yolunun birbiriyle nasıl etkileşime girdiğini araştırmak.	Teorik modelleme, analiz	Hayır
Denicolai, S., Zucchella, A. ve Magnani, G. (2021)	Uluslararasılaşma, Dijitalleşme ve Sürdürülebilirlik: KOBİ'ler Hazır mı?		Anket, istatistiksel analiz	Hayır
Dike, H. U., Zhou, Y., Deveerasetty, K. K. ve Wu, Q. (2018)	Yapay Sinir Ağlarına Dayalı Denetimsiz Öğrenme: Bir İnceleme	Yapay sinir ağları kullanılarak denetimsiz öğrenme yöntemlerinin gözden geçirilmesi ve değerlendirilmesi.	Literatür incelemesi	Hayır

Çizelge 2.1 (devam): Literatür taraması.

Çalışma (Yazar, Yıl)	Konusu	Amacı	Yöntem	Uygulama Var mı?
Ding, L., Davies, D. ve McMahon, C. A. (2009)	İşbirlikçi Tasarım Temsili için Hafif Temsil ve Anotasyon Entegrasyonu	Mühendislik tasarımında işbirlikçi çalışmayı kolaylaştırmak için hafif temsil ve anotasyon yöntemlerinin entegrasyonunu incelemek.	Vaka çalışması, prototip geliştirme	Evet
Elgh, F. (2012)	Mühendislik Ürünleri İçin Teklif Sürecinde Karar Destek	Mühendislik ürünlerinin özelleştirilmiş sipariş süreçlerinde teklif oluşturma aşamasında karar destek sistemlerinin kullanımını analiz etmek.	Vaka çalışması, simülasyon	Evet
Elmaghraby, W. ve Keskinocak, P. (2003)	Envanter Dikkate Alındığında Dinamik Fiyatlandırma	Envanter düşüncelerinin dinamik fiyatlandırma stratejileri üzerindeki etkilerini incelemek ve bu alandaki uygulamaları ve gelecek yönelimleri tartışmak.	Literatür incelemesi, teorik çerçeve	Hayır
Faulin, J., Juan, A. A., Grasman, S. E. ve Fry, M. J. (2012)	Hizmet Endüstrilerinde Karar Verme: Pratik Bir Yaklaşım	Hizmet sektörlerinde karar verme süreçlerini desteklemek için pratik yöntem ve araçlar sunmak.	Kavramsal analiz, vaka çalışması	Evet
Fisher, M., Gallino, S. ve Li, J. (2018)	Online Perakendecilikte Rekabet Bazlı Dinamik Fiyatlandırma	Online perakendecilikte rekabet bazlı dinamik fiyatlandırma stratejilerinin etkinliğini alan deneyleri ile doğrulamak.	Alan deneyi, veri analizi	Evet
Gallego, G. ve Van Ryzin, G. (1994)	Stokastik Talep Altında Envanterlerin Optimal Dinamik Fiyatlandırması	Belirsiz talep altında envanterler için optimal dinamik fiyatlandırma stratejilerini geliştirmek ve analiz etmek.	Matematiksel modelleme, optimizasyon	Hayır
Goodwin, R., Akkiraju, R. ve Wu, F. (2002)	Teklif Oluşturma için Bir Karar Destek Sistemi	Teklif oluşturma süreçlerinde karar verme süreçlerini desteklemek için bir karar destek sistemi geliştirmek.	Sistem tasarımı, prototip geliştirme	Evet
Greenwald, A. R., Kephart, J. O. ve Tesaro, G. J. (1999)	Stratejik Fiyat Bot Dinamikleri	Elektronik ticaret ortamlarında fiyat belirleme stratejilerinin ve fiyat botlarının dinamiklerini incelemek.	Oyun teorisi, simülasyon	Hayır
Gupta, J. N., Forgionne, G. A. ve Mora, M. (2007)	Akıllı Karar Destek Sistemleri: Temeller, Uygulamalar ve Zorluklar	Akıllı karar destek sistemlerinin temelini, uygulama alanlarını ve karşılaşılan zorlukları incelemek.	Literatür incelemesi, teorik çerçeve	Hayır
Halfawy, M. R., Dridi, L. ve Baker, S. (2008)	Kanal Ağları Yenileme Planlaması için Entegre Karar Destek Sistemi	Kanal ağlarının yenilenmesi için optimal planlama yapılmasını destekleyen entegre bir karar destek sistemi geliştirmek.	Modelleme, optimizasyon	Evet
Hamşioğlu, D. P. (2018)	Bilgi Teknolojisi Tabanlı Kararlar ve Grup Karar Destek Sistemleri Uygulaması	Grup karar destek sistemlerinin ve bilgi teknolojisinin karar verme süreçleri üzerindeki etkilerini ve avantajlarını incelemek.	Kavramsal analiz, anket	Evet
Hess, T. J., Rees, L. P. ve Rakes, T. R. (2000)	Otonom Yazılım Ajanlarını Kullanarak Karar Destek Sistemlerinin Yeni Neslini Oluşturmak	Otonom yazılım ajanlarının karar destek sistemlerinde kullanımını ve bunların getirebileceği yenilikleri incelemek.	Teorik çerçeve, vaka çalışması	Evet
Hu, J. ve Zhang, Y. (2002)	Çok Ajanlı Sistemlerde Çevrimiçi Güçlendirme Öğrenimi	Çok ajanlı sistemlerde çevrimiçi güçlendirme öğrenimi yöntemlerinin uygulanabilirliğini ve etkilerini incelemek.	Modelleme, simülasyon	Evet
Javaid, M., Haleem, A., Singh, R. P., & Suman, R. (2022)	Mühendislik Ürünleri İçin Teklif Sürecinde Karar Destek	Mühendislik ürünlerinin özelleştirilmiş sipariş süreçlerinde teklif oluşturma aşamasında karar destek sistemlerinin kullanımını analiz etmek.	Vaka çalışması, simülasyon	Evet
Johnson, E. D. (1973)	Endüstri 4.0 için yapay zeka uygulamaları: Literatür tabanlı bir çalışma	Endüstri 4.0 bağlamında yapay zekanın uygulamalarını ve etkilerini incelemek	Literatür incelemesi	Hayır

Çizelge 2.1 (devam): Literatür taraması.

Çalışma (Yazar, Yıl)	Konusu	Amacı	Yöntem	Uygulama Var mı?
Kephart, J. O., & Tesauro, G. (2000)	Yazma, baskı, kitaplar ve kütüphanelerin tarihine giriş	İletişim araçlarının tarihsel gelişimini tartışmak	Tarihsel analiz	Hayır
Kwon, K. S., Rahman, M. K., Phung, T. H., Hoath, S. D., Jeong, S., & Kim, J. S. (2020)	Rekabetçi fiyat botları tarafından sözde yakınsak Q-öğrenme	Rekabetçi pazarlarda fiyat botlarının Q-öğrenme dinamiklerini keşfetmek	Simülasyon çalışması	Evet
Lam, D., Leon, L., Hamilton, S., Crookshank, N., Bonin, D., & Swayne, D. (2004)	Elektronik malzemeler için dijital baskı teknolojileri incelemesi	Elektronik malzemeler için dijital baskı teknolojilerinin güncel durumunu ve ilerlemelerini gözden geçirmek	Teknik inceleme	Evet
Learning, S. S. (2006)	Yarı-Gözetimli Öğrenme	Yarı-gözetimli öğrenme konseptlerini ve metodolojilerini incelemek	Literatür incelemesi ve teorik analiz	Hayır
Lee, K. W. ve Huh, S. Y. (2006)	Otonom ve akıllı model çözümleri için model-çözücü entegrasyon çerçevesi	Otonom sistemler için model-çözücü entegrasyonunu tasarlamak ve değerlendirmek	Sistem tasarımı ve simülasyon	Evet
Leloup, B. ve Deveaux, L. (2001)	İnternet üzerinde dinamik fiyatlandırma: Teori ve simülasyonlar	İnternet tabanlı dinamik fiyatlandırma stratejilerinin etkinliğini ve teorilerini analiz etmek	Kavramsal analiz ve simülasyon	Hayır
Linthicum, D. S. (2004)	Basit Bilgiden Web Hizmetlerine Sonraki Nesil Uygulama Entegrasyonu	Uygulama entegrasyonu teknolojilerinin gelişimini ve gelecekteki yönlerini incelemek	Kavramsal inceleme ve literatür araştırması	Hayır
Liu, S., Duffy, A. H., Whitfield, R. I. ve Boyle, I. M. (2010)	Karar destek sistemlerinin entegrasyonu ile karar destek performansını iyileştirmek	Karar destek sistemlerinin etkinliğini artırmak için farklı sistemlerin entegrasyon stratejilerini değerlendirmek	Vaka çalışması ve kantitatif analiz	Evet
Liu, S., McMahon, C. A. ve Culley, S. J. (2008)	Mühendislik doküman yönetiminde bilgi erişim performansını iyileştirmek için yapılandırılmış doküman alma (SDR) teknolojisinin incelemesi	Mühendislik doküman yönetiminde bilgi erişim performansını iyileştirmeye yönelik teknolojileri değerlendirmek	Literatür incelemesi ve teknik analiz	Evet
Liu, S. ve Young, R. I. (2004)	Küresel üretim koordinasyon kararlarını desteklemek için bilgi ve bilgi modellerini kullanma	Küresel üretimde karar verme süreçlerini desteklemek için bilgi sistemlerini entegre etmek	Kavramsal inceleme ve vaka çalışması	Evet
McCulloch, W. S. ve Pitts, W. (1943)	Sinirsel aktivitede yer alan fikirlerin mantıksal hesaplaması	Sinir ağlarının matematiksel modellenmesini sağlayan bir hesaplama modeli geliştirmek	Literatür incelemesi ve kavramsal analiz	Hayır
Narahari, Y., Raju, C., Ravikumar, K. ve Shah, S. (2005)	Elektronik iş için dinamik fiyatlandırma modelleri	Elektronik iş ortamlarında dinamik fiyatlandırmanın modellenmesi ve analizi	Kavramsal analiz ve modelleme	Evet
Nasiri, S., Khosravani, M. R. ve Weinberg, K. (2017)	Yapay zeka yöntemleri ile kırılma mekaniği ve mekanik hata tespiti: Bir inceleme	Kırılma mekaniği ve arıza tespitinde yapay zekanın rolünü incelemek	Literatür incelemesi	Evet
Nasteski, V. (2017)	Gözetimli makine öğrenme yöntemlerine genel bir bakış	Gözetimli makine öğrenme algoritmalarını ve kullanım alanlarını incelemek	Literatür incelemesi ve kavramsal analiz	Hayır
Popescu, I. ve Wu, Y. (2007)	Referans etkileri ile dinamik fiyatlandırma stratejileri	Referans fiyat etkilerinin fiyatlandırma stratejilerine etkisini analiz etmek	Kantitatif analiz ve modelleme	Evet
Prim, A. G. H. (2006)	Yapay zeka	Yapay zeka kavramlarına genel bir giriş sağlamak	Kavramsal inceleme	Hayır

Çizelge 2.1 (devam): Literatür taraması.

Çalışma (Yazar, Yıl)	Konusu	Amacı	Yöntem	Uygulama Var mı?
Raghavan, V. ve Hafez, A. (2000)	Dinamik veri madenciliği	Endüstriyel, mühendislik ve diğer uygulamalı akıllı sistemlerde dinamik veri madenciliği yaklaşımlarını incelemek	Uygulamalı araştırma	Evet
Rathee, G., Garg, S., Kaddoum, G. ve Choi, B. J. (2020)	Akıllı endüstrilerde IoT cihazlarını güvenli hale getirmek için karar verme modeli	Akıllı endüstrilerde IoT cihazlarının güvenliğini sağlamak için karar verme modellerini geliştirmek	Modelleme ve uygulamalı analiz	Evet
Rodgers, P. A., Huxor, A. P. ve Caldwell, N. H. (1999)	Dağıtık Web tabanlı AI araçları kullanarak tasarım desteği	Web tabanlı AI araçlarıyla dağıtık tasarım desteğini incelemek	Vaka çalışması ve uygulamalı araştırma	Evet
Tunçel, O. (2019)	Dijital çağda baskı teknolojileri	Dijital baskı teknolojilerinin sanat ve tasarım üzerindeki etkisini incelemek	Literatür incelemesi ve analiz	Hayır
Turgut, A., Temir, A., Aksoy, B. & Özsoy, K. (2019)	Yapay zeka yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması	Yapay zeka kullanarak hava sıcaklığı tahmini yapabilen bir sistem geliştirmek	Deneysel tasarım ve uygulama	Evet
Tyler, D. J. (2005)	Tekstil dijital baskı teknolojileri	Tekstil endüstrisinde dijital baskı teknolojilerinin gelişimini incelemek	Teknik inceleme ve literatür araştırması	Hayır
Uçar, T. F. (2004)	Görsel İletişim ve Grafik Tasarım	Görsel iletişim ve grafik tasarımın temellerini ve önemini açıklamak	Kavramsal inceleme	Hayır
Van Der Meer, M., Kurth-Nelson, Z. & Redish, A. D. (2012)	Karar verme sistemlerinde bilgi işleme	Karar verme sistemlerinde bilgi işleme mekanizmalarını incelemek	Bilimsel inceleme ve analiz	Hayır
Varian, H. R. (1996)	Farklılaştırılmış fiyatlandırma ve verimlilik	Farklılaştırılmış fiyatlandırmanın ekonomik etkilerini ve verimlilik konularını incelemek	Ekonomik analiz ve teorik inceleme	Hayır
Vidrova, Z., et al. (2019)	Rekabetçi fiyatlandırma stratejilerinin avantajları ve sınırları	Rekabetçi fiyatlandırma stratejilerinin kullanımındaki avantajları, sınırları ve sorunları incelemek	Kavramsal inceleme, vaka analizi	Hayır
Yusof, Y., et al. (2017)	Yapay zekâ ile hava sıcaklığı tahmini	Yapay zekâ yöntemlerini kullanarak hava sıcaklığı tahmini yapabilen bir sistem geliştirmek	Deneysel tasarım, simülasyon	Evet
Zare Mehrjerdi, Y. (2009)	Esnek üretim sistemleri için karar verme modeli	Esnek üretim sistemlerinde karar verme süreçlerini optimize etmek için bir model geliştirmek	Modelleme, optimizasyon	Hayır
Zhang, D., et al. (2002)	İnsani yardım/afet yardımında karar destek için bilgi yönetimi çerçevesi	İnsani yardım ve afet yardımında karar verme süreçlerini desteklemek için bilgi yönetimi çerçevesini geliştirmek	Kavramsal inceleme, vaka analizi	Hayır
Zhang, R. (2013)	Stokastik talep altında fiyatlandırma ve envanter yönetimi	Stokastik talep koşullarında ortak fiyatlandırma ve envanter yönetimi stratejilerini incelemek	Kavramsal analiz, kantitatif modelleme	Hayır

2.7 Literatür İncelemesi Sonuç


Çizelge 2.1’de özetlenen literatür incelemesi, baskı endüstrisinin teknolojik entegrasyonu ve dijitalleşme süreçlerini kapsayan geniş bir aralıktaki çalışmaları ele almaktadır. Bu çalışmalar, endüstrideki operasyonel verimliliği artırma, müşteri ihtiyaçlarına daha hızlı yanıt verme ve maliyet optimizasyonu gibi konulara odaklanmaktadır. Özellikle, otomatize tekliflendirme ve cihaz yönetimi gibi alanlarda teknolojik yeniliklerin uygulanmasının potansiyel faydaları üzerine yoğunlaşmıştır.

Araştırmalar, sektördeki iş akışlarını iyileştirmenin ve müşteriye özel çözümler sunmanın önemini vurgulamakla birlikte, sektöre özel detaylı çözüm önerileri sunma konusunda genellikle yetersiz kalmaktadır. Bu nedenle, baskı endüstrisine yönelik özelleştirilmiş, detaylı ve uygulamalı çözümlere duyulan ihtiyaç açıkça ortadadır.

Bu bağlamda, mevcut literatürdeki boşlukları dikkate alan ve baskı endüstrisinin özgün ihtiyaçlarına odaklanan detaylı araştırmaların değeri ön plana çıkmaktadır. Sektörün özel dinamiklerini ve ihtiyaçlarını anlayarak, bu alana özel yenilikçi çözümler geliştiren çalışmalar, baskı endüstrisindeki firmalara önemli rekabet avantajları sağlayabilir. Bu tür araştırmalar, sektörün dijital dönüşüm sürecine katkıda bulunarak, operasyonel verimliliği artırma, maliyetleri düşürme ve pazarda rekabet edebilirliği güçlendirme gibi önemli faydalar sunabilir.

Sonuç olarak, baskı endüstrisinin teknolojik entegrasyonu ve dijital dönüşümü üzerine yapılan araştırmalar, genel teknolojik yeniliklerin ötesinde, sektöre özgü uygulamaları ve çözümleri detaylandıran çalışmalara ihtiyaç duymaktadır. Bu tür detaylı ve uygulamaya yönelik çalışmalar, baskı endüstrisindeki firmaların karşılaştıkları zorlukları aşmalarına ve sektördeki değişimlere uyum sağlamalarına yardımcı olabilir. Bu nedenle, baskı endüstrisine yönelik araştırmalarda, sektörün özgün ihtiyaçlarını ve teknolojik yeniliklerin pratik uygulamalarını merkeze alan bir yaklaşımın benimsenmesi gerekmektedir.

3. METODOLOJİ



Şekil 3.1: Metodoloji akış şeması.

3.1 Veri Toplama

Şekil 3.1’de detaylandırılan metodolojinin akışı ilk olarak veri toplama ile başlamaktadır. Araştırma kapsamında, sektör özelinde hizmet veren firmaların CRM sistemlerinden elde edilen veriler; müşterilerin firma bilgileri, baskı hacimleri ve tercih ettikleri modeller gibi önemli bilgileri içermektedir. Bu veriler, müşteri tabanının derinlemesine anlaşılmasını ve pazarın talep yapısının detaylı bir şekilde incelenmesini sağlamaktadır. Satış raporları, ürünlerin satış performansını, bölgesel satış dağılımları ve satış trendlerini ortaya koymakta, bu da pazarın ve müşteri taleplerinin dinamiklerini anlamada kritik bir rol oynamaktadır.

Toplanan verilerin işlenmesi ve analizi aşamasında, veri seti üzerinde veri ön işleme ve temizleme uygulamaları gerçekleştirilmiş ve analize uygun hale getirilmiştir. Böylelikle sonraki aşamalarda yapılacak olan analizlerin doğruluğu ve güvenilirliği artırılmıştır.

3.2 Veri Analizi

Çalışmanın ikinci aşaması olan veri analizi, modelde kullanılacak girdilerin belirlenmesi noktasına odaklanmaktadır. Çizelge 3.1’de modelde kullanılacak ve analizi gerçekleştirilecek değişkenler listelenmiştir. Bağımlı değişken olarak belirlenen makine modeli üzerinde etkili olan faktörlerin, yani bağımsız değişkenlerin, katkı ve önem derecelerini anlamak amacıyla ilk adımda Chi-squared Automatic Interaction Detection (CHAID) analizi kullanılmıştır.

Çizelge 3.1: Veri değişkenleri ve açıklamaları.

Değişkenler	Değişken Türü	Açıklama
MFP	Bağımsız Değişken	Çok fonksiyonlu yazıcı özelliği
Paper Size	Bağımsız Değişken	Kâğıt boyutu
Print Type	Bağımsız Değişken	Baskı tipi
Number of Worker	Bağımsız Değişken	Çalışan sayısı
Sector	Bağımsız Değişken	Şirketin faaliyet gösterdiği sektör
Volume	Bağımsız Değişken	Ortalama baskı hacmi
Model	Bağımlı Değişken	Makine Modeli

CHAID, veri setlerini homojen alt gruplara bölerek, her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini ve bu etkiler arasındaki etkileşimleri ortaya çıkaran bir istatistiksel yöntemdir. Bu analiz, veri setindeki karmaşık yapıları ve ilişkileri belirlemek için kullanılır ve özellikle piyasa araştırması, müşteri segmentasyonu, tıbbi araştırmalar ve sosyal bilimlerde yaygın olarak tercih edilir.

CHAID algoritması, veri setini bir dizi karar kuralı uygulayarak, bağımlı değişkenin kategorilerini en iyi şekilde ayırt eden bağımsız değişkenler temelinde dallara ve düğümlere ayırır. Her bir dal veya düğüm, Ki-kare istatistiğini kullanarak en iyi ayrımı yapacak şekilde seçilir. Bu işlem, önceden tanımlanmış bir maksimum derinlik seviyesine veya minimum gözlem sayısına ulaşıncaya kadar devam eder.

CHAID analizinin bir özelliği, nominal veya ordinal ölçekli verilerle çalışabilmesi ve veri setindeki eksik değerlerle etkili bir şekilde başa çıkabilmesidir. Ağaç yapısı, kolay anlaşılabilir ve görsel olarak ifade edilebilir raporlar sağlar ve bu da karar verme sürecinde faydalı olabilir.

Analizin bir parçası olarak, aşağıdaki adımlar gerçekleştirilir:

Homojenlik Testi: Her bir bağımsız değişkenin kategorileri, bağımlı değişkenin kategorileri arasındaki farklılıkları belirlemek için Ki-kare testi ile analiz edilir.

Ağaç Oluşturma: İstatistiksel olarak en anlamlı bağımsız değişken, ilk dal veya düğüm olarak seçilir ve veri seti, bu değişkenin kategorileri temelinde bölünür.

Dallanma ve Budama: Her yeni alt grup, aynı işlemle daha fazla bölünmeye devam eder. Dallar, maksimum derinliğe veya minimum gözlem sayısına ulaşana kadar oluşturulur. Budama işlemi ile aşırı dallanma ve modelin aşırı öğrenme (overfitting) riski kontrol altına alınır.

Araştırma kapsamında makine modeli üzerindeki çeşitli faktörlerin etkilerini anlamak ve bu etkiler arasındaki ilişkileri saptamak amacıyla ilk adımda toplanan müşteri verilerinin kapsamlı bir veri analizi gerçekleştirilmiştir.

Veri analizinin ikinci adımında ise Rastgele Orman yöntemi, CHAID tarafından belirlenen önemli özelliklerin model performansına katkısını değerlendirmek amacıyla kullanılmıştır. Bu yöntem, modelin her bir özelliğin tahmin yapma sürecine ne kadar katkıda bulunduğunu belirleyerek, modelin performansını artırmak için tercih edilmiştir.

CHAID ve Rastgele Orman yöntemlerinin birlikte kullanılması, model performansını iyileştirmek ve modelin iç işleyişini daha iyi anlamak için güçlü bir yaklaşımdır. CHAID, veri setindeki bağımsız değişkenler arasındaki etkileşimleri belirleyerek hangi özelliklerin daha önemli olduğunu gösterir. Rastgele Orman ise bu özelliklerin model performansına katkısını değerlendirerek modelin genelleme yeteneğini artırır. Bu iki yöntemin birlikte kullanılması, modelin daha doğru ve güvenilir tahminler yapmasını sağlar.

Rastgele Orman, makine öğrenimi ve veri madenciliği alanlarında kullanılan güçlü bir algoritmadır. Bir dizi karar ağacını kullanarak sınıflandırma ve regresyon görevlerini yerine getirir. Bu modelin önemli bir özelliği, her bir değişkenin modeldeki önemini belirleyebilmesidir. Özellik önem sıralaması, modelin karar verme sürecinde hangi özelliklerin daha belirleyici olduğunu gösterir ve modelin performansını artırmak için kullanılır.

Rastgele Orman modelinde deęişken önem sıralamasını belirlemek için en yaygın kullanılan yöntem, Gini Importance veya dięer adıyla Mean Decrease in Impurity yöntemidir. Bu yöntem, her bir özelliğın modelin doęruluęunu artırma derecesini ölçer.

Gini Safsızlıęı (Gini Impurity): Karar ağalarında safsızlık ölçütü olarak yaygın olarak kullanılan bir ölçüttür. Gini safsızlıęı, bir düęümdeki örneklerin heterojenlięini (eşitlilięini) ölçer. Eęer tüm örnekler aynı sınıfa aitse, safsızlık sıfır olur; eęer örnekler eşit dağılıyorsa, safsızlık maksimum olur.

$$Gini(D) = 1 - \sum_{i=1}^n p_i^2 \quad (3.1)$$

D, düęümdeki veri setini, n , sınıf sayısını, ve p_i i 'inci sınıfa ait örneklerin oranını temsil eder.

Her bir düęümde, veri seti belirli bir özellik kullanılarak iki alt kümeye bölünür. Bu bölünme, düęümdeki safsızlıęı azaltır. Her bölünme için, bölünmeden önceki ve sonraki safsızlık hesaplanır. İki alt kümenin ağırlıklı safsızlıklarının toplamı, toplam safsızlıęı verir:

$$Gini_{split} = \frac{N_{left}}{N} Gini(D_{left}) + \frac{N_{right}}{N} Gini(D_{right}) \quad (3.2)$$

N , toplam örnek sayısını, N_{left} ve N_{right} sırasıyla sol ve saę alt kümelerdeki örnek sayısını ve $Gini(D_{left})$ ve $Gini(D_{right})$ sırasıyla sol ve saę alt kümelerdeki Gini safsızlıęını temsil eder.

Her bir karar ağacının her bir düęümünde, bir özellik kullanılarak safsızlık azaltılır. Bu azalma, o özelliğın safsızlık azaltma kapasitesini gösterir. Rastgele Orman modelinde, her bir özellik için tüm ağalarda gerçekleşen safsızlık azalmaları toplanır ve bu deęer, o özelliğın önem skoru olarak kullanılır:

$$Importance(X_j) = \frac{1}{T} \sum_{t=1}^T (Gini_{parent} - Gini_{split}) \quad (3.3)$$

T , toplam ağa sayısını, X_j j 'inci özellięi, $Gini_{parent}$ bölünmeden önceki düęümün Gini safsızlıęını ve $Gini_{split}$ bölünmeden sonraki düęümün Gini safsızlıęını temsil eder.

Özellik önem skorları hesaplandıktan sonra, bu skorlar kullanılarak özellikler sıralanır. Daha yüksek önem skoruna sahip özellikler, modelin tahmin performansında daha belirleyici rol oynar.

Özellik önem sıralaması, modelin performansını artırmak için kullanılabilir. Daha yüksek önem skoruna sahip özellikler, modelin eğitimi sırasında daha fazla dikkate alınabilir. Gereksiz veya düşük önem skoruna sahip özellikler çıkarılarak modelin sadeliği ve hızı artırılabilir. Özellik önem sıralaması, yeni özellikler oluşturmak veya mevcut özellikleri birleştirmek için kullanılabilir.

Sonuç olarak, Rastgele Orman modelinin özellik önem sıralaması analizi, modelin performansını anlamak ve iyileştirmek için kritik bir araçtır. Bu analiz, modelin karar verme sürecinde hangi özelliklerin daha belirleyici olduğunu gösterir ve bu bilgiyi model performansını artırmak için kullanır. Özellik önem sıralaması, modelin güvenilirliğini ve yorumlanabilirliğini artırarak, pratik uygulamalarda daha etkili ve güvenilir tahminler yapılmasını sağlar.

3.3 Makine Öğrenmesi ve Karar Destek Sisteminin Oluşturulması

Gerçekleştirilen çalışmada makine modeli belirleme süreci makine öğrenimi yaklaşımı kullanılarak gerçekleştirilmiştir.

3.3.1 Makine öğrenmesi modeli

Çalışma kapsamında makine öğrenmesi algoritmaları tahmin doğruluğunu en üst düzeye çıkartmak adına değerlendirilmiş olup modelin verimliliğini maksimize edecek algoritmanın tercih edilmesi hedeflenmiştir. Bu kapsamda aşağıda özetlenen 5 farklı makine öğrenmesi algoritması değerlendirilmiştir;

1. Karar Ağaçları (Decision Trees), gözetimli öğrenme algoritmalarından biri olarak hem sınıflandırma hem de regresyon görevlerinde kullanılır. Bu modeller, veri setlerini basamaklı karar düğümleriyle böler ve sonuçları bir ağaç yapısı şeklinde görselleştirir (Quinlan, 1986). Her düğüm, bir özneliğin değerini kontrol eder ve bir alt kümeye ayırır, yaprak düğümler ise son tahmin veya sınıfı temsil eder (Breiman, Friedman, Olshen, & Stone, 1984). Karar ağaçlarının ana avantajlarından biri, oluşturdukları modelin kolay anlaşılabilir olması ve az veri ön işleme ihtiyacı duymasındır (Rokach & Maimon, 2005). Ancak, karar ağaçları aşırı öğrenme (overfitting) yapmaya

meyllidirler; bu yüzden genellikle budama teknikleri uygulanır veya daha dayanaklı model olan Rastgele Ormanlar tercih edilir (Hastie, Tibshirani, & Friedman, 2009). Ayrıca, çok boyutlu veri kümelerinde performansları düşebilir, çünkü her karar düğümü yalnızca bir özelliğe odaklanır (James, Witten, Hastie, & Tibshirani, 2013).

2. Rastgele Ormanlar (Random Forests), birçok karar ağacının bir araya gelerek oluşturduğu ve gözetimli öğrenme çerçevesinde sınıflandırma ve regresyon görevlerinde kullanılan bir modeldir. Bu yöntem, birbirinden bağımsız karar ağaçlarını rastgele seçilmiş veri alt kümeleri üzerinde eğitir ve bu ağaçların çıktılarını birleştirerek nihai tahmini oluşturur (Breiman, 2001). Rastgele Ormanlar, karar ağaçlarının aşırı öğrenme (overfitting) sorununu azaltırken, modelin doğruluğunu ve dayanıklılığını artırır (Liaw & Wiener, 2002). Her bir karar ağacı bağımsız olarak ve rastgele seçilmiş özellikler kullanılarak eğitildiğinden, modelin çeşitliliği artar ve bu da genel performansı iyileştirir (Dietterich, 2000). Çalışmalarda, Rastgele Orman algoritmasının, yüksek boyutlu veri kümelerinde dahi etkili olduğu ve özellikle çok değişkenli veri setlerinde güçlü sonuçlar verdiği gözlemlenmiştir (Cutler et al., 2007). Ayrıca, bu model önemli özellikleri belirleme konusunda da bilgilendirici olabilir, çünkü her özelliğin model tahminine katkısını değerlendirebilir (Strobl et al., 2007).
3. Lojistik Regresyon, sınıflandırma problemleri için kullanılan ve çıktı olarak olasılıklar veren gözetimli bir öğrenme algoritmasıdır. Bu model, bağımsız değişkenlerin doğrusal bir kombinasyonunu kullanarak sonuçların olasılığını hesaplar ve bu olasılıkları belirli bir sınıfa dönüştürmek için bir eşik değeri kullanır (Hosmer, Lemeshow, & Sturdivant, 2013). Özellikle ikili sınıflandırma görevlerinde, yani çıktının iki olası değeri olduğu durumlarda tercih edilir (Walker & Duncan, 1967). Lojistik regresyon, özellikler ile sonuç arasındaki ilişkiyi anlamak ve tahminler yapmak için sağlam ve etkili bir yöntemdir (Menard, 2002). Ayrıca, modelin çıktıları, değişkenlerin sonuç üzerindeki etkilerini yorumlamayı kolaylaştırdığı için tıp ve sosyal bilimler gibi alanlarda yaygın olarak kullanılır (Peng, Lee, & Ingersoll, 2002).
4. Destek Vektör Makineleri (SVM), veri noktalarını optimum bir hiperdüzlem kullanarak sınıflara ayıran güçlü bir gözetimli öğrenme modelidir (Cortes &

Vapnik, 1995). SVM, sınıflar arasındaki marjı maksimize ederek çalışır, bu sayede yeni örnekler üzerindeki genelleme performansı artar (Boser, Guyon, & Vapnik, 1992). Model, doğrusal olmayan ilişkileri modellemek için çekirdek hilelerini (kernel tricks) kullanır, bu da onu karmaşık veri kümelerinde etkili kılar (Schölkopf, Burges, & Smola, 1999). SVM, metin ve resim sınıflandırma gibi yüksek boyutlu veri kümelerinde özellikle etkilidir (Joachims, 1998).

5. K-En Yakın Komşu (KNN) algoritması, bir örneğin sınıfını belirlemek için, en yakın komşularının sınıflarına bakar (Cover & Hart, 1967). Bu yöntem, belirlenen k sayısı kadar en yakın komşunun çoğunluk oyu ile sınıflandırma yapar. Basit ve etkili olan KNN, tembellik esasına dayanan bir yöntemdir; yani model eğitimi süreci yoktur, sorgu noktasının sınıfı, veri setindeki mevcut noktalar arasından hesaplanarak belirlenir. Bu, KNN'i özellikle veri setleri büyük olduğunda hesaplama açısından maliyetli hale getirebilir (Weinberger et al., 2006). Ayrıca, KNN algoritması, veri normalizasyonu ve uygun mesafe ölçüsünün seçimi gibi ön işlemlere duyarlıdır, bu da modelin performansını doğrudan etkiler (Altman, 1992).

3.3.2 Model girdi katmanı

Karar Destek Sisteminin temelini oluşturan girdi katmanı, baskı çoğaltma endüstrisindeki firmalar için özelleştirilmiş tekliflendirme arayüzünün veri toplama ve işleme süreçlerini yönetir. Bu bölümde, belirlenen makine öğrenmesi modelinden sonra sistemin girdi katmanında kullanılan ana parametreler ve bunların işleniş şekli detaylandırılmıştır.

Girdi katmanında kullanılan ana parametreler aşağıda listelenmiştir;

- Çalışan Sayısı: Firmanın çalışan sayısı, tekliflendirme sürecinde cihaz kapasitesi ve fiyatlandırma stratejilerini etkiler. Daha fazla çalışanı olan firmalara daha güçlü makineler veya özel fiyat teklifleri yapılabilir.
- Aylık Baskı Sayısı: Müşterinin aylık veya yıllık baskı ihtiyacı, cihaz seçimi ve fiyatlandırma için önemli bir göstergedir. Örneğin, aylık cihaz başı 10.000 sayfanın üzerinde baskı yapan müşterilere daha güçlü makineler sunulmalıdır.
- Lokasyon: Müşterinin bulunduğu yerin servis merkezlerine olan yakınlığı, lojistik ve teknik servis maliyetlerini etkileyerek fiyatlandırmada dikkate alınır.

- Lokasyon Adeti: Tekli veya çoklu lokasyonlar, cihaz ihtiyaçlarını, gelecek potansiyeli ve dolayısıyla teklif stratejisini etkileyebilir.
- A3/A4 Baskı İhtiyacı: A3 baskı yapabilme ihtiyacı, teklif edilecek cihazın özelliklerini belirlemede önemli bir faktördür.
- Renkli Baskı İhtiyacı: Renkli baskı ihtiyacı olan müşteriler için, bu özelliği destekleyen cihazlar önerilir.

Özelleştirilmiş tekliflendirme sisteminin verimliliği ve doğruluğu, bu katmandaki verilerin kapsamı ve kalitesine doğrudan bağlıdır. İlk belirlenen parametrelerin yanı sıra, sisteme entegre edilecek ek girdiler aşağıda detaylandırılmıştır:

- Mevcut Cihaz Modelleri ve Özellikleri: Sisteme, markanın baskı cihazlarının tüm modelleri, teknik özellikleri ve performans verileri girilir. Bu bilgi, müşteri ihtiyaçlarına en uygun cihazın seçiminde temel bir rol oynar.
- Güncel Cihaz Fiyatları: Cihazların güncel piyasa fiyatları, dinamik fiyatlandırma modelinin temelini oluşturur. Bu veriler, piyasa trendlerine ve stok durumlarına bağlı olarak sürekli güncellenir.
- Stok Durumu: Cihazların tedarik zinciri durumu ve stok seviyeleri de modele eklenecektir. Cihazların stok durumları, stokta olmayan ürünler için alternatif önerileri belirlemede ve tekliflendirme aşamasında önceliklendirmede kullanılır. Stok kontrolü beklenmedik talep artışlarına hızla yanıt verme yeteneği kazandırır, böylece müşteri memnuniyeti artar ve potansiyel satış kayıpları azalır.
- Faiz Oranları ve Finansal Koşullar: Müşterilere sunulan finansman seçenekleri ve ödeme planları için gerekli olan güncel finansal koşullar, tekliflendirme sürecinde önemli bir faktördür.
- Firmanın Kar Oranı Tercihi: Her teklif, firmanın belirlediği kar oranı çerçevesinde hazırlanır. Bu oran, piyasa koşullarına, rekabet durumuna ve stratejik hedeflere göre ayarlanabilir.
- Ek Maliyetler ve Operasyonel Giderler: Bakım, servis, lojistik ve diğer operasyonel maliyetler, toplam teklif maliyetinin hesaplanmasında dikkate alınır.

3.4 Model Değerlendirme ve Validasyon

Makine öğrenimi modelinin başarısının değerlendirilmesi, geliştirme sürecinin kritik bir parçasıdır. Modelin gerçek veriler üzerindeki performansını objektif bir şekilde

ölçmek, modelin güvenilirliğini ve uygulanabilirliğini belirlemenin temelini oluşturur. Bu bölümde, geliştirilen modelin nasıl bir değerlendirme ve validasyon sürecinden geçirildiği detaylandırılmıştır.

3.4.1 Çapraz doğrulama

Çapraz doğrulama (cross-validation), bir makine öğrenme modelinin genelleme yeteneğini değerlendirmek ve aşırı öğrenme (overfitting) riskini minimize etmek için kullanılan bir yöntemdir. Bu teknik, modelin performansını farklı veri alt kümeleri üzerinde test ederek, modelin çeşitli veri senaryolarına karşı dayanıklılığını ve tutarlılığını ölçer. Çapraz doğrulama, veri setinin sınırlı olduğu durumlarda bile verilerin etkin bir şekilde kullanılmasını sağlar ve modelin bağımsız veri setleri üzerindeki potansiyel performansını daha güvenilir bir şekilde tahmin etmeye olanak tanır (Bishop, 2006).

K-katlı çapraz doğrulama, veri setinin k eşit parçaya bölünmesi ve her bir parça sırasıyla test seti olarak kullanılırken geri kalan $k-1$ parçanın eğitim seti olarak kullanılmasıdır. Bu işlem k kez tekrarlanır ve her seferinde farklı bir parça test seti olarak seçilir. Sonuç olarak, modelin k farklı değerlendirme sonucunun ortalaması alınarak genel performans tahmini yapılır. Bu yöntem, modelin performansının farklı veri alt kümeleri üzerinde tutarlı bir şekilde ölçülmesini sağlar (Hastie, Tibshirani, & Friedman, 2009).

Stratified K-Fold, K-katlı çapraz doğrulamanın bir varyasyonudur. Bu yöntemde, her bir katmanın (fold) sınıf dağılımı, orijinal veri setindeki sınıf dağılımına benzer şekilde yapılır. Özellikle dengesiz veri setlerinde, sınıflar arasında dengeli bir dağılım sağlanarak daha doğru ve güvenilir performans değerlendirmesi yapılır (Kohavi, 1995).

Leave-One-Out çapraz doğrulama, veri setindeki her bir örneğin sırasıyla test seti olarak kullanıldığı bir yöntemdir. Geriye kalan tüm örnekler ise eğitim seti olarak kullanılır. Bu yöntem, modelin her bir veri noktasına karşı ne kadar duyarlı olduğunu ölçer. Ancak, veri seti büyük olduğunda oldukça zaman alıcı ve hesaplama açısından maliyetli olabilir (Hastie, Tibshirani, & Friedman, 2009).

Leave-P-Out çapraz doğrulama, veri setinden P adet örneğin test seti olarak seçildiği ve geri kalan örneklerin eğitim seti olarak kullanıldığı bir yöntemdir. Bu işlem, tüm mümkün P adet kombinasyonları için tekrarlanır. Bu yöntem, modelin farklı

boyutlardaki veri alt kümeleri üzerinde nasıl performans gösterdiğini değerlendirir ancak büyük veri setleri için hesaplama maliyeti yüksektir (Bishop, 2006).

Holdout yöntemi, veri setinin bir kısmının eğitim, diğer kısmının ise test seti olarak ayrıldığı en basit çapraz doğrulama yöntemidir. Genellikle veri setinin %70-80'i eğitim, %20-30'u ise test seti olarak kullanılır. Bu yöntem hızlıdır, ancak tek bir ayrımın model performansını doğru yansıtır yansıtmadığını garanti etmez (Kohavi, 1995).

Bu çalışmada da modelin farklı veri alt kümeleri üzerindeki tutarlılığını ve güvenilirliğini değerlendirmek için 5 katlı çapraz doğrulama uygulanmıştır. Bu yöntem, modelin aşırı öğrenime (overfitting) karşı dayanıklılığını ve genelleştirme kabiliyetini test eder.

Çapraz doğrulama yöntemi, bu çalışmada birkaç önemli nedenden dolayı tercih edilmiştir. İlk olarak, bu yöntem, modelin farklı veri alt kümeleri üzerindeki performansını değerlendirmek amacıyla, genelleştirme kabiliyetinin kapsamlı bir şekilde test edilmesine olanak tanır. Bu, özellikle veri setimizin sınırlı boyutu göz önünde bulundurulduğunda, modelin eğitim verilerine aşırı öğrenme (overfitting) riskini minimize eder ve böylece modelin bağımsız veri setleri üzerindeki potansiyel performansı hakkında daha güvenilir tahminler yapılmasına imkan verir.

İkincil olarak, çapraz doğrulama, modelin farklı veri dağılımları üzerindeki tutarlılığını ve kararlılığının değerlendirilmesini sağlar. Bu yöntemle elde edilen performans metriklerinin varyansı, modelin çeşitli veri senaryolarına ne derece duyarlı olduğunu ve böylece uygulama esnasında beklenen performans dalgalanmalarını ortaya koyar.

Üçüncü bir neden ise, çapraz doğrulamanın veri kullanımı açısından verimli olmasıdır. Bu yöntem, mevcut verilerin hem eğitim hem de doğrulama amacıyla maksimum seviyede kullanılmasını sağlar, böylece veri kısıtlamaları olan durumlarda dahi modelin etkin bir şekilde değerlendirilmesine imkan tanır.

Son olarak, çapraz doğrulama yöntemi, modelin performansını değerlendirmek için objektif bir çerçeve sunar. Her bir katın test seti olarak kullanılması ve modelin her kat için yeniden eğitilmesi, model değerlendirmesine sistematik bir yaklaşım getirir ve bireysel model seçimlerinin veya rastgele veri bölünmelerinin sonuçlar üzerindeki etkisini azaltır.

3.4.2 Karışıklık matrisi ve sınıflandırma raporu

Bu çalışmada modelin performansını derinlemesine analiz etmek amacıyla karışıklık matrisi ve sınıflandırma raporu da tercih edilmiştir. Karışıklık matrisi, modelin her bir sınıfı ne kadar başarılı bir şekilde tahmin ettiğini ve hangi sınıflar arasında karışıklıkların olduğunu göstermektedir. Bu matris üzerinden hesaplanan doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi metrikler, modelin sınıflandırma performansının çeşitli yönlerini aydınlatmaktadır.

Doğruluk metriği, modelin genel performansını bir bütün olarak sunarken, hassasiyet ve geri çağırma gibi metrikler modelin pozitif olarak tahmin edilen örnekler üzerindeki performansını detaylandırır. Hassasiyet, modelin pozitif olarak işaretlediği örneklerin gerçekten ne kadarının pozitif olduğunu; geri çağırma ise gerçek pozitif örneklerin ne kadarının model tarafından doğru şekilde tespit edildiğini gösterir. F1 skoru ise hassasiyet ve geri çağırmanın harmonik ortalaması alınarak, her iki metriği dengeli bir şekilde birleştirir.

Karışıklık matrisi ve sınıflandırma raporu, modelin sadece genel başarısını değil, aynı zamanda sınıf bazında nasıl performans gösterdiğini de gözler önüne sermektedir. Bu, özellikle dengesiz veri setlerinde veya sınıf sayısının fazla olduğu durumlarda kritik öneme sahiptir. Modelin bazı sınıfları diğerlerine göre daha iyi ayırt edip edemediğini, hangi sınıfların model için zorlayıcı olduğunu ve modelin hatalarının hangi türde yoğunlaştığını anlamak, modelin iyileştirilmesi ve daha dengeli bir performansa ulaşması için gerekli stratejilerin belirlenmesinde yardımcı olur.

Bu detaylı analiz, modelin güçlü yönlerini ve iyileştirme gerektiren alanlarını belirlemeye olanak tanır. Örneğin, düşük geri çağırma skoruna sahip bir sınıf için ek özellik mühendisliği yapılabilir veya modelin bu sınıfı daha iyi ayırt etmesini sağlamak amacıyla özel ağırlıklandırmalar uygulanabilir. Bu nedenlerle, karışıklık matrisi ve sınıflandırma raporu, modelin sınıflandırma kabiliyetini çok yönlü bir şekilde değerlendirme ve gerekli iyileştirmeleri yapma sürecinde kilit rol oynamaktadır. Bu analizler, modelin belirli sınıflar üzerinde nasıl iyileştirilebileceğine dair değerli içgörüler sağlamakta ve modelin daha dengeli ve güvenilir bir performans sergilemesine katkıda bulunmaktadır.

3.5 Tekliflendirme

Bu bölümde tekliflendirme stratejisi kısmında, tahmin edilen makine modellerine bağlı olarak kira bedellerinin nasıl belirlendiği üzerinde durulmuştur. Tekliflendirme süreci, belirli parametrelerin ve maliyet unsurlarının dikkate alınmasıyla gerçekleştirilmiştir. Bu parametreler arasında kurulum maliyeti, kilometre başına ulaşım giderleri, yıllık bakım maliyeti, enflasyon oranı ve getiri oranı yer almaktadır. Ayrıca, tahmin edilen makine modelinin alış fiyatı ve hurda değeri de önemli bir maliyet bileşenidir.

Tekliflendirme stratejisi, her bir makine modeli için toplam maliyetin hesaplanmasını içermektedir. Maliyet analizi süreci, ürünlerin kurulumu, bakımı ve lojistik gibi çeşitli maliyet unsurlarının dikkate alınmasıyla gerçekleştirilmiştir. Bu süreçte, aşağıda belirtilen parametreler temel alınmıştır:

Kurulum Maliyeti: Ürünlerin kurulum süreçlerinde ortaya çıkan maliyetler hesaplamalara dahil edilmiştir. Bu maliyet, ürünün müşteri lokasyonunda kullanıma hazır hale getirilmesi için gerekli olan tüm işçilik, malzeme ve diğer ilgili giderleri kapsamaktadır.

Kilometre Başına Ulaşım Giderleri: Lojistik faaliyetler sırasında, kilometre başına tüketilen yakıt ve diğer operasyonel giderler göz önünde bulundurulmuştur. Bu maliyet, ürünlerin tedarik zinciri boyunca taşınması esnasında kat edilen mesafeye bağlı olarak hesaplanmıştır.

Bakım Maliyeti: Ürünlerin bakım ve onarımı için yıllık olarak ödenen tutarlar analize dahil edilmiştir. Bu maliyet, ürünlerin uzun vadede sorunsuz bir şekilde çalışabilmesi için gereken rutin bakım ve arıza giderme işlemlerini kapsamaktadır.

Enflasyon Oranı: Maliyet hesaplamalarında, ekonomik koşulların getirdiği maliyet artışlarını dikkate alabilmek adına yıllık enflasyon oranı göz önünde bulundurulmuştur.

Getiri Oranı: Yatırımın beklenen getirisi, maliyet hesaplamalarında önemli bir parametre olarak ele alınmıştır. Bu oran, işletmenin yatırımlarından elde etmeyi hedeflediği kârlılık düzeyini temsil etmektedir.

Hurda Değeri: Ürünlerin kullanım ömrünün sonunda muhtemel olarak sahip olacakları değerler hesaplamalara dahil edilmiştir. Bu değer, ürünlerin ekonomik ömürlerinin

sonunda yeniden satılabilirliği veya hurda olarak değerlendirilmesi durumunda elde edilebilecek tutarı ifade etmektedir.

Bu parametrelerin belirlenmesi, ürünlerin toplam maliyetinin ve müşterilere sunulacak aylık ödeme planlarının doğru bir şekilde hesaplanabilmesi için kritik öneme sahiptir.

3.5.1 Mesafe bilgileri ve lojistik maliyetlerin hesaplanması

Lojistik maliyetlerin hesaplanmasında kullanılan mesafe bilgileri ve lojistik süreçlerin yönetimi, işletmenin belirli servis noktalarını merkez olarak organize edilmiştir. Bu yaklaşımda, işletmenin hizmet verdiği her bir bölge veya şehir için bir merkez servis noktası belirlenmiş ve tüm lojistik faaliyetler bu merkezler üzerinden planlanmıştır. Bu merkez servis noktaları, işletmenin lojistik ağının temel taşlarını oluşturur ve hizmetin verimli bir şekilde sunulabilmesi için stratejik konumlarda yer alırlar.

Bu yapıda, bir müşteriden gelen talebin karşılanması sürecinde, müşterinin bulunduğu lokasyon ile en yakın servis merkezi arasındaki mesafe temel alınır. Teslimatın yapılacağı şehrin merkezi, hizmetin sunulacağı nokta olarak kabul edilir ve bu şehir merkezine en yakın olan servis merkezinden hizmetin sağlanması planlanır. Bu yaklaşım, lojistik faaliyetlerin merkeziyetçi bir şekilde yönetilmesini ve böylece hem maliyetlerin optimize edilmesini hem de hizmet kalitesinin standart bir şekilde korunmasını sağlar.

Müşterinin lokasyonunda bir servis yetkilisinin yer alıp almadığı kontrol edilir ve bu lokasyona en yakın servis merkezinin belirlenmesi sağlanır. Bu stratejik yaklaşım, işletmenin lojistik maliyetlerini daha etkin bir şekilde yönetmesine olanak tanırken, aynı zamanda hizmet süreçlerindeki verimliliği ve müşteri memnuniyetini de artırır. Müşteri lokasyonuna en yakın servis merkezinden hizmetin sağlanması, teslimat süreçlerinin hızlandırılmasına ve lojistik faaliyetler sırasında ortaya çıkabilecek aksaklıkların minimize edilmesine katkı sağlar. Bu, işletmenin operasyonel verimliliğinin yanı sıra rekabet avantajının da güçlenmesine olanak tanır.

3.5.2 Maliyet ve fiyatlandırma hesaplamaları

Tez çalışmasında yer alan bu bölümde, müşterilere sunulacak ürünler için aylık ödeme planlarının ve toplam maliyetin hesaplanması süreci detaylandırılmıştır. Bu hesaplamalar, işletmenin finansal planlama süreçlerinin bir parçası olarak, müşterilere sunulacak finansman seçeneklerinin belirlenmesinde kullanılmaktadır.

Aylık kira bedeli hesaplaması, nominal indirim oranı kullanılarak yapılmıştır. Nominal indirim oranı, enflasyon oranı ve getiri oranının birleşimi ile elde edilmiştir. Bu oran, belirlenen dönem boyunca kira bedelinin nasıl indirgeneceğini göstermektedir.

$$\text{Nominal İndirim Oranı} = (1 + \text{Enflasyon Oranı}) \times (1 + \text{Getiri Oranı}) - 1 \quad (3.4)$$

$$\text{Aylık İndirim Oranı} = (1 + \text{Nominal İndirim Oranı})^{1/12} - 1 \quad (3.5)$$

Toplam başlangıç maliyeti, ürünün satın alma fiyatı ile kurulum ve lojistik gibi ek maliyetleri de kapsayacak şekilde hesaplanmıştır. Bu ek maliyetler, ürünün teslimatından kurulumuna kadar olan süreçteki giderleri yansıtmaktadır.

$$\text{Toplam Başlangıç Maliyetleri} = \text{Satın Alma Fiyatı} + \text{Kurulum Maliyeti} + \text{Lojistik Maliyeti} \quad (3.6)$$

$$\begin{aligned} \text{Aylık Ödeme} = & (\text{Toplam Başlangıç Maliyetleri} \times A/P, i, n) + \\ & (\text{Yıllık Bakım Maliyeti} \times A/F, i, n) - (\text{Hurda Değeri} \times A/F, i, n) \end{aligned} \quad (3.7)$$

$$A/P, i, n = \frac{i}{1 - (1+i)^{-n}} \quad (3.8)$$

$$A/F, i, n = \frac{i}{(1+i)^n - 1} \quad (3.9)$$

Çalışmada belirli dönemler için aylık kira bedelleri hesaplanmıştır. Aylık kira bedeli hesaplaması, toplam maliyetin aylık indirim oranına göre dağıtılması esasına dayanmaktadır. Hesaplanan aylık ödemeler, kira dönemine göre değişiklik göstermektedir ve bu, farklı kullanım süreleri için maliyetin nasıl etkilendiğini göstermektedir.

Bu fiyatlandırma stratejisi, makine kiralama hizmetlerinin maliyet etkinliğinin değerlendirilmesinde ve potansiyel müşterilere sunulacak kira tekliflerinin belirlenmesinde önemli bir metodoloji olarak hizmet etmektedir.

Tekliflendirme sürecine kadar gerçekleşen tüm süreç ve sonrasında 2. Aşama olarak geliştirilen arayüze kadar olan akış Çizelge 3.2’de detaylarıyla özetlenmiştir.

Çizelge 3.2: Metodoloji akış özeti.

Adım Numarası	Adım İsmi	Yöntem	Girdi	Çıktı
1	Veri Toplama	Çeşitli Kaynaklardan Veri Toplama	Crm, Satış Raporları, Pazarlama Raporları	Müşteri Model Verisi
2	Veri Analizi	CHAID Analizi	Müşteri Model Verisi	Anlamlılık Sonuçları
3	Girdilerin Belirlenmesi	Analiz Sonuçlarına Dayalı Karar Verme	Anlamlılık Sonuçları	Baskı Hacmi, Çalışan Sayısı, Baskı Türü, Kağıt Türü, Cihaz Türü
4	Modelin Oluşturulması	Rastgele Orman Algoritması	Baskı Hacmi, Çalışan Sayısı, Baskı Türü, Kağıt Türü, Cihaz Türü	Makine Modeli Tercihi
5	Modelin Değerlendirilmesi	Çapraz Doğrulama ve Karışıklık Matrisi	Makine Modeli Tercihi	Doğruluk Oranı ve Sınıflandırma Raporu
6	Tekliflendirme	Özelleştirilmiş Teklif Oluşturma	Makine Modeli Tercihi, Firma Bilgileri, Stok Bilgileri, Piyasa Verileri, Lojistik Maliyetleri, Kurulum Maliyetleri	Aylık Ödeme Planı, Müşteriye Özel Tekliflendirme
7	Kullanıcı Arayüzü Oluşturma	Kullanıcı Dostu Tasarım: Frontend Oluşturma ve Backend Entegrasyonu	Form girdileri ve KDS'den elde edilen veriler	İşlevsel Kullanıcı Arayüzü



4. UYGULAMA: MAKİNE ÖĞRENMESİ DESTEKLİ KARAR DESTEK SİSTEMİ TASARIMI

4.1 Veri Seti ve Analizi

Uygulama aşamasında, Kopitek Kopyalama Sistemleri Ltd. Şti. tarafından elde edilen 8600 adet müşteri bilgisinin bulunduğu veri seti kullanılmıştır. Kopitek Kopyalama Sistemleri Ltd. Şti., merkezi İstanbul'da olan ve dokümantasyon sektöründe faaliyet gösteren bir Türk şirkettir. 1999 yılında kurulan firma, ofis tipi profesyonel baskı ekipmanları satışı, kiralaması, teknik servis desteği ve yazılım tarafında kurumsal firmalara hizmet vermektedir. Bu doğrultuda satış departmanındaki operasyonel verimliliği arttırmak ve süreç iyileştirmesini sağlamak amacıyla çalışmaya katkıda bulunmuştur.

Veri seti, toplamda 8600 gerçek müşteri gözlemini kapsamakta olup, bu gözlemler Çizelge 4.1'de belirtilen 'MFP (Multifunctional Printer)', 'Kâğıt Boyutu (Paper Size)', 'Baskı Tipi (Print Type)', 'Çalışan Sayısı (Number of Worker)', Baskı Hacmi (Volume) ve 'Sektör' olmak üzere farklı kategorik değişkenler açısından incelenmiştir.

Çizelge 4.1: Bağımsız veri değişkenleri ve açıklamaları.

Değişken	Açıklama
MFP	Çok fonksiyonlu yazıcı varlığı (0: Yok, 1: Var)
Paper Size	Kâğıt boyutu (1: A4, 2: A4 & A3)
Print Type	Baskı tipi (0: Renksiz, 1: Renkli)
Number of Worker	Çalışan sayısı (0: 1-20, 1: 21-50, 2: 51-100, 3: 100+)
Sector	Şirketin faaliyet gösterdiği sektör
Volume	Ortalama baskı hacmi

Bu çalışmada gerçekleştirilen veri analizi, Ki-kare Otomatik Etkileşim Algılama (CHAID) karar ağacı metodolojisinin kullanılmasıyla, makine modellerinin belirlenmesinde etkili olan değişkenlerin anlamlılığını ve etkileşimlerini incelemiştir. CHAID analizi, bağımlı değişken olarak tanımlanan makine modelleri ile bağımsız

değişkenler arasındaki ilişkileri keşfetmek için bir dizi bölünme kriteri kullanmış ve her bir düğümde istatistiksel anlamlılığı değerlendirmiştir.

Çizelge 4.2’de bu analitik işlemin bir sonucu olarak, incelenen veri setine ait tanımlayıcı istatistikleri sunmaktadır. Tanımlayıcı istatistikler, araştırma verilerinin anlaşılabilir ve özet bir biçimde sunulmasını sağlayan temel istatistiksel analiz teknikleridir. Bunlar, veri setinin merkezi eğilim, dağılım ve frekans gibi temel özelliklerini özetler ve araştırma sorularının daha detaylı analizi için zemin hazırlar. Bu bağlamda Çizelge 4.2’de yer alan veriler, çalışma kapsamında ele alınan örneklem grubunun demografik ve işlevsel özelliklerinin bir yansımasıdır ve araştırmacılara, veri setinin genel yapısı hakkında önemli bilgiler sağlar.

Çizelge 4.2: Tanımlayıcı istatistikler.

MFP	N = 8600
0	6800 (79.07)
1	1800 (20.93)
Paper Size	
1	3600 (41.86)
2	5000 (58.14)
Print Type	
0	4000 (46.51)
1	4600 (53.49)
Number of Worker	
0	440 (5.12)
1	1420 (16.51)
2	2921 (33.97)
3	3819 (44.41)
Sector	
Bilgi Teknolojileri	1122 (13.05)
Diğer	1029 (11.97)
Eğitim	1 (0.01)
Finans	1065 (12.38)
Gayrimenkul	1029 (11.97)
Hukuk	1083 (12.59)
Kamu	1133 (13.17)
Perakende	1062 (12.35)
Sağlık	1076 (12.51)
Volume	18758.52 ± 26314.36

MFP olarak tanımlanan veri makine modelinin çok fonksiyonlu olup olmadığını belirlemek adına kullanılmıştır. MFP kategorisinde, iki alt kategori bulunmaktadır: Kategori "0": MFP ve Kategori "1": SFP (Single Functional Printer) ‘yi temsil etmektedir. Kategori "0", veri setindeki gözlemlerin büyük bir çoğunluğunu

oluşturarak %79,07 (n=6800) ile temsil edilmektedir. Öte yandan, Kategori "1" daha düşük bir oranla, yani %20,93 (n=1800) olarak kaydedilmiştir.

Kağıt Boyutu (Paper Size) değişkeni altında, "1" ve "2" olarak iki farklı sınıflandırma mevcuttur. Kağıt Boyutu değerinin "1" olması makinenin yalnızca A4 tipi baskı almasını ifade ederken, veri setinin yaklaşık dörtte iki kısmını, %41,86 (n=3600) ile temsil eder. "2" kategorisi ise hem A4 hem de A3 kağıt boyutunda baskı almasını ifade ederken nispeten daha yüksek bir oranla, %58,14'lük bir paya sahip (n=5000) ve bu dağılım, "2" kategorisinin "1"e göre daha yaygın olduğunu göstermektedir.

Baskı Tipi (Print Type) kategorisinde, "0" Renksiz baskı ve "1" Renkli baskı olarak iki farklı sınıflama gözlemlenmiştir. Ren "0" kategorisi, gözlemlerin hemen yarısına yakın bir kısmını, %46,51 (n=4000) ile içerirken, "1" kategorisi, veri setindeki gözlemlerin biraz daha fazlasını, %53,49 (n=4600) ile kapsamaktadır.

Çalışan Sayısı (Number of Worker) değişkenine gelince, dört farklı kategoride dağılım göstermektedir: "0" 1-20 çalışan, "1" 20-50 çalışan, "2" 50-100 çalışan ve "3" 100 ve üzeri çalışanı ifade etmektedir. "0" kategorisi, %5,12'lik bir oranla (n=440) en düşük paya sahiptir. "1" kategorisi %16,51 (n=1420), "2" kategorisi %33,97 (n=2921) oranında temsil edilirken, "3" kategorisi, %44,41 (n=3819) ile en yüksek oranı elde etmiştir ve bu, veri setindeki gözlemlerin neredeyse yarısını oluşturan bir kategori olarak dikkat çekmektedir.

Sektör bazında inceleme yapıldığında, çeşitli sektörler arasında dengeli bir dağılım gözlemlenmektedir. "Bilgi Teknolojileri" sektörü, veri setindeki gözlemlerin %13,05'ini (n=1122) oluştururken, "Eğitim" sektörü sadece %0.01 (n=1) ile temsil edilmektedir, ki bu göreceli olarak diğer sektörlerle kıyasla oldukça düşük bir orandır. "Finans", "Gayrimenkul", "Hukuk", "Kamu", "Perakende" ve "Sağlık" sektörleri, %11,97 ile %13,17 arasında bir oranda temsil edilmektedirler, bu da veri setinin bu sektörler arasında nispeten homojen bir dağılıma sahip olduğunu işaret etmektedir.

Son olarak, hacim (Volume) değişkeninin ortalaması 18758,52 olarak hesaplanmıştır.

Çizelge 4.3: Korelasyonlar.

			Model	MFP	Paper Size	Print Type	Volume	Number of Worker	Sector
Spearman's rho	Model	Correlation Coefficient	1,000	.175**	0,011	.368**	-.156**	-.066**	-0,002
		Sig. (2-tailed)		0,000	0,291	0,000	0,000	0,000	0,871
		N	8600	8600	8600	8600	8600	8600	8599
	MFP	Correlation Coefficient	.175**	1,000	-.490**	.021*	-.571**	-.236**	0,005
		Sig. (2-tailed)	0,000		0,000	0,048	0,000	0,000	0,661
		N	8600	8600	8600	8600	8600	8600	8599
	Paper Size	Correlation Coefficient	.058**	-.490**	1,000	.059**	.786**	.437**	0,001
		Sig. (2-tailed)	0,000	0,000		0,000	0,000	0,000	0,959
		N	8600	8600	8600	8600	8600	8600	8599
	Print Type	Correlation Coefficient	.368**	.021*	.059**	1,000	-.150**	-.046**	-0,007
		Sig. (2-tailed)	0,000	0,048	0,000		0,000	0,000	0,501
		N	8600	8600	8600	8600	8600	8600	8599
	Volume	Correlation Coefficient	-.156**	-.571**	.786**	-.150**	1,000	.542**	-0,010
		Sig. (2-tailed)	0,000	0,000	0,000	0,000		0,000	0,361
		N	8600	8600	8600	8600	8600	8600	8599
	Number of Worker	Correlation Coefficient	-.066**	-.236**	.437**	-.046**	.542**	1,000	-0,003
		Sig. (2-tailed)	0,000	0,000	0,000	0,000	0,000		0,810
		N	8600	8600	8600	8600	8600	8600	8599
	Sector	Correlation Coefficient	-0,002	0,005	0,001	-0,007	-0,010	-0,003	1,000
		Sig. (2-tailed)	0,871	0,661	0,959	0,501	0,361	0,810	
		N	8599	8599	8599	8599	8599	8599	8599

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).

Çizelge 4.3'te sunulan Spearman'ın rho korelasyon katsayısı analizi, araştırma kapsamındaki değişkenler arasındaki monotonik ilişkilerin gücünü ve yönünü değerlendirmekte kullanılan bir nonparametrik test sonucudur. Bu test, özellikle normal dağılım varsayımının sağlanmadığı durumlarda tercih edilen bir yöntemdir. Korelasyon katsayısı değerleri, -1 ile +1 arasında değişebilir; +1 mükemmel bir pozitif monotonik ilişki, -1 mükemmel bir negatif monotonik ilişki ve 0 ise hiçbir monotonik ilişkinin olmadığını gösterir. Anlamlılık düzeyleri (p-değerleri), korelasyonun rastlantı sonucu olup olmadığını test etmek için kullanılır ve genellikle 0.05'ten küçük değerler (veya araştırmada belirlenen özel bir eşik değer) istatistiksel olarak anlamlı kabul edilir.

Analiz sonuçları aşağıda yorumlanmıştır;

Model ve MFP: Model ile MFP arasında pozitif ve orta şiddette bir korelasyon bulunmuştur ($r = .175$, $p < .01$), bu ilişki istatistiksel olarak anlamlıdır ve modelin artışıyla MFP değerlerinin de arttığı yönünde bir eğilim olduğunu göstermektedir.

Model ve Kâğıt Boyutu: İlişki istatistiksel olarak anlamlıdır. ($r = .058$, $p < .01$), dolayısıyla Model ile Kâğıt Boyutu arasında anlamlı bir ilişki bulunduğu söylenebilir.


Model ve Baskı Tipi: Model ile Baskı Tipi arasında orta şiddette bir pozitif korelasyon saptanmıştır ($r = .368$, $p < .01$), bu, modelin artışıyla Baskı Tipi değerlerinin de artma eğiliminde olduğunu gösterir ve bu ilişki istatistiksel olarak anlamlıdır.

Model ve Hacim: Model ile Hacim arasında negatif ve orta şiddette bir korelasyon tespit edilmiştir ($r = -.156$, $p < .01$), bu, model değerleri arttıkça Hacim değerlerinin düşme eğiliminde olduğunu gösterir ve bu ilişki istatistiksel olarak anlamlıdır.

Model ve Çalışan Sayısı: Model ile Çalışan Sayısı arasında düşük şiddette negatif bir korelasyon bulunmuştur ($r = -.066$, $p < .01$), bu ilişki istatistiksel olarak anlamlıdır ve modelin artışının, Çalışan Sayısı değerlerinin düşmesiyle ilişkili olduğunu gösterir.

Model ve Sektör: Model ile Sektör arasında korelasyon yok denecek kadar düşüktür ($r = -.002$, $p > .05$), bu yüzden bu iki değişken arasında anlamlı bir ilişki olmadığı sonucuna varılabilir.

Bu istatistiksel bulgular, sonucunda Şekil 4.1'de gösterilen karar ağacı diyagramı oluşturulmuştur.



Şekil 4.1: Karar ağacı diyagramı.

Çizelge 4.4: Makine modellerini etkileyen değişkenlerin karar ağacı ile incelenmesi.

Terminal Node	Path	Classification	Number Correct	%	Total N	Total %
11	Volume $\leq$ 1885 --> MFP = 0	i-S X C1127iF/C1127i	200	48.2	415	0.05
13	Volume (1885 : 2436] --> MFP = 0	i-S X 1238iF/1238i	185	73.1	253	0.03
18	Volume (3169 : 4665] --> MFP = 1	iR-ADV DX C357P	200	100	200	0.02
19	Volume (4665 : 6194] --> Paper Size = 2	iR-ADV DX C3725i	181	37.6	481	0.06
23	Volume (11355 : 19631] --> Print Type = 1	IR-ADV DX C5750i	200	44.2	453	0.05
24	Volume (11355 : 19631] --> Print Type = 0	iR-ADV DX 4745i	200	49.1	407	0.05
26	Volume (19631 : 31276] --> Print Type = 0	iR-ADV DX 6755i	160	42.9	373	0.04
27	Volume (31276 : 46395] --> Print Type = 1	IR-ADV DX C7780i	200	34.8	574	0.07
28	Volume (31276 : 46395] --> Print Type = 0	iR-ADV DX 6765i	200	69.9	286	0.03
29	Volume > 46395 --> Print Type = 1	IR-ADV C9070s PRO	66	100	66	0.01
30	Volume > 46395 --> Print Type = 0	iR-ADV 8595 PRO/P	200	25.2	794	0.09
31	Volume $\leq$ 1885 --> MFP = 1 --> Print Type = 1	i-S X C1127P	200	100	200	0.02
32	Volume $\leq$ 1885 --> MFP = 1 --> Print Type = 0	LBP251dw	200	81.6	245	0.03
33	Volume (1885 : 2436] --> MFP = 1 --> Paper Size = 2	LBP852Cx	69	100	69	0.01
34	Volume (1885 : 2436] --> MFP = 1 --> Paper Size = 1	i-S X 1238P/1238Pr	182	33.6	541	0.06
35	Volume (2436 : 3169] --> Print Type = 1 --> Paper Size = 2	LBP852Cx	131	100	131	0.02
36	Volume (2436 : 3169] --> Print Type = 1 --> Paper Size = 1	iR-ADV DX C257i	179	39.2	457	0.05
37	Volume (2436 : 3169] --> Print Type = 0 --> MFP = 0	iR1643i/1643iF	132	100	132	0.02
38	Volume (2436 : 3169] --> Print Type = 0 --> MFP = 1	i-S X 1643P	136	100	136	0.02
39	Volume (3169 : 4665] --> MFP = 0 --> Paper Size = 2	iR-ADV DX C3720i	200	91.3	219	0.03
40	Volume (3169 : 4665] --> MFP = 0 --> Paper Size = 1	iR-ADV DX C357i	200	45.2	442	0.05
41	Volume (4665 : 6194] --> Paper Size = 1 --> Print Type = 1	iR- ADV DX C477i/iZ	188	100	188	0.02
42	Volume (4665 : 6194] --> Paper Size = 1 --> Print Type = 0	iR-ADV DX 617i	191	100	191	0.02
43	Volume (6194 : 11355] --> Print Type = 1 --> Number of Worker = 2	IR-ADV DX C5735i	61	55.5	110	0.01
44	Volume (6194 : 11355] --> Print Type = 1 --> Number of Worker = 3	IR-ADV DX C5735i	139	79.4	175	0.02
45	Volume (6194 : 11355] --> Print Type = 1 --> Number of Worker = 1	iR-ADV C3530i/II & III	25	71.4	35	0.00
46	Volume (6194 : 11355] --> Print Type = 0 --> Paper Size = 2	iR-ADV DX 4725i	200	58.8	340	0.04
47	Volume (6194 : 11355] --> Print Type = 0 --> Paper Size = 1	iR-ADV DX 717i	200	100	200	0.02
48	Volume (31276 : 46395] --> Print Type = 1 --> Number of Worker = 2	IR-ADV DX C7765i	65	44.5	146	0.02
49	Volume (31276 : 46395] --> Print Type = 1 --> Number of Worker = 3	IR-ADV DX C7765i	135	39.6	341	0.04

Şekil 4.2’de karar Ağacında bölünmeler önem sırasına göre gerçekleşir. Burada volüme değişkeni, model ile ilgili en önemli faktör olduğu gözlemlenmiştir, dolayısıyla 8600 müşteri verisinin tamamını içeren ilk düğüm (parent node) volume değerlerini ≤ 1885 , (1885: 2436], (2436:3169], (3169:4665], (4665:6194], (6194: 11355], (11355 : 19631], (19631:31276], (31276:46395] ve >46395 olarak kategoriye ayırarak 10 (child node) alt düğümlere ayrılmaktadır

Çizelge 4.4’te, bir CHAID karar ağacı analizini kullanarak, baskı hacmi (Volume) ile bir dizi diğer değişken arasındaki ilişkileri ve bunların belirli makine modellerinin sınıflandırmasına olan etkisini incelemektedir. Bu analiz, baskı hacmi temel alınarak çeşitli parametrelerin (MFP, Kağıt Boyutu, Baskı Tipi, Çalışan Sayısı) her bir makine modeli üzerindeki etkisini ve sınıflandırma doğruluğunu ortaya koymaktadır.

Her bir terminal düğümde, baskı hacmi ve diğer bağımsız değişkenlerin belirli bir eşik veya kategoriye göre yapılandırılmasıyla elde edilen sınıflandırma bilgisi bulunmaktadır. Buna göre, düğüm yolları, her düğümde hangi koşulların karşılandığını belirleyen kuralları ifade etmektedir. Düğümlerden elde edilen sınıflandırmalar, doğruluk yüzdeleri ve toplam gözlem sayıları (Total N) ile birlikte verilerek, her bir koşul kombinasyonunun tahmin gücünü göstermektedir.

Örneğin, baskı hacmi 1885 birimden az olan ve MFP değeri "0" olan makine modelleri için "i-S X C1127iF/C1127i" sınıflandırması, 415 gözlemin %48,2'sinde doğru tahmin edilmiştir. Benzer şekilde, baskı hacmi 46395 birimden fazla ve Baskı Tipi "1" olan durumlar için "IR-ADV C9070s PRO" sınıflandırması, 66 gözlemin tamamında (%100) doğru tahmin edilmiştir. Bu, yüksek hacimli baskı ihtiyacı olan kullanıcı segmentinin bu modeli tercih etme eğiliminde olduğunu gösterir.

CHAID karar ağacı modelindeki düğümlerin anlamlılık test sonuçları Çizelge 4.5 üzerinde belirtilmiştir. Her düğüm, CHAID analizi sürecinde bölünme kriteri olarak kullanılan birincil etkileyen değişkenin anlamlılığını test etmek için yapılan Chi-kare testlerinin sonuçlarını göstermektedir. Bu testler, her bir bölünmenin (dallanmanın) istatistiksel olarak anlamlı olup olmadığını belirlemekte kullanılır. Anlamlılık düzeyi (p-değeri), Ki-kare istatistiği ve serbestlik derecesi (df), her düğüm için sağlanmıştır.

Analizin yorumu aşağıdaki gibi yapılabilir:

Anlamlılık (p-değeri): Tüm düğümler için p-değeri <0.001 olarak rapor edilmiştir, bu da bölünmelerin son derece anlamlı olduğunu gösterir, yani bağımsız değişkenlerin

sınıflandırmadaki etkileri rastlantısal değildir ve belirgin bir model olduğunu kanıtlar. Düğümler 48 ve 49 için p-değeri 0.036'dır, bu daha az anlamlıdır fakat yine de genel anlamlılık eşiği olan 0.05'in altındadır.

Ki-kare (Chi-Square): Çok yüksek Ki-kare değerleri (örneğin 860.000) gözlenmektedir, bu da modeldeki bölünmelerin yüksek derecede anlamlı olduğunu ve veri setindeki grupların birbirinden iyi ayrıldığını gösterir. Daha düşük Ki-kare değerleri (örneğin düğümler 48 ve 49'daki 6.669) daha az kesin bölünmeleri işaret eder fakat yine de anlamlıdır.

Serbestlik Derecesi (df): Ki-kare dağılımında karşılaştırma için kullanılan parametre sayısını ifade eder ve her düğüm için bu değer verilmiştir. Genellikle, df değeri bağımsız değişkenlerin kategorileri sayısı ile ilişkilidir.

Her düğüm için birincil etkileyen değişken belirtilmiştir ve bunlar baskı hacmi, Kağıt Boyutu, Baskı Tipi, Çalışan Sayısı ve MFP gibi özelliklerdir. Bu değişkenlerin her birinin ayrı ayrı düğümlerde baskı hacmi sınıflandırmasını nasıl etkilediğini göstermektedir. Örneğin, bir düğümde Kağıt Boyutu'nun anlamlı bir bölünme kriteri olduğu ve düğümler 18, 37 ve 38 gibi diğerlerinde MFP'nin anlamlı olduğu gözlemlenmektedir.

Genel olarak, Çizelge 4.4'te sunulan sonuçlar, CHAID karar ağacı modelinin yüksek anlamlılık düzeylerine sahip olduğunu ve seçilen değişkenlerin baskı hacmi üzerinde önemli etkilere sahip olduğunu ortaya koymaktadır. Bu sonuçlar, modelin güvenilirliğini ve kullanılan değişkenlerin etkilerinin gücünü doğrular niteliktedir. Bu bulgular, ilgili alanlarda stratejik kararlar alınırken kullanılabilir ve makine modellerinin pazar segmentasyonuna yönelik değerli içgörüler sağlayabilir.

Çizelge 4.5: Karar ağacı modeline ilişkin anlamlılık sonuçları.

Node	Parent Node	Birincil Etkileyen Değişken	p	Chi-Square	df
11	1	MFP	<0.001	860.000	6
13	2	MFP	<0.001	863.000	7
18	4	MFP	<0.001	861.000	7
19	5	Paper Size	<0.001	860.000	4
23	7	Print Type	<0.001	860.000	5
24	7	Print Type	<0.001	860.000	5
26	8	Print Type	<0.001	860.000	5
27	9	Print Type	<0.001	860.000	7
28	9	Print Type	<0.001	860.000	7
29	10	Print Type	<0.001	860.000	4
30	10	Print Type	<0.001	860.000	4
31	12	Print Type	<0.001	445.000	3
32	12	Print Type	<0.001	445.000	3
33	14	Paper Size	<0.001	610.000	5
34	14	Paper Size	<0.001	610.000	5
35	15	Paper Size	<0.001	588.000	3
36	15	Paper Size	<0.001	588.000	3
37	16	MFP	<0.001	268.000	1
38	16	MFP	<0.001	268.000	1
39	17	Paper Size	<0.001	661.000	6
40	17	Paper Size	<0.001	661.000	6
41	20	Print Type	<0.001	379.000	1
42	20	Print Type	<0.001	379.000	1
43	21	Number of Worker	<0.001	108.805	6
44	21	Number of Worker	<0.001	108.805	6
45	21	Number of Worker	<0.001	108.805	6
46	22	Paper Size	<0.001	540.000	2
47	22	Paper Size	<0.001	540.000	2
48	25	Number of Worker	0.036	6.669	2
49	25	Number of Worker	0.036	6.669	2

4.1.1 Bağımsız değişken seçimi ve önem sıralaması

Çizelge 4.4'te sunulan analiz sonuçlarına göre, makine modellerinin sınıflandırılmasında baskı hacmi, MFP, Kâğıt Boyutu, Baskı Tipi ve Çalışan Sayısı değişkenleri önemli birer ayırıcı faktör olarak belirlenmiştir. Her bir terminal düğüm, belirli bir baskı hacmi aralığı ve diğer bağımsız değişkenlerin kombinasyonlarına göre makine modellerinin sınıflandırılmasını sağlamış ve bu kombinasyonların doğruluk oranları ve toplam gözlem sayıları ile desteklenmiştir.

Özellikle, düşük ve yüksek baskı hacmi aralıklarındaki farklı makine modellerinin doğruluk oranları, potansiyel müşteri tercihlerinin ve pazar segmentlerinin belirgin bir şekilde anlaşılmasına olanak tanımıştır. Ki-kare istatistikleri, bu bölünmelerin istatistiksel olarak son derece anlamlı olduğunu ($p < 0.001$) ve modelin baskı hacmi sınıflandırmasının güvenilirliğini doğrulamıştır.

Çizelge 4.5'te yer alan anlamlılık sonuçları ise, her bir düğümün ana etkileyen değişkenine odaklanmış ve serbestlik dereceleri dikkate alınarak ki-kare test sonuçları sunulmuştur. Bu sonuçlar, modelin bütünlüğünü ve değişkenlerin etkisinin gücünü kanıtlamakta ve bağımsız değişkenlerin makine modellerinin sınıflandırılmasındaki rolünün anlaşılmasında kritik önem taşımaktadır.

Sonuç olarak, gerçekleştirilen CHAID karar ağacı analizi, makine modellerinin sınıflandırılmasında baskı hacmi dahil olmak üzere çeşitli faktörlerin etkileşimlerini ve etkilerini açıkça ortaya koymuştur. Elde edilen bulgular, bu analitik çalışmada kullanılacak ve müşteriden talep edilecek bilgilerin belirlenmesi adına gerçekleştirilmiştir. Bu çıktılar sonucunda girdi katmanında kullanılacak ana parametreler şu şekildedir; Çalışan Sayısı, Aylık Baskı Hacmi, MFP (Çok Fonksiyon), Kâğıt Boyutu, Baskı Tipi.

İkinci adımda Rastgele Ormanlar modeli kullanılarak elde edilen özellik önem sıralaması Çizelge 4.6'da verilmiştir.

Çizelge 4.6: Değişken önem sıralaması.

Özellik	Önem Skoru
Baskı Hacmi	0.764994
Baskı Tipi	0.078437
Kâğıt Boyutu	0.053839
MFP	0.050085
Çalışan Sayısı	0.031518

Yapılan analiz sonucunda Baskı Hacmi özelliği, modelin tahminlerinde en belirleyici faktör olarak öne çıkmaktadır. Bu özellik, modelin sınıflandırma performansını en çok etkileyen değişkendir. Baskı Tipi, Kâğıt Boyutu ve MFP gibi diğer özellikler de önemli katkılarda bulunmakla birlikte, Baskı Hacmi özelliği modelin performansında en büyük etkiye sahiptir.

Veri analizinde kullanılan CHAID yöntemi, bağımsız değişkenler arasındaki etkileşimleri belirlerken, Rastgele Ormanlar bu etkileşimlerin model performansına katkısını değerlendirerek modelin doğruluğunu ve genelleme yeteneğini artırmıştır. Bu iki yöntemin birlikte kullanılması, modelin daha doğru ve güvenilir tahminler yapmasını sağlamaktadır.

4.2 Makine Öğrenmesi Algoritma Seçimi

Bu çalışmada, beş farklı sınıflandırma algoritmasının performansları karşılaştırılmıştır: Karar Ağaçları (Decision Tree), Rastgele Orman (Random Forest), Lojistik Regresyon (Logistic Regression), Destek Vektör Makineleri (SVM) ve K-En Yakın Komşu (KNN). Her bir modelin doğruluk skorları, Çizelge 4.7’de özetlenmiştir:


Çizelge 4.7: Sınıflandırma algoritma performansları.

Algoritma	Doğruluk Oranı (%)
Rastgele Orman	90.12
Karar Ağaçları	89.65
Lojistik Regresyon	54.59
Destek Vektör Makineleri	50.23
K-En Yakın Komşu	44.24

Karar Ağaçları ve Rastgele Orman algoritmalarının, incelenen veri setinde önemli ölçüde yüksek doğruluk oranlarına ulaştığını göstermektedir. Bu durum, bu iki yöntemin veri setindeki özelliklerin karmaşıklığını ve özellikler arası etkileşimleri etkili bir şekilde yakalayabildiğini işaret etmektedir. Özellikle, Rastgele Orman algoritması birden fazla karar ağacının tahminlerini birleştirerek varyansı azaltır ve genel olarak tek bir Karar Ağacına göre daha iyi genelleme performansı sunar.

Diğer taraftan, Lojistik Regresyon, SVM ve KNN algoritmalarının daha düşük doğruluk oranlarına ulaşması, bu yöntemlerin veri setindeki karmaşık yapıları modellemekte zorlandıklarını göstermektedir. Lojistik Regresyonun doğrusal bir model olması, veri setindeki doğrusal olmayan ilişkilerin yakalanmasında sınırlılıklar oluşturabilir. SVM, doğru çekirdek fonksiyonunun (kernel) ve parametrelerin seçimiyle önemli ölçüde performans artışı sağlayabilir, ancak bu çalışmada basit bir SVM modeli ile sınırlı kalmıştır. KNN algoritması ise, büyük ölçekli veri setlerinde ve yüksek boyutlu özellik uzaylarında etkinliğini yitirebilir, ayrıca komşu sayısının (k değeri) seçimi de model performansını doğrudan etkiler.

Bu analizler sonucunda model eğitimi için Rastgele Orman Sınıflandırması (Random Forest Classifier) algoritması kullanılmıştır. Bu algoritma, birden fazla karar ağacını kullanarak tahmin yapma yeteneğine sahiptir ve hem sınıflandırma hem de regresyon problemlerinde etkili sonuçlar vermektedir.



Şekil 4.2: Rastgele orman algoritması akış şeması.

Şekil 4.2’de akışı özetlenen algoritmanın seçilmesindeki temel neden, genellikle yüksek doğruluk oranları sunması ve aşırı öğrenmeye karşı dirençli olmasıdır.

Rastgele Ormanın seçilme nedenleri aşağıda belirtilmiştir;

Genelleştirme Kabiliyeti: Rastgele Orman, tek bir karar ağacının aksine, çok sayıda karar ağacının tahminlerini birleştirerek çalışır. Bu yaklaşım, modelin genelleştirme kabiliyetini artırır ve aşırı öğrenme riskini azaltır. Her bir karar ağacı, veri setinin rastgele alt kümeleri üzerinde eğitilir, bu da modelin farklı veri yapılarını öğrenmesine ve daha güçlü bir model oluşturmaya olanak tanır.

Değişkenlerin Öneminin Belirlenmesi: Rastgele Orman, her bir özneliliğin modelin tahmin performansına katkısını değerlendirme imkânı sunar. Bu özellik, hangi değişkenlerin model için en bilgilendirici olduğunu belirlemede önemli bir araçtır ve tez çalışmasının analitik kısmına derinlemesine bir bakış açısı sağlar.

Esneklik: Rastgele Orman hem kategorik hem de sayısal verilerle iyi çalışabilen esnek bir yapıya sahiptir. Bu özellik, tez çalışmasında kullanılan veri setinin çeşitli türdeki verileri içermesi durumunda büyük bir avantaj sağlar.

Parametre Ayarlarının Kolaylığı: Rastgele Orman algoritması, az sayıda hiper parametre ayarı gerektirir ve bu parametrelerin model üzerindeki etkisi nispeten anlaşılabilir. Örneğin, ağaç sayısı ($n_{estimators}$) ve ağaç derinliği gibi parametreler, modelin karmaşıklığını ve performansını doğrudan etkiler.

Yüksek Performans: Çok sayıda karar ağacının tahminlerini birleştirerek, Rastgele Orman, tek bir karar ağacına kıyasla genellikle daha yüksek doğruluk ve performans sunar. Bu, modelin karmaşık veri setlerinde ve çeşitli problem türlerinde etkili olmasını sağlar.

4.3 Form Tasarımı ve Geliştirme Süreci

Bu bölümde, baskı çoğaltma endüstrisi için özelleştirilmiş tekliflendirme robotunun geliştirilmesinde kritik bir adım olan kullanıcı arayüzü formunun tasarımı ele alınmıştır. Ana hedef, endüstriyel gereksinimleri ve kullanıcı beklentilerini karşılayacak, veri odaklı bir karar destek sistemine veri girişi sağlayacak bir web tabanlı form oluşturmaktır. Şekil 4.3'te gösterilen form, müşterilerin ve potansiyel kullanıcıların, tekliflendirme robotu tarafından işlenecek spesifik verileri girmelerini sağlayacak şekilde tasarlanmıştır.

Bu tasarım süreci, kullanıcıların kolaylıkla naviga edebilecekleri, anlaşılır ve etkileşimli bir arayüz oluşturmaya amaçlar. Her bir girdi alanı, kullanıcının ihtiyaç ve tercihlerine uygun özelleştirilmiş teklifler üretmek için tasarlanmıştır. Tasarlanan bu form, <http://beta.kopitek.com.tr/> adresinde konumlandırılarak, potansiyel müşterilerin ve mevcut kullanıcıların teklif talebinde bulunmalarını sağlamaktadır.

Ayrıca web tabanlı tekliflendirme sisteminin etkin yönetimi için, bir admin paneli de geliştirilmiştir. Bu panel, sistem yöneticilerinin kullanıcı verileri ve etkileşimleri üzerinde tam kontrol sahibi olmalarını sağlar. Admin paneli, kullanıcı dostu bir arayüzle, veri izleme ve yönetim işlemlerini kolaylaştıracak şekilde tasarlanmıştır.

Panel, <http://api2.kopitek.com.tr:8081/api/customers/> adresindeki API ile entegre edilmiştir ve panelin sistemin diğer bileşenleriyle sürekli olarak senkronize olmasını sağlar. Böylece, veri tutarlılığı ve güncelliği korunur.

Teklif Talep Formu

Firma Ünvanı

Firma Ünvanı

Yetkili İsmi

Yetkili İsmi

Email

Yetkili mail adresini giriniz.

Telefon Numarası

Telefon numarasını giriniz.

Firma Lokasyonu:

Çoklu Lokasyon:

☐ Evet

☐ Hayır

Sektör:

Çalışan Sayısı:

Baskı Türü:

☐ Renkli & Siyah/Beyaz

☐ Yalnızca Siyah/Beyaz

Kağıt Türü:

☐ A3 & A4

☐ Yalnızca A4

☐ Diğer

Baskı Hacmi

Aylık Baskı Hacminizi Giriniz

Cihaz Türü

☐ MFP

☐ SFP

Gönder

Şekil 4.3: Teklif talep formu.

4.4 Makine Öğrenmesi ve Karar Destek Sisteminin Oluşturulması

Öncelikle, Python'un geniş kütüphane ekosistemi, araştırmacıların ve geliştiricilerin çeşitli veri analizi, işleme ve modelleme görevlerini kolayca gerçekleştirmelerine olanak tanınması nedeniyle uygulama kısmında Python kullanılmıştır. Örneğin, pandas ve NumPy gibi kütüphaneler veri manipülasyonu ve sayısal hesaplamalar için güçlü araçlar sunarken, scikit-learn makine öğrenimi modellerinin hızlı bir şekilde eğitilmesi ve değerlendirilmesi için geniş bir altyapı sağlar.

Python, aynı zamanda yüksek seviyeli ve yorumlanabilir bir programlama dili olması sebebiyle kullanıcı dostudur. Bu özellikler, kodun okunabilirliğini ve bakımını kolaylaştırır, bu da geliştirme sürecini hızlandırır ve daha az hata yapılmasını sağlar. Python'un basit yapısı, özellikle veri bilimi ve makine öğrenmesi alanında çalışanlar için öğrenmesi kolay bir dil olmasını sağlar.

Makine öğrenmesi ve karar destek sistemlerinin geliştirilmesi sürecinde, farklı veri kaynaklarından veri toplama ve entegrasyon ihtiyacı sıkça karşılaşılan bir durumdur. Python, requests gibi kütüphaneleri aracılığıyla web API'lerinden veri çekme ve openpyxl gibi kütüphanelerle Excel dosyaları gibi çeşitli veri formatlarıyla çalışma imkânı sunar. Bu özellikler, Python'u gerçek dünya verileri üzerinde çalışan uygulamalar için de ideal bir seçim haline getirir.

Son olarak, Python'un geniş ve aktif bir kullanıcı topluluğa sahip olması, dilin sürekli olarak geliştirilmesine ve desteklenmesine katkıda bulunur. Bu topluluk, yeni başlayanlardan deneyimli profesyonellere kadar her seviyeden kullanıcıya yardımcı olabilecek zengin bir bilgi kaynağı ve destek ağı sunar. Bu topluluk desteği, Python'u makine öğrenmesi ve karar destek sistemleri gibi alanlarda yenilikçi ve etkili çözümler geliştirmek için tercih edilen bir dil haline getirir.

Bu nedenlerle, Python, makine öğrenmesi ve karar destek sistemleri geliştirme sürecinde esneklik, erişilebilirlik ve güçlü bir destek ağı sunan bir programlama dili olarak öne çıkar. Bu özellikler, Python'u bu tür projeler için popüler ve etkili bir seçenek yapar ve bu tezde de Python programlama dili kullanılmıştır.

4.4.1 Veri setinin hazırlanması ve ön işleme

Makine öğrenimi modelinin geliştirilme sürecinde, 8600 adet müşteri bilgisinin bulunduğu veri setinin Python programlama dili aracılığıyla yüklenmesi ilk adımı

teşkil etmektedir. Bu süreç, pandas kütüphanesinin `read_excel` fonksiyonu kullanılarak gerçekleştirilmiştir. Pandas, veri analizi ve manipülasyonu için geniş kabul görmüş bir kütüphanedir ve bu çalışmada, veri setinin etkin bir şekilde işlenmesi amacıyla tercih edilmiştir. İlgili komut, belirtilen dosya yolundaki Excel dosyasını, analiz ve işleme işlemlerinin kolaylıkla gerçekleştirilebilmesini sağlayan bir pandas DataFrame'ine dönüştürmektedir.

Veri setinin yüklenmesi ve ilk incelemesi sonrasında, veri ön işleme adımlarına geçilmiştir. Bu süreç, modelin eğitime hazırlık olarak kritik önem taşır ve veri setindeki kategorik verilerin sayısal formata dönüştürülmesini, eksik değerlerin işlenmesini ve veri setinin eğitim ve test setlerine ayrılmasını içerir.

Veri setinde yer alan kategorik veriler, makine öğrenimi algoritmalarının gereksinimleri doğrultusunda sayısal formata dönüştürülmüştür. Bu dönüşüm, `LabelEncoder` sınıfı kullanılarak gerçekleştirilmiştir. `LabelEncoder`, kategorik verileri modele uygun sayısal değerlere çevirerek, algoritmanın veri seti üzerinde çalışabilmesini sağlar. Her bir kategorik sütun için bu dönüşüm işlemi uygulanmış ve böylece veri seti, modelin işleyebileceği bir forma getirilmiştir.

Veri setindeki her bir kategorik sütunu (dtype'ı 'object' olan sütunlar) dönüştürmek için bir döngü kullanılmaktadır. Her bir sütun için bir `LabelEncoder` örneği oluşturulur ve sütun üzerinde `fit_transform` metodu uygulanarak kategorik değerler sayısal değerlere çevrilir. Bu işlem sonucunda, her bir kategorik sütun için eşleştirme bilgileri bir sözlükte saklanır, bu da ileride bu dönüşüm işleminin tersinin yapılmasına olanak tanır.

Modelin eğitimi ve testi için veri seti, bağımsız değişkenler (özellikler) ve bağımlı değişken (hedef) olarak ayrılmıştır. Bu çalışmada hedef değişken, 'Model' sütunu olarak belirlenmiş ve özellikler ise bu sütun dışındaki diğer sütunlardan oluşmuştur.

Bu aşamada, `drop` metodu 'Model' sütununu veri setinden çıkarmak için kullanılarak bağımsız değişkenlerin matrisi (x) oluşturulmuş, 'Model' sütunu ise bağımlı değişken vektörü (y) olarak ayrılmıştır.

Veri setinin eğitim ve test setlerine ayrılması, modelin performansının değerlendirilmesi ve genelleştirilebilirliğinin test edilmesi açısından önemlidir. Bu ayırım, `train_test_split` fonksiyonu kullanılarak gerçekleştirilmiştir.

Veri seti rastgele eğitim ve test setlerine ayrılır. `test_size` parametresi, veri setinin yüzde kaçının test seti olarak ayrılacağını belirlerken, `random_state` parametresi, bu ayrımın her seferinde aynı şekilde gerçekleşmesini sağlar.

Bu adımlar, makine öğrenimi modelinin eğitilmesi için veri setinin hazırlanması sürecini tamamlar ve model eğitimi aşamasına geçişi sağlar. Veri ön işleme sürecinin titizlikle yürütülmesi, modelin başarısı için temel bir ön koşuldur. Bu aşamalar, veri setinin model tarafından etkin bir şekilde işlenmesini ve analiz edilmesini sağlar, böylece modelin eğitimi ve sonuçların değerlendirilmesi daha sağlıklı bir şekilde gerçekleştirilebilir.

Veri setinin hazırlanması ve ön işleme adımlarının tamamlanmasının ardından, model eğitimi sürecine geçilmiştir.

4.4.2 Modelin eğitimi ve değerlendirilmesi

Modelin eğitiminde `RandomForestClassifier` sınıfından bir örnek oluşturulmuş ve `n_estimators` parametresi 100 olarak belirlenmiştir. Bu parametre, modelin kullanacağı karar ağaçlarının sayısını ifade eder. `Random_state` parametresi ise, modelin her seferinde aynı sonuçları üretmesini sağlamak için kullanılmıştır. Model, ölçeklendirilmiş eğitim verileri (`X_train_scaled`) ve eğitim etiketleri (`y_train`) kullanılarak eğitilmiştir. Ölçeklendirme işlemi, `StandardScaler` kullanılarak gerçekleştirilmiş ve modelin daha iyi performans göstermesi sağlanmıştır. Modelin eğitilmesinin ardından, test seti üzerinde tahminlerde bulunulmuş ve modelin performansı değerlendirilmiştir.

Veri seti büyüklüğü, eğitim ve test setlerinin belirlenmesinde önemli bir faktördür. Küçük veri setleri, sınırlı sayıda veri noktası içerdiğinden, daha büyük bir test seti (örneğin %30-40) modelin gerçek dünya performansını daha iyi temsil edebilir. Ancak bu durum, eğitim verisinin miktarını azaltarak modelin öğrenme kapasitesini düşürebilir. Büyük veri setlerinde ise, daha küçük bir test seti (örneğin %10-20) güvenilir bir performans tahmini sağlarken, yeterli miktarda eğitim verisi bırakır. Bu çalışmada kullanılan veri seti, yeterli büyüklükte olduğundan, %80 eğitim ve %20 test oranı optimal bir denge sağlamaktadır. Bu oran, modelin eğitimi için yeterli veri sağlarken, modelin genel performansını değerlendirmek için de yeterli veri bırakmaktadır (Sammut ve Webb, 2010; Goodfellow, Bengio ve Courville, 2016).

Farklı veri bölünme oranlarının model doğruluğuna etkisini değerlendirmek amacıyla, 80-20 bölünmesi dışında 90-10, 70-30, 60-40, 50-50, 40-60 ve 30-70 bölünmeleri de incelenmiştir. Elde edilen doğruluk oranları Çizelge 4.8’de gösterilmiştir.

Çizelge 4.8: Bölünme doğruluk oranı.

Bölünme Oranı (Eğitim-Test)	Doğruluk Oranı (%)
90-10 Bölünmesi	90.35
80-20 Bölünmesi	90.64
70-30 Bölünmesi	89.81
60-40 Bölünmesi	90.23
50-50 Bölünmesi	90.49
40-60 Bölünmesi	90.02
30-70 Bölünmesi	89.44

Doğruluk oranları incelendiğinde, %80 eğitim ve %20 test oranının, modelin en yüksek doğruluğa yakın performans gösterdiği oranlardan biri olduğu görülmektedir. Bu oran, hem modelin eğitim verisi üzerinde iyi performans göstermesi hem de genelleme kapasitesinin yüksek olması açısından optimal bir denge sağlamaktadır. Bu nedenle, %80 eğitim ve %20 test oranı, model performansını değerlendirmek için en uygun oran olarak seçilmiştir.

Sonuç olarak, bu çalışmada %80 eğitim ve %20 test oranının seçilmesi, veri seti büyüklüğü, model karmaşıklığı, değerlendirme kararlılığı ve güvenilirlik gibi faktörler göz önünde bulundurularak optimal bir denge sağladığı için tercih edilmiştir. Bu oran, modelin genelleme kapasitesini artırırken, performans değerlendirmesinin kararlılığını ve güvenilirliğini sağlamaktadır. Çalışmanın sonuçları, model performansının yüksek olduğunu ve seçilen veri bölünme oranının uygun olduğunu göstermektedir.

Belirlenen veri seti ile eğitilen model (rf), test seti üzerindeki ölçeklendirilmiş özellikler (X_{test_scaled}) kullanılarak tahminlerde bulunur. Ardından, `accuracy_score` fonksiyonu ile modelin doğruluk skoru hesaplanır. Bu skor, modelin test setindeki gözlemleri ne kadar doğru sınıflandırdığının bir göstergesidir ve modelin genelleştirilebilirliği hakkında önemli bilgiler sunar. Modelin yüksek bir doğruluk skoru elde etmesi, seçilen algoritmanın ve ön işleme adımlarının doğru bir şekilde uygulandığının bir işaretidir.

Sonuç olarak, bu aşamalar makine öğrenimi modelinin başarılı bir şekilde eğitilmesini ve test edilmesini sağlar. Modelin eğitimi, ön işleme adımlarının dikkatli bir şekilde gerçekleştirilmesi ve model parametrelerinin doğru bir şekilde ayarlanması sayesinde, tez çalışmasının hedeflerine ulaşılmasında kritik bir rol oynar. Modelin test seti üzerindeki değerlendirilmesi ise, modelin genelleştirilebilirliği ve pratik uygulamalardaki potansiyel başarısını ortaya koyar.

4.4.3 Müşteri verileri ile modelin uygulanması

Makine öğrenimi modelinin müşteri verileri üzerinde uygulanması süreci, öncelikle belirlenen bir API'den alınan müşteri firma bilgilerinin çekilmesiyle başlar. Bu aşama, requests kütüphanesi kullanılarak bir HTTP GET isteği gerçekleştirilerek ve elde edilen yanıtın JSON formatındaki verilerini içeren bir yanıtın alınmasıyla gerçekleşir. Elde edilen bu veri, tez çalışmasının ilgili bölümünde incelenmek üzere bir pandas DataFrame'ine dönüştürülür.

Bu işlem, API üzerinden elde edilen verilerin analiz ve modelleme sürecine hazır hale getirilmesini sağlar. Ardından, bu DataFrame içerisinden modelin tahmin yapması için gerekli olan sütunlar seçilir. Bu sütunlar, lokasyon (location), sektör (sector), çalışan sayısı (employee), baskı tipi (printype), kağıt boyutu (papersize), hacim (volume) ve çok fonksiyonlu yazıcı varlığı (mfp) gibi özellikleri içerir.

Elde edilen test verisi DataFrame'i üzerinde, modelin eğitimi sırasında uygulanan aynı veri ön işleme adımları tekrarlanır. Bu adımlar, kategorik verilerin sayısal verilere dönüştürülmesini ve özelliklerin ölçeklendirilmesini içerir. Kategorik verilerin sayısal değerlere dönüştürülmesi, modelin eğitim aşamasında kullanılan LabelEncoder nesneleri aracılığıyla gerçekleştirilir. Bu işlem, modelin kategorik veriler üzerinde doğrudan işlem yapamayacağı için gereklidir ve sayısal değerler modelin anlayabileceği bir forma dönüştürülür.

Test verisinin özellikleri, modelin eğitimi sırasında kullanılan aynı StandardScaler nesnesi ile ölçeklendirilir. Bu ölçeklendirme işlemi, modelin daha iyi tahminler yapabilmesi için gerekli olan verilerin standart bir formatta olmasını sağlar.

Bu ön işleme adımlarının tamamlanmasının ardından, ölçeklendirilmiş test verisi üzerinde Rastgele Orman modeli kullanılarak tahminlerde bulunulur. Modelin ürettiği tahminler, daha önce LabelEncoder ile sayısal değerlere dönüştürülmüş kategorik değişkenlerin orijinal kategorik değerlerine dönüştürülmesiyle anlaşılır hale getirilir.

Bu süreç, makine öğrenimi modelinin gerçek dünya verileri üzerinde nasıl uygulandığını ve elde edilen tahminlerin nasıl işlendiğini detaylı bir şekilde ortaya koymaktadır. Modelin tahmin kabiliyetinin gerçek dünya senaryolarında test edilmesi, tez çalışmasının uygulamalı yönünü güçlendirir ve modelin pratikteki etkinliğini değerlendirme fırsatı sunar. Bu, modelin gerçek dünya koşullarında karşılaşılabilecek çeşitli durumlar için ne kadar uygun olduğunu anlamak açısından önemlidir.

4.4.3 Stok kontrolü ve alternatif ürünlerin değerlendirilmesi

Bu bölümde, makine öğrenimi modeli tarafından yapılan tahminlerin, firma stok verisinde yer alan ürün bilgileri ile eşleştirilmesi ve bu bilgilerin analizi süreci anlatılmaktadır. Bu işlem, tahmin edilen ürün modelinin gerçek dünya uygulamalarında kullanımını simüle eder ve modelin karar destek sistemlerine nasıl entegre edilebileceğini gösterir.

İlk adımda, ürünler listesi pandas kütüphanesi kullanılarak yüklenir. Bu dosya, ürünlerin model isimleri, alış fiyatları ve stok durumları gibi önemli bilgileri içerir. Daha sonra, makine öğrenimi modeli tarafından tahmin edilen model ismi, bu DataFrame içerisinde sorgulanır. Eğer tahmin edilen model ismi DataFrame'de bulunursa, ilgili ürünün alış fiyatı elde edilir ve ekrana yazdırılır. Bu işlem, modelin tahmin ettiği ürünün piyasa bilgilerine nasıl erişilebileceğini gösterir.

Model tarafından yapılan tahminler, yalnızca bir ürünün tahmin edilmesiyle sınırlı kalmaz. Model, sınıflandırma olasılıklarını da hesaplar ve bu olasılıklar, ürünlerin stok durumlarına göre değerlendirilir. Her bir tahmin için, en yüksek olasılığa sahip ürünlerden başlanarak stok durumları kontrol edilir. Eğer bir ürün stokta varsa, ürünün model ismi, alış fiyatı ve stok miktarı ekrana yazdırılır. Bu, stokta olmayan bir ürün için alternatif seçeneklerin nasıl değerlendirilebileceğini gösterir.

Bu değerlendirme sürecinde, eğer tahmin edilen model veya alternatif modellerden biri stokta mevcut değilse, yani stok miktarı sıfır ise, bu durum işletme için önemli bir bilgidir. Stokta mevcut olmayan ürünler için, sistem "Stokta uygun alternatif bulunamadı." mesajını vererek, işletmenin talep edilen ürünün mevcut olmadığına dair bilgilendirilmesini sağlar. Bu, işletmenin alternatif ürün önerileri sunması veya stok yönetimini gözden geçirmesi için bir fırsat sunar.

Bu geliştirme, stokta uygun bir alternatifin bulunamadığı durumlar için işletmeyi uyarır. Stokta mevcut olmayan bir ürünün tespit edilmesi, işletmenin stok yönetimi

stratejilerini yeniden değerlendirmesine ve müşteri taleplerini karşılamak için gerekli önlemleri almasına olanak tanır. Bu durum, aynı zamanda, işletmenin tedarik zinciri yönetimini optimize etmesi ve müşteri memnuniyetini artırıcı adımlar atması için bir teşvik oluşturur.

Sonuç olarak, bu süreç, makine öğrenimi modelinin sadece ürün tahminleri yapmakla kalmayıp, aynı zamanda işletmenin stok durumunu etkin bir şekilde yönetmesine ve müşteri taleplerine daha hızlı ve etkili bir şekilde yanıt vermesine yardımcı olduğunu gösterir. Stokta mevcut olmayan ürünler için yapılan uyarılar, işletmenin operasyonel verimliliğini ve müşteri hizmeti kalitesini artırmasına katkıda bulunur.

4.5 Model Değerlendirme ve Validasyon

Modelin performansı, test seti üzerindeki doğruluk skoru ile değerlendirilmiştir. Ayrıca, modelin genelleştirme kabiliyetini ve kararlılığını değerlendirmek için 5 katlı çapraz doğrulama yöntemi kullanılmıştır. Çapraz doğrulama, modelin farklı veri alt kümeleri üzerinde nasıl performans gösterdiğini göstererek, modelin eğitim setine aşırı uyum sağlama riskini azaltmaktadır.

Karışıklık matrisi ve sınıflandırma raporu, modelin sınıf bazında performansını detaylı bir şekilde analiz etmek için kullanılmıştır. Bu analizler, modelin her bir sınıfı ne kadar doğru sınıflandırdığını, hangi sınıflar arasında karışıklıkların olduğunu ve modelin hassasiyet, geri çağırma, F1 skoru gibi önemli metriklerle nasıl performans gösterdiğini ortaya koymaktadır.

4.5.1 Çapraz doğrulama

Modelin genelleştirme kabiliyetini ve kararlılığını kapsamlı bir şekilde test etmek amacıyla 5 katlı çapraz doğrulama yöntemi uygulanmıştır.

İlk adımda, ölçeklendirilmiş özelliklerden oluşan `X_train_scaled` ve hedef değişken `y_train` veri seti, 5 eşit boyutta alt kümeye bölünmüştür. Bu bölünme işlemi, her bir alt kümenin model tarafından hem eğitim hem de test amaçlı kullanılabilmesi için rastgele bir şekilde gerçekleştirilmiştir.

Her bir iterasyonda, 5 alt kümeden biri test seti olarak ayrılmış, kalan 4 alt küme ise modelin eğitimi için kullanılmıştır. Bu işlem, her bir alt kümenin tam olarak bir kez test seti olarak kullanılacağı şekilde 5 kez tekrarlanmıştır. Her tekrarda, Rastgele

Ormanlar modeli eğitim seti üzerinde eğitilmiş ve ayrılan test seti üzerindeki performansı değerlendirilmiştir.


Her bir iterasyondaki test seti üzerindeki performans skoru kaydedilmiş ve bu skorlar, modelin farklı veri alt kümeleri üzerindeki genel performansının bir göstergesi olarak kullanılmıştır.

Bu çalışmanın uygulama bölümünde elde edilen sonuçlar, modelin sınıflandırma problemi üzerindeki etkinliğini göstermektedir. Öncelikle, modelin test seti üzerindeki doğruluk skoru %90.12 olarak hesaplanmıştır. Bu skor, modelin test verileri üzerinde yaptığı tahminlerin yüksek bir yüzdesinin doğru olduğunu göstermektedir ve modelin genel performansının güçlü olduğuna işaret etmektedir.

Daha detaylı bir değerlendirme için uygulanan 5 katlı çapraz doğrulama yöntemi, modelin farklı veri alt kümeleri üzerindeki performansını daha kapsamlı bir şekilde test edilmesine olanak tanımıştır. Şekil 4.4'te çapraz doğrulama skorları sırasıyla %90.116, %90.262, %91.206, %89.753, ve %89.826 olarak elde edilmiştir. Bu skorlar, modelin farklı veri alt kümeleri üzerinde tutarlı ve yüksek bir performans sergilediğini göstermektedir.

Elde edilen çapraz doğrulama skorlarının ortalaması %90.23 olarak hesaplanmıştır. Bu ortalama skor, modelin genel olarak yüksek bir genelleştirme kabiliyetine sahip olduğunu ve farklı veri dağılımlarına iyi bir şekilde uyum sağlayabildiğini göstermektedir. Skorların nispeten dar bir aralıkta olması, modelin kararlı olduğunu ve farklı veri setleri üzerinde tutarlı bir şekilde yüksek performans sergileyebileceğini işaret etmektedir.

Bu sonuçlar, geliştirilen Rastgele Orman modelinin, ele alınan sınıflandırma problemi için etkili ve güvenilir bir çözüm sunduğunu göstermektedir. Modelin yüksek doğruluk skoru ve çapraz doğrulama sonuçları, modelin pratik uygulamalarda başarılı bir şekilde kullanılabileceğini ve farklı veri setleri üzerinde iyi bir genelleştirme performansı gösterebileceğini öne sürmektedir. Bu bulgular, modelin daha ileri analizler ve optimizasyonlar için sağlam bir temel oluşturduğunu ve gerçek veriler üzerindeki potansiyel uygulamaları için umut verici olduğunu göstermektedir.



Şekil 4.4: Çapraz doğrulama skoru.

4.5.2 Karışıklık matrisi ve sınıflandırma raporu

Karışıklık matrisi ve sınıflandırma raporu, modelin sınıflandırma performansının derinlemesine incelenmesinde kullanılan iki temel araçtır. Bu çalışmada elde edilen karışıklık matrisi ve sınıflandırma raporu, modelin her bir sınıfı ne kadar doğru tahmin ettiğini ve hatalı tahminlerin detaylarını göstermektedir.


Şekil 4.5'te gösterilen karışıklık matrisi, modelin tahminlerinin gerçek değerlerle karşılaştırılmasıyla oluşturulmuştur. Matrisin satırları gerçek sınıfları, sütunları ise modelin tahmin ettiği sınıfları temsil etmektedir. Diyagonal üzerindeki değerler doğru tahminleri, diğer hücreler ise çeşitli türdeki hatalı tahminleri (yanlış pozitifler ve yanlış negatifler) göstermektedir. Bu çalışmada elde edilen karışıklık matrisi, modelin çoğu sınıfı yüksek doğrulukla tahmin ettiğini, ancak bazı sınıflar arasında karışıklıkların olduğunu göstermektedir. Bu karışıklıkların analizi, modelin iyileştirilmesi için potansiyel alanların belirlenmesine yardımcı olmuştur.

Örneğin, 0 numaralı sınıfta model 44 doğru tahmin yapmış ve 8 yanlış pozitif tahminde bulunmuştur. 2, 3, 4 ve 5 numaralı sınıflar için model tüm tahminleri doğru yapmıştır, bu sınıflarda yanlış pozitif veya yanlış negatif gözlenmemiştir. Bu durum, modelin bu sınıfları mükemmel bir şekilde sınıflandırdığını gösterir.

Diğer yandan, 24 numaralı sınıf için model 21 doğru tahmin yapmış ve 12 yanlış negatif (yanlış olarak negatif sınıflandırılmış) tahminde bulunmuştur, bu da modelin

bu sınıftaki örnekleri yeterince iyi sınıflandıramadığını gösterir. Bu durum, modelin bu sınıfta gerçekleştirdiği tahminlerin daha iyileştirilmesi gerektiğine işaret eder.

Şekil 4.5'te oluşan matris, modelin bazı sınıflar için iyileştirme ihtiyacı olduğunu açıkça ortaya koyar. Modelin performansını artırmak için, daha fazla veri toplama, özellik mühendisliği veya model hiper parametrelerinin ayarlanması gibi stratejiler geliştirilebilir. Özellikle yanlış negatif ve yanlış pozitif değerleri yüksek olan sınıflar üzerinde odaklanarak, bu sınıfların doğru bir şekilde sınıflandırılması için ek adımlar atılabilir. Bu analizler, spesifik sınıflarda model performansını artırmak için alınacak eylemleri belirleme noktasında değerli içgörüler sunmaktadır.



Şekil 4.5: Karışıklık matrisi.

Çizelge 4.9'da oluşturulan sınıflandırma raporu, modelin her bir sınıf için hesaplanan hassasiyet (precision), duyarlılık (recall), ve F1 skoru gibi önemli metrikleri içermektedir. Hassasiyet, modelin bir sınıfı pozitif olarak tahmin ettiğinde ne kadar sıklıkla doğru olduğunu gösterirken, geri çağırma modelin gerçek pozitifleri ne kadar iyi tespit ettiğini göstermektedir. F1 skoru ise hassasiyet ve geri çağırmanın dengeli

bir ölçüsüdür. Bu çalışmada elde edilen sınıflandırma raporu, modelin çoğu sınıfta yüksek hassasiyet ve geri çağırma değerlerine ulaştığını göstermektedir. Ancak, bazı sınıfların düşük geri çağırma veya hassasiyet skorlarına sahip olduğu görülmüştür, bu da bu sınıfların model tarafından daha zor ayırt edildiğini göstermektedir.

Çizelge 4.9: Sınıflandırma raporu

	Precision	Recall	F1- score	support
0	0.90	0.85	0.87	52
1	0.74	0.74	0.74	43
2	1.00	1.00	1.00	42
3	1.00	1.00	1.00	47
4	1.00	1.00	1.00	39
5	1.00	1.00	1.00	44
6	1.00	1.00	1.00	35
7	0.95	0.97	0.96	36
8	0.87	0.90	0.88	51
9	1.00	1.00	1.00	41
10	0.74	0.67	0.70	42
11	0.55	0.46	0.50	37
12	0.39	0.48	0.43	27
13	1.00	1.00	1.00	31
14	1.00	1.00	1.00	39
15	0.67	0.74	0.70	38
16	1.00	1.00	1.00	36
17	1.00	1.00	1.00	27
18	1.00	1.00	1.00	48
19	1.00	1.00	1.00	46
20	1.00	1.00	1.00	35
21	1.00	1.00	1.00	35
22	1.00	1.00	1.00	41
23	1.00	1.00	1.00	35
24	0.38	0.64	0.47	33
25	1.00	1.00	1.00	36
26	1.00	0.98	0.99	43
27	0.98	1.00	0.99	47
28	1.00	1.00	1.00	37
29	1.00	1.00	1.00	49
30	0.40	0.49	0.44	37
31	1.00	1.00	1.00	45
32	0.51	0.43	0.47	47
33	1.00	1.00	1.00	20
34	1.00	1.00	1.00	31
35	1.00	1.00	1.00	33
36	1.00	1.00	1.00	43
37	1.00	1.00	1.00	49
38	1.00	1.00	1.00	37
39	1.00	1.00	1.00	39
40	0.98	0.98	0.98	51
41	0.64	0.38	0.47	56
42	1.00	1.00	1.00	40
Accuracy			0.90	1.720
Macro avg	0.90	0.90	0.90	1720
Weighted avg	0.90	0.90	0.90	1720

Her sınıf için hassasiyet (precision), duyarlılık (recall) ve F1 skoru incelendiğinde, modelin çoğu sınıfta mükemmel performans sergilediği; yüksek hassasiyet, geri çağırma ve F1 skorlarına ulaştığı görülmektedir. Örneğin, sınıflar 2'den 6'ya ve 13'ten 23'e kadar olan sınıflar için hem hassasiyet hem de geri çağırma %100'dür, bu da modelin bu sınıflardaki örnekleri mükemmel bir şekilde sınıflandırdığını göstermektedir.

Sınıf 0, 0.90 hassasiyet ve 0.85 geri çağırma ile oldukça iyi performans göstermiş, ancak bazı yanlış negatiflerin olduğuna işaret etmektedir. Benzer şekilde, sınıf 8 için de hassasiyet ve geri çağırma oranları yüksektir (%0.87 ve %0.90), bu da modelin bu sınıftaki örnekleri nispeten doğru bir şekilde sınıflandırdığını gösterir.


Buna karşılık, sınıf 11, 12 ve 24 için hem hassasiyet hem de geri çağırma değerleri nispeten düşüktür. Özellikle sınıf 24 için hassasiyet %38, geri çağırma ise %64'tür, bu da modelin bu sınıfa ait birçok örneği yanlış negatif olarak sınıflandırdığını ve hassasiyetin düşük olduğunu göstermektedir. Bu durum, modelin bu sınıflardaki örnekleri doğru bir şekilde sınıflandırmakta zorlandığını ve iyileştirme gerektiğini belirtir.

Genel olarak, modelin doğruluğu %90 olarak rapor edilmiştir, bu da modelin toplamda yüksek bir başarı oranına sahip olduğunu gösterir. Makro ve ağırlıklı ortalama skorlar da %90'dır, bu da modelin tüm sınıflar üzerinde dengeli bir performansa sahip olduğunu ve tüm sınıfların model performansına eşit ağırlıkta katkıda bulunduğunu gösterir.

4.7 Kullanıcı Tekliflendirme Arayüzü

Çalışmadan elde edilen model ve veriler doğrultusunda baskı çoğaltma endüstrisine özel dinamik tekliflendirme ve cihaz yönetimi stratejilerinin uygulanabilmesi için bir kullanıcı arayüzü tasarlanmıştır. Tasarlanan kullanıcı arayüzü, kullanıcılara özelleştirilmiş teklifler sunarken, aynı zamanda müşteri ihtiyaçlarına ve piyasa dinamiklerine uygun şekilde en uygun cihaz seçimlerini yapabilmelerine olanak tanır. Şekil 4.6'da gösterilen arayüz sade ve anlaşılır bir tasarıma sahiptir ve firmalara kullanıcı dostu bir deneyim sunmayı hedefler.

Arayüzün çalışma mekanizması, müşterinin temel veri girişinden başlayarak, makine öğrenimi destekli model seçimi ve dinamik fiyatlandırma süreçlerini kapsayan bir dizi işlemi içerir.



Şekil 4.6: Kullanıcı tekliflendirme arayüzü.


İlk adımda müşteri, firmanın web sitesi üzerinden geliştirilen teklif talep formunu kullanarak işletme adı, iletişim bilgileri, baskı tercihleri (MFP, Renkli / Renksiz, A3 /A4 vs.) gibi çeşitli parametreleri girer. Bu veriler, daha sonra işlem ve analiz için arayüze iletilir.

Müşterinin girdiği veriler doğrultusunda uygun model seçimi için tercih edilen makine öğrenimi algoritması devreye girer. Model, stok durumunu, cihaz özelliklerini ve müşteri ihtiyaçlarını değerlendirerek en uygun cihazı ve alternatifleri önerir. Fiyat teklifleri, cihazın satın alma maliyeti, diğer ek maliyetler, kullanım süresi ve stok durumu gibi dinamik parametrelere dayanarak hesaplanır.

Hesaplanan teklif, kullanıcı arayüzüne geri döndürülerek firmanın ya da satış temsilcisinin incelemesine sunulur. Yetkili kişi teklifi inceleyebilir, kabul edebilir veya revizyon gerçekleştirebilir.

Her teklif otomatik olarak kaydedilir, böylece firma yetkilileri tarih bilgisiyle birlikte geçmiş teklifleri görüntüleyebilir ve değerlendirebilir. Aynı zamanda, müşteri ilişkileri

yönetim sistemiyle (CRM) entegrasyon sayesinde, işletmeler müşteri etkileşimlerini ve tercihlerini takip ederek gelecekteki teklifler için veri tabanlı stratejiler geliştirebilir. Şekil 4.7’de süreç akışı detaylandırılmıştır.



Şekil 4.7: Kullanıcı tekliflendirme akış şeması.

Arayüz, Flask web çerçevesi kullanılarak Python programlama dili ile geliştirilmiştir. Kullanıcı arayüzü, HTML, CSS ve JavaScript ile zenginleştirilmiş, dinamik içerikler için AJAX ve jQuery kullanılmıştır. Sunucu tarafı işlemler, veri işleme ve cihaz seçimi için optimize edilmiş Python scriptlerini içerir.

4.7.1 Teklif dokümanının oluşturulması

Bu aşamada, API aracılığıyla müşteri bilgilerinin nasıl elde edildiği, bu bilgilerin özelleştirilmiş bir Excel şablonu ile nasıl entegre edildiği ve sonuçta nasıl profesyonel bir teklif dokümanının oluşturulduğu detaylı olarak incelenmiştir.

İlk olarak, belirlenen API endpoint'ine yönelik bir HTTP GET isteği gerçekleştirilmiş ve müşteriye ait temel bilgiler içeren JSON formatında bir yanıt alınmıştır. Bu veriler, geliştirilen bir dizi veri doğrulama ve işleme mekanizması aracılığıyla sisteme başarıyla entegre edilmiştir. Alınan müşteri bilgileri, teklif dokümanının temel yapısını belirleyen ve önceden hazırlanmış olan teklif şablonuna yerleştirilmiştir. Bu entegrasyon sürecinde, müşteri bilgileri ve teklif detayları dikkatlice şablonun ilgili alanlarına entegre edilmiş ve doküman müşteriye özgü bilgilerle kişiselleştirilmiştir.

Tüm gerekli bilgilerin ve hesaplamaların teklif şablonuna başarıyla entegre edilmesiyle, Şekil 4.3'te gösterilen teklif dokümanı hazırlanmıştır. Doküman, müşteriye sunulmak üzere elektronik posta yoluyla veya diğer dijital kanallar aracılığıyla iletilebilir hale getirilmiştir.

kopitek
group

Canon

Müşteri: Kopitek Kopyalama Sistemleri LTD.

İlgili: Deniz Şimşek

Tel: 0532xxxxxxx

Tarih: 25.03.2024

Mail: deniz.simsek@kopitek.com.tr

Konu: Cihaz Fiyat Teklifi

Sayın Yetkili,

Talebinize istinaden en uygun makine modeli ve kiralama alternatifleri aşağıdaki tabloda sunulmuştur. Geri dönüşlerinizi bekler, iyi çalışmalar dileriz.

Makine Modeli	36 Ay	48 Ay	60 Ay
MF645Cx/643Cdw/641Cw	€ 28,36	€ 29,70	€ 31,93

***Yukarıda verilen fiyatlara KDV dâhil değildir.

***Fiyat Geçerlilik Süresi: 3 iş günü.



Bağlarbaşı Mah. Atatürk Cad. Sülün Sok. No: 8 Kopitek İş Merkezi Maltepe /İSTANBUL Telefon: 0(216) 441 0 444 Pbx. Faks : 0(216) 518 03 43

Şekil 4.8: Oluşturulan teklif görseli.

4.8 Gerçek Veri Uygulaması

Bu bölümde, son olarak tasarlanan kullanıcı tekliflendirme arayüzünün gerçek dünya verileriyle nasıl test edildiği adım adım açıklanmıştır. Aslan Hukuk Bürosu firması adına yapılan deneme teklif oluşturma işlemi, sistemin pratikteki işleyişi ve karar destek kapasitesini gözler önüne sermektedir. İlk adımda, "Aslan Hukuk Bürosu" adına firma yetkilisi, arayüz üzerinde yer alan formu dikkatlice doldurmuştur.

Teklif Talep Formu

Firma Ünvanı

Aslan Hukuk Bürosu

Yetkili İsmi

Akın Aslan Tarhan

Email

aslan@aslanhukuk.com.tr

Telefon Numarası

0532xxxxxxx

Firma Lokasyonu:

Istanbul

Çoklu Lokasyon:

☐ Evet

☒ Hayır

Sektör:

Hukuk

Çalışan Sayısı:

50-100 Çalışan

Baskı Türü:

☒ Renkli & Siyah/Beyaz

☐ Yalnızca Siyah/Beyaz

Kağıt Türü:

☐ A3 & A4

☒ Yalnızca A4

☐ Diğer

Baskı Hacmi

5000

Cihaz Türü

☒ MFP

☐ SFP

Gönder

Şekil 4.9: Uygulama teklif talep formu.

Şekil 4.9'daki teklif talep formu, şirketin iletişim bilgilerinden başlayarak, baskı ihtiyaçlarına özgü spesifikasyonları içermektedir.

Girilen müşteri bilgileri sistem tarafından alındıktan sonra, arka plan işlemleri için API ile entegre edilmiştir. RESTful API aracılığıyla Kopitek'in cihaz envanterine bağlanarak, belirlenen modelin maliyeti, stok durumu ve alternatif cihaz seçenekleri gibi önemli veriler dinamik bir şekilde elde edilmiştir.

API'den temin edilen verilerle beslenen sistem, 3 farklı kiralama dönemi için çeşitli fiyatlandırma senaryoları üretmiştir.

Müşteri Verisi:
id: 25
companyname: Aslan Hukuk Bürosu
contact: Akın Aslan Tarhan
mail: aslan@aslanhukuk.com.tr
phone: 0532xxxxxx
location: İstanbul
multiplelocation: 1
sector: Hukuk
employee: 3
printype: 1
papersize: 1
volume: 5000
mfp: 0
Test örneği 0: 2. en uygun model iR-ADV DX C357i, Alış Fiyatı: 1363.6363636363637 , Stok: 5
İlk tercih stokta olmadığı için stokta bulunan en uygun alternatifte geçildi.
36 ay için şehir içi aylık kira bedeli: 16.69 Euro
48 ay için şehir içi aylık kira bedeli: 19.35 Euro
60 ay için şehir içi aylık kira bedeli: 22.29 Euro
Teklif kaydedildi: Aslan Hukuk Bürosu_iR-ADV DX C357i_2024-05-13.xlsx

Şekil 4.10: Uygulama arayüz formu.

Hesaplama modeli, piyasa koşullarını ve stok verilerini analiz ederek, müşteriye en uygun kira tekliflerini belirlemiştir. Her bir teklif, cihaz, kurulum ve işletme maliyetlerinin analizine dayanarak hesaplanmıştır. Hesaplanan kira bedelleri, önerilen cihaz modeliyle beraber Şekil 4.10'da gösterilen arayüz üzerinden kullanıcıya sunulmuştur. Sistem, 36 aylık, 48 aylık ve 60 aylık kira dönemleri için detaylı fiyat tekliflerini içeren bir rapor hazırlamıştır. Şekil 4.11'de örneği gösterilen teklifler, hem arayüz üzerinden müşterinin incelemesine açılmış hem de Firma İsmi, Model ve Tarih bilgilerini içerecek şekilde adlandırılarak doküman olarak kaydedilmiştir.

kopítek
group

Canon

Müşteri: Aslan Hukuk Bürosu

İlgili: Akın Aslan Tarhan

Tel: 0532xxxxxxx

Tarih: 13.05.2024

Mail: aslan@aslanhukuk.com.tr

Konu: Cihaz Fiyat Teklifi

Sayın Yetkili,
Talebinize istinaden en uygun makine modeli ve kiralama alternatifleri aşağıdaki tabloda sunulmuştur.
Geri dönüşlerinizi bekler, iyi çalışmalar dileriz.

Makine Modeli	36 Ay	48 Ay	60 Ay
IR-ADV DX C357i	€ 16,69	€ 19,35	€ 22,29

***Yukarıda verilen fiyatlara KDV dâhil değildir.
***Fiyat Geçerlilik Süresi: 3 iş günü.











www.kopitek.com.tr

Bağlarbaşı Mah. Atatürk Cad. Sülün Sok. No: 8 Kopitec İş Merkezi Maltepe /İSTANBUL Telefon: 0(216) 441 0 444 Pbx. Faks : 0(216) 518 03 43

Şekil 4.11: Uygulama cihaz teklifi.

Bu süreç, Kopitec Kopitec Kopyalama Sistemleri Ltd. Şti. şirketine sağlanan gerçek veri tabanlı teklif oluşturma sisteminin sadece müşteri memnuniyetini artırmakla kalmayıp, aynı zamanda şirketin operasyonel verimliliğini arttırmada nasıl kritik bir rol oynadığını göstermiştir.

5. SONUÇ VE ÖNERİLER

5.1. Tezin Ana Bulgularının Özeti

Tezin kapsamında geliştirilen model, baskı çoğaltma endüstrisine yönelik karmaşık müşteri tekliflendirme ve cihaz yönetimi süreçlerini yeniden şekillendiren yenilikçi bir yaklaşım sunmaktadır. Müşteri tercihleri ve ihtiyaçlarına odaklanan bu model, derin veri analizi ve kullanıcı davranışı modellemesini entegre ederek, özelleştirilmiş tekliflerin hazırlanmasını ve cihaz yönetiminin etkinleştirilmesini sağlamaktadır. Bu entegrasyon sayesinde müşteri memnuniyetinde önemli bir artış sağlanmış ve operasyonel mükemmellik için gerekli dinamik süreç optimizasyonu mümkün hale gelmiştir. Model, sektöre özgü cihaz seçim kriterlerini derinlemesine analiz ederek, baskı endüstrisinin ihtiyaç duyduğu özelleştirmeyi ve verimlilik artışını desteklemektedir.

Modelin geliştirilmesi sürecinde makine öğrenimi teknolojilerinin entegrasyonu kritik bir öneme sahiptir. Bu teknolojiler, veri işleme kapasitesini önemli ölçüde artırarak, modelin hızlı ve doğru teklifler üretmesini sağlayacak hesaplama gücünü sunmuştur. Algoritmaların ve veri işleme tekniklerinin bir araya gelmesi, mevcut ve potansiyel müşteri verilerini derinlemesine analiz etme ve iş süreçlerindeki performansı ve etkinliği artırma imkanı sunmuştur. Sistem, veriye dayalı karar alma süreçlerini destekleyerek, baskı çoğaltma endüstrisine özgü stratejik kararların öngörüselleştirilmesi için analizlerle alınmasına olanak tanımıştır. Modelin analizi, bazı özniteliklerin teklif oluşturma ve cihaz seçimi üzerinde diğerlerine kıyasla daha fazla etkiye sahip olduğunu göstermiştir. Bu öznitelikler arasında müşterinin geçmiş satın alma davranışları, baskı hacmi, tercih edilen cihaz özellikleri ve makroekonomik göstergeler yer almaktadır. Modelin içgörülerini, firmaların müşteri ihtiyaçlarını daha iyi anlamalarına ve pazar dinamiklerine uyum sağlamalarına yardımcı olmaktadır.

Model, veri setinin %80'i ile eğitilmiş ve kalan %20'si ile test edilmiştir. Eğitim sürecinde modelin doğruluğu ve genelleştirme kabiliyeti çeşitli performans metrikleri ile değerlendirilmiştir. Modelin test seti üzerindeki doğruluk oranı, müşteri tekliflerinin ve cihaz yönetimi stratejilerinin tahmininde %90.23 olarak belirlenmiştir.

Bu yüksek doğruluk oranı, modelin endüstriye özgü senaryolarda güvenilir tahminler yapabileceğinin bir göstergesidir.

Modelin başarısı, baskı çoğaltma endüstrisinde makine öğrenimi ve karar destek sistemlerinin uygulanabilirliğini göstermektedir. Model, endüstriye özgü zorlukları ve ihtiyaçları karşılayacak şekilde tasarlanmış olup, dinamik fiyatlandırma stratejileri, müşteri davranış analizi ve piyasa koşullarına uyum gibi önemli faktörleri dikkate almaktadır. Geliştirilen sistem, firmaların rekabet avantajı elde etmesini, müşteri ilişkilerini güçlendirmesini ve piyasa değişikliklerine hızla adapte olmasını sağlayacak şekilde tasarlanmıştır. Bu yenilikçi yaklaşım, baskı çoğaltma endüstrisinin dijital dönüşümüne katkıda bulunarak, sektördeki firmaların karar alma süreçlerini verimli ve etkili bir şekilde yönlendirmelerine yardımcı olmaktadır.

5.2. Teorik ve Pratik Katkılar

Araştırmanın, baskı çoğaltma endüstrisine yönelik teorik ve pratik katkıları, sektördeki mevcut paradigmanın yeniden şekillendirilmesine önemli ölçüde etki etmiştir. Araştırma, yapay zeka ve makine öğrenimi teknolojilerinin baskı çoğaltma endüstrisindeki karar destek sistemlerine entegrasyonunu derinlemesine inceler. Bu, literatürde bu teknolojilerin sektörel entegrasyonuna yönelik önemli bir katkıdır ve diğer araştırmacılara metodolojik bir temel sağlar.

Araştırma, müşteriye özgü tekliflendirme ve cihaz yönetimi süreçlerinde yapay zekânın ve makine öğreniminin rolünü teorik olarak ele almakta ve bu teknolojilerin karar destek sistemlerine entegrasyonunu detaylandırmaktadır.

Model, müşteri ihtiyaçlarının doğru tespit edilmesi ve buna yönelik tekliflerin optimize edilmesi sürecinde yenilikçi yöntemler önermektedir. Bu yöntemler, cihaz yönetimi stratejilerinin verimliliğini artırmak ve karar verme süreçlerini geliştirmek için kritik bir temel teşkil etmektedir.

Pratik uygulamalarda, modelin entegrasyonu ile cihaz seçimi ve fiyatlandırma stratejilerinde önemli bir dönüşüm yaşanmıştır. Model, kullanıcı dostu arayüzü ve hızlı geri dönüş yeteneği ile sektör profesyonellerine zaman ve maliyet açısından avantajlar sunmaktadır.

Modelin baskı çoğaltma endüstrisi üzerindeki uzun vadeli etkileri hem operasyonel verimlilikte hem de stratejik planlama kapasitesinde önemli iyileştirmeler sağlama potansiyeline sahiptir. Özellikle, müşteriye özgü tekliflerin ve cihaz seçimlerinin

optimize edilmesi, endüstrinin rekabetçi doğasında firmalara önemli bir avantaj sağlayacaktır.

Yapay zekâ ve makine öğrenimi teknolojilerinin entegrasyonu ile sağlanan veriye dayalı karar verme süreçleri, endüstrinin gelecekteki yönünü şekillendirecek ve daha sürdürülebilir iş modellerinin ortaya çıkmasına zemin hazırlayacaktır.

5.3. Limitasyonlar ve Gelecek Araştırmalar için Öneriler:

5.3.1. Limitasyonlar

- a) Veri Setinin Temsiliyeti: Kullanılan veri seti, belirli bir piyasa segmenti ve zaman dilimine özgüdür. Farklı coğrafi bölgeler, sektörler veya zaman dilimleri için modelin doğruluğu ve genelleyiciliği sınırlı olabilir. Veri setinin çeşitliliğini artırarak ve farklı piyasalardan veriler ekleyerek bu sınırlamayı aşmak mümkün olabilir.
- b) Model Seçimi ve Optimizasyon: Rastgele Orman algoritması seçilmiş olmasına rağmen, bu modelin karmaşıklığı ve yüksek boyutlu veri setlerinde yavaş çalışma eğilimi gibi sınırlamaları bulunmaktadır. Model seçimi ve hiperparametre optimizasyonu konusunda daha kapsamlı bir araştırma yapılabilir. Ayrıca, model karşılaştırması için çapraz doğrulama teknikleri kullanılabilir.
- c) Veri Ön İşleme ve Öznitelik Mühendisliği: Betik, kategorik verileri sayısal değerlere dönüştürme ve özellik ölçeklendirme gibi temel veri ön işleme adımlarını içermektedir. Ancak, daha gelişmiş öznitelik mühendisliği teknikleri ve veri temizleme işlemleri modelin performansını iyileştirebilir. Örneğin, eksik verilerin doldurulması, aykırı değerlerin ele alınması ve öznitelik seçimi tekniklerinin uygulanması faydalı olabilir.
- d) Dinamik Piyasa Koşullarına Adaptasyon: Model, statik bir veri seti üzerine kurulmuş ve piyasa dinamiklerinin zaman içindeki değişimini hesaba katmamaktadır. Modelin düzenli olarak güncellenmesi veya online öğrenme algoritmalarının kullanılması, modelin zaman içinde değişen koşullara adaptasyonunu sağlayabilir.
- e) API Bağlantısı ve Veri Entegrasyonu: Betik, belirli bir API'den veri çekmekte ve bu verileri işlemektedir. Ancak, API'nin yanıt süresi, güvenilirliği veya formatındaki değişiklikler iş akışını etkileyebilir. API ile entegrasyonu daha

sağlam hale getirmek için hata yönetimi ve veri formatı validasyonları eklenmesi gerekebilir.

5.3.2. Gelecek araştırmalar için öneriler

- a) Veri Setinin Genişletilmesi: Gelecek araştırmalar, modelin genelleyici kabiliyetini ve dayanıklılığını artırmak için çeşitli coğrafyalar ve zaman aralıklarından elde edilen verilerle veri setini genişletmeye odaklanmalıdır. Bu, modelin farklı piyasa dinamiklerine ve trendlere daha iyi adapte olmasını sağlayacak ve böylece tahminlerin doğruluğunu artıracaktır.
- b) Sezonsallık Analizi: Gelecek çalışmalarda sezonsallığın dikkate alınması, tahmin modellerinin doğruluğunu artırmak ve veri analitiği projelerinin başarısını yükseltmek için kritiktir. Finansal piyasalar, belirli dönemlerde mevsimsel dalgalanmalar gösterebilir. Sezonsallık analizi, yatırım stratejilerinin ve risk yönetiminin geliştirilmesine katkıda bulunabilir.
- c) Model Segmentasyonu: Gelecek çalışmalar, segmentasyon yöntemlerinin daha geniş bir yelpazede uygulanmasını ve bu yöntemlerin farklı veri setleri ve uygulama alanlarındaki etkilerinin incelenmesini içerebilir. Bu sayede, makine öğrenimi modellerinin doğruluğu, güvenilirliği ve yorumlanabilirliği artırılarak, daha etkili ve verimli karar destek sistemleri geliştirilebilir.
- d) Yeni Makine Öğrenimi Modellerinin Keşfi: Araştırmacılar, modelin performansını artırmak ve daha karmaşık veri ilişkilerini çözümlmek için derin öğrenme, takviyeli öğrenme gibi gelişmiş makine öğrenimi tekniklerini keşfetmeye teşvik edilmelidir. Bu yeni yaklaşımlar, modelin mevcut sınırlarını aşmasına ve daha zorlu veri setlerinde bile yüksek tahmin başarısı göstermesine olanak tanıyabilir.
- e) Dinamik Model Güncellemeleri: Modelin piyasa koşullarındaki ani değişikliklere hızla adapte olabilmesi için dinamik modelleme stratejilerinin geliştirilmesi önemlidir. Bu, modelin zaman içinde değişen veri paternlerine uyum sağlamasını sağlayarak, sistemlerin uzun vadeli etkinliğini ve güvenilirliğini koruyacaktır.
- f) Uyarlamalı ve Öğrenen Sistemlerin Geliştirilmesi: Araştırmalar, piyasa koşulları ve kullanıcı davranışlarındaki değişikliklere gerçek zamanlı olarak uyum sağlayabilen, kendini sürekli olarak güncelleyebilen ve öğrenebilen sistemler üzerine yoğunlaşabilir. Bu, özellikle hızlı değişen endüstrilerde modelin uzun vadeli etkinliğini artıracaktır.

- g) Benzetim ve Senaryo Analizi: Model, farklı senaryolar altında benzetimler yapmak için kullanılabilir. Bu, özellikle belirsizliklerin yüksek olduđu durumlarda, risk yönetimi ve stratejik planlama için deęerli içgörüler sunabilir.





KAYNAKLAR

- Aalto, H.** (2019). Competition-based dynamic pricing in e-commerce.
- Altman, N. S.** (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- Anameriç, H.** (2005). Yönetim bilgi sistemlerinin yönetim fonksiyonları üzerine etkisi, *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 45 (2), 25-43.
- Asadi, R., Kareem, S. A., Asadi, M. ve Asadi, S.** (2017). An unsupervised feed forward neural network method for efficient clustering, *Update*, 20, 02.
- Atalay, M. ve Çelik, E.** (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis, *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9 (22), 155-172.
- Avunduk, H. ve Küçükylmaz, S.** (2020). Dinamik fiyatlandırma stratejisi, *İzmir Democracy University Social Sciences Journal*, 3 (1), 10-23.
- Bag, S., Gupta, S., Kumar, A. ve Sivarajah, U.** (2021). An integrated artificial intelligence framework for knowledge creation and B2B marketing rational decision making for improving firm performance, *Industrial Marketing Management*, 92, 178-189.
- Bhatt, G. D. ve Zaveri, J.** (2002). The enabling role of decision support systems in organizational learning, *Decision Support Systems*, 32 (3), 297-309.
- Bichler, M., Kalagnanam, J., Katircioglu, K., King, A. J., Lawrence, R. D., Lee, H. S., Lin, G. Y. ve Lu, Y.** (2002). Applications of flexible pricing in business-to-business electronic commerce, *IBM Systems Journal*, 41 (2), 287-302.
- Bishop, C. M.** (2006). *Pattern Recognition and Machine Learning*. Springer. [DOI: 10.5555/1162264]
- Boser, B. E., Guyon, I. M., & Vapnik, V. N.** (1992). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152).
- Boyd, E. A. ve Bilegan, I. C.** (2003). Revenue management and e-commerce. *Management Science*, 49 (10), 1363-1386.
- Breiman, L.** (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J.** (1984). *Classification and regression trees*. Monterey, CA: Wadsworth & Brooks.
- Brooks, C. H., Fay, S., Das, R., MacKie-Mason, J. K., Kephart, J. O. ve Durfee, E. H.** (1999). Automated strategy searches in an electronic goods

- market: Learning and complex price schedules. *Proceedings of the 1st ACM Conference on Electronic Commerce*.
- Carvalho, A. X. ve Puterman, M. L.** (2003). Dynamic pricing and reinforcement learning. *Proceedings of the International Joint Conference on Neural Networks*.
- Cohen, S.** (2021). The Basics of Machine Learning: Strategies and Techniques. *Artificial Intelligence and Deep Learning in Pathology* (s. 13-40). Elsevier.
- Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Cover, T. M., & Hart, P. E.** (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Cutler, A., Cutler, D. R., & Stevens, J. R.** (2007). Random forests. *Machine Learning*, 45(1), 157-176.
- Dasgupta, P. ve Das, R.** (2000). Dynamic pricing with limited competitor information in a multi-agent economy. Cooperative Information Systems: 7th International Conference, CoopIS 2000 Eilat, Israel, September 6-8, 2000. Proceedings 7.
- Denicolai, S., Zucchella, A. ve Magnani, G.** (2021). Internationalization, digitalization, and sustainability: Are SMEs ready? A survey on synergies and substituting effects among growth paths, *Technological Forecasting and Social Change*, 166, 120650.
- Dietterich, T. G.** (2000). Ensemble methods in machine learning. In *International workshop on multiple classifier systems* (pp. 1-15). Springer, Berlin, Heidelberg.
- Dike, H. U., Zhou, Y., Deveerasetty, K. K. ve Wu, Q.** (2018). Unsupervised Learning Based on Artificial Neural Network: A Review. *2018 IEEE International Conference on Cyborg and Bionic Systems (CBS)*, (s. 322-327). IEEE.
- Ding, L., Davies, D. ve McMahon, C. A.** (2009). The integration of lightweight representation and annotation for collaborative design representation, *Research in Engineering Design*, 20, 185-200.
- Elgh, F.** (2012). Decision support in the quotation process of engineered-to-order products, *Advanced Engineering Informatics*, 26 (1), 66-79.
- Elmaghraby, W. ve Keskinocak, P.** (2003). Dynamic pricing in the presence of inventory considerations: Research overview, current practices, and future directions, *Management Science*, 49 (10), 1287-1309.
- Faulin, J., Juan, A. A., Grasman, S. E. ve Fry, M. J.** (2012). *Decision Making in Service Industries: A Practical Approach*. CRC Press.
- Fisher, M., Gallino, S. ve Li, J.** (2018). Competition-based dynamic pricing in online retailing: A methodology validated with field experiments, *Management Science*, 64 (6), 2496-2514.

- Gallego, G. ve Van Ryzin, G.** (1994). Optimal dynamic pricing of inventories with stochastic demand over finite horizons, *Management Science*, 40 (8), 999-1020.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). Deep Learning. MIT Press.
- Goodwin, R., Akkiraju, R. ve Wu, F.** (2002). *A Decision-Support System for Quote Generation*. AAAI/IAAI.
- Grand View Research.** (2023). Commercial Printing Market Size, Share & Trends Analysis Report. Retrieved from <https://www.grandviewresearch.com/industry-analysis/commercial-printing-market>
- Greenwald, A. R., Kephart, J. O. ve Tesauero, G. J.** (1999). Strategic pricebot dynamics. *Proceedings of the 1st ACM Conference on Electronic Commerce*.
- Gupta, J. N., Forgionne, G. A. ve Mora, M.** (2007). Intelligent decision-making support systems: Foundations, applications and challenges.
- Halfawy, M. R., Dridi, L. ve Baker, S.** (2008). Integrated decision support system for optimal renewal planning of sewer networks, *Journal of Computing in Civil Engineering*, 22 (6), 360-372.
- Hamşioğlu, D. P.** (2018). *Bilgi Teknolojisi Tabanlı Kararlar ve Grup Karar Destek Sistemleri Uygulaması*. Anadolu Üniversitesi.
- Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer. [DOI: 10.1007/978-0-387-84858-7]
- Hess, T. J., Rees, L. P. ve Rakes, T. R.** (2000). Using autonomous software agents to create the next generation of decision support systems, *Decision Sciences*, 31 (1), 1-31.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X.** (2013). *Applied logistic regression*. John Wiley & Sons.
- Hu, J. ve Zhang, Y.** (2002). Online reinforcement learning in multiagent systems, *William E. Simon Graduate School of Business Administration*, University of Rochester, Rochester, New York, USA: Tech. Rep.
- James, G., Witten, D., Hastie, T., & Tibshirani, R.** (2013). An Introduction to Statistical Learning with Applications in R. New York, NY: Springer.
- Javaid, M., Haleem, A., Singh, R. P. ve Suman, R.** (2022). Artificial intelligence applications for industry 4.0: A literature-based study. *Journal of Industrial Integration and Management*, 7 (01), 83-111.
- Joachims, T.** (1998). Text categorization with support vector machines: Learning with many relevant features. In European conference on machine learning (pp. 137-142).
- Johnson, E. D.** (1973). Communication: An introduction to the history of writing, printing, books and libraries. (*No Title*).

- Kephart, J. O. ve Tesauro, G.** (2000). Pseudo-convergent Q-learning by competitive pricebots. *Proceedings of the Seventeenth International Conference on Machine Learning*.
- Kohavi, R.** (1995). A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *International Joint Conference on Artificial Intelligence (IJCAI)*
- Kwon, K. S., Rahman, M. K., Phung, T. H., Hoath, S. D., Jeong, S. ve Kim, J. S.** (2020). Review of digital printing technologies for electronic materials, *Flexible and Printed Electronics*, 5 (4), 043003.
- Lam, D., Leon, L., Hamilton, S., Crookshank, N., Bonin, D. ve Swayne, D.** (2004). Multi-model integration in a decision support system: A technical user interface approach for watershed and lake management scenarios, *Environmental Modelling & Software*, 19 (3), 317-324.
- Learning, S. S.** (2006). *Semi-Supervised Learning*. CSZ2006. html.
- Lee, K. W. ve Huh, S. Y.** (2006). A model-solver integration framework for autonomous and intelligent model solution, *Decision Support Systems*, 42 (2), 926-944.
- Leloup, B. ve Deveaux, L.** (2001). Dynamic pricing on the internet: Theory and simulations, *Electronic Commerce Research*, 1, 265-276.
- Liaw, A., & Wiener, M.** (2002). Classification and regression by random forest. *R News*, 2(3), 18-22.
- Linthicum, D. S.** (2004). *Next Generation Application Integration: From Simple Information to Web Services*. Addison-Wesley Professional.
- Liu, S., Duffy, A. H., Whitfield, R. I. ve Boyle, I. M.** (2010). Integration of decision support systems to improve decision support performance, *Knowledge and Information Systems*, 22, 261-286.
- Liu, S., McMahon, C. A. ve Culley, S. J.** (2008). A review of structured document retrieval (SDR) technology to improve information access performance in engineering document management, *Computers in Industry*, 59 (1), 3-16.
- Liu, S. ve Young, R. I.** (2004). Utilizing information and knowledge models to support global manufacturing co-ordination decisions, *International Journal of Computer Integrated Manufacturing*, 17 (6), 479-492.
- McCulloch, W. S. ve Pitts, W.** (1943). A logical calculus of the ideas immanent in nervous activity, *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Menard, S.** (2002). Applied logistic regression analysis. Sage.
- Narahari, Y., Raju, C., Ravikumar, K. ve Shah, S.** (2005). Dynamic pricing models for electronic business, *Sadhana*, 30, 231-256.
- Nasiri, S., Khosravani, M. R. ve Weinberg, K.** (2017). Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review, *Engineering Failure Analysis*, 81, 270-293.
- Nasteski, V.** (2017). An overview of the supervised machine learning methods, *Horizons*. b, 4, 51-62.

- Peng, C. Y., Lee, K. L., & Ingersoll, G. M.** (2002). An introduction to logistic regression analysis and reporting. *The Journal of Educational Research*, 96(1), 3-14.
- Popescu, I. ve Wu, Y.** (2007). Dynamic pricing strategies with reference effects, *Operations Research*, 55 (3), 413-429.
- Prim, A. G. H.** (2006). Yapay zeka, *Yaşar Üniversitesi E-Dergisi*, 1 (1), 81-93.
- Quinlan, J. R.** (1986). Induction of decision trees. *Machine Learning*, 1(1), 81-106.
- Raghavan, V. ve Hafez, A.** (2000). Dynamic data mining. *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*.
- Rathee, G., Garg, S., Kaddoum, G. ve Choi, B. J.** (2020). Decision-making model for securing IoT devices in smart industries, *IEEE Transactions on Industrial Informatics*, 17 (6), 4270-4278.
- Rodgers, P. A., Huxor, A. P. ve Caldwell, N. H.** (1999). Design support using distributed Web-based AI tools, *Research in Engineering Design*, 11, 31-44.
- Rokach, L., & Maimon, O.** (2005). Top-down induction of decision trees classifiers—a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 35(4), 476-487.
- Rosenblatt, F.** (1957). *The Perceptron, A Perceiving and Recognizing Automaton Project Para*. Cornell Aeronautical Laboratory.
- Sammut, C., & Webb, G. I. (Eds.).** (2010). *Encyclopedia of Machine Learning*. Springer
- Saridakis, K. M. ve Dentsoras, A. J.** (2006). Integration of fuzzy logic, genetic algorithms and neural networks in collaborative parametric design, *Advanced Engineering Informatics*, 20 (4), 379-399.
- Sarker, I. H.** (2021). Machine learning: Algorithms, real-world applications and research directions, *SN Computer Science*, 2 (3), 160.
- Schölkopf, B., Burges, C. J. C., & Smola, A. J.** (1999). *Advances in kernel methods: Support vector learning*. MIT Press.
- Sejnowski, T. J.** (2018). *The Deep Learning Revolution*. MIT Press.
- Senefelder, J. N. F. A.** (1819). *A Complete Course of Lithography*, tr. by AS. Ackermann.
- Shim, J. P., Warkentin, M., Courtney, J. F., Power, D. J., Sharda, R. ve Carlsson, C.** (2002). Past, present, and future of decision support technology. *Decision Support Systems*, 33 (2), 111-126.
- Spilsbury, L.** (2015). *Johannes Gutenberg and the Printing Press*. The Rosen Publishing Group, Inc.
- Strobl, C., Boulesteix, A. L., Zeileis, A., & Hothorn, T.** (2007). Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics*, 8(1), 25.

- Sundar, D. ve Ravikumar, K.** (2003). Multi-agent learning in dynamic pricing games of service markets, *IIM Bangalore Research Paper*, (210).
- Tunçel, O.** (2019). Dijital çağda baskı teknolojileri, *Sanat ve Tasarım Dergisi*, (23), 361-377.
- Turgut, A., Temir, A., Aksoy, B. ve Özsoy, K.** (2019). Yapay zekâ yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması, *International Journal of 3D Printing Technologies and Digital Industry*, 3 (3), 244-253.
- Tyler, D. J.** (2005). Textile digital printing technologies, *Textile Progress*, 37 (4), 1-65.
- Uçar, T. F.** (2004). *Görsel İletişim ve Grafik Tasarım*. İnkılap Kitabevi.
- Van Der Meer, M., Kurth-Nelson, Z. ve Redish, A. D.** (2012). Information processing in decision-making systems, *The Neuroscientist*, 18 (4), 342-359.
- Varian, H. R.** (1996). Differential pricing and efficiency.
- Vidrova, Z., Krizanova, A. ve Gajanova, L.** (2019). Advantages, limits and issues of using the competitive pricing strategy, *Economic and Social Development: Book of Proceedings*, 339-348.
- Walker, S. H., & Duncan, D. B.** (1967). Estimation of the probability of an event as a function of several independent variables. *Biometrika*, 54(1-2), 167-179.
- Weinberger, K. Q., Blitzer, J., & Saul, L. K.** (2006). Distance metric learning for large margin nearest neighbor classification. In *Advances in neural information processing systems*.
- Yusof, Y., Mansor, H. A. H. ve Ahmad, A.** (2017). Utilizing unsupervised weightless neural network as autonomous states classifier in reinforcement learning algorithm. *2017 IEEE 13th International Colloquium on Signal Processing & its Applications (CSPA)* (s. 264-269). IEEE.
- Zare Mehrjerdi, Y.** (2009). A decision-making model for flexible manufacturing system, *Assembly Automation*, 29 (1), 32-40.
- Zhang, D., Zhou, L. ve Nunamaker Jr, J. F.** (2002). A knowledge management framework for the support of decision making in humanitarian assistance/disaster relief, *Knowledge and Information Systems*, 4, 370-385.
- Zhang, R.** (2013). An introduction to joint pricing and inventory management under stochastic demand. *Olin Business School, Washington University in St. Louis*.

EKLER

EK A: Model Kaynak Kodu

EK B: Giriş Formu Kaynak Kodu

EK C: API Kaynak Kodu

EK D: Validasyon Kaynak Kodu

EK E: Kullanıcı Arayüzü Tasarım Kodu



EK A: Model Kaynak Kodu

```
import pandas as pd

import numpy as np

import requests

import openpyxl

import matplotlib.pyplot as plt

from openpyxl import load_workbook

from openpyxl.styles import PatternFill

from sklearn.model_selection import train_test_split

from sklearn.ensemble import RandomForestClassifier

from sklearn.metrics import accuracy_score

from sklearn.preprocessing import LabelEncoder, StandardScaler

from sklearn.metrics import roc_curve, auc

import pandas as pd

from reportlab.lib.pagesizes import letter

from reportlab.pdfgen import canvas

from datetime import datetime

print("Veri seti yükleniyor...")

data = pd.read_excel('C:/Users/deniz.simsek/Desktop/Machine Data Tem2.xlsx')

print("İlk 5 satır:")

print(data.head())

print("\nKategorik veriler sayısal verilere dönüştürülüyor...")

label_encoders = {}

for column in data.select_dtypes(include=['object']).columns:

    print(f" {column} sütunu dönüştürülüyor...")

    le = LabelEncoder()
```

```

data[column] = le.fit_transform(data[column])

label_encoders[column] = le

X = data.drop('Model', axis=1)

y = data['Model']

print("\nVeri seti eğitim ve test setlerine ayrılıyor...")

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)

print("\nÖzellikler ölçeklendiriliyor...")

scaler = StandardScaler()

X_train_scaled = scaler.fit_transform(X_train)

X_test_scaled = scaler.transform(X_test)

print("\nModel eğitiliyor...")

rf = RandomForestClassifier(n_estimators=100, random_state=42)

rf.fit(X_train_scaled, y_train)

print("\nTest seti üzerinde tahmin yapılıyor...")

y_pred = rf.predict(X_test_scaled)

accuracy = accuracy_score(y_test, y_pred)

print(f"\nModel Doğruluğu: {accuracy:.4f}")

print("\nAPI'den veriler yükleniyor...")

response = requests.get('http://api2.kopitek.com.tr:8081/api/customers/')

test_data = response.json() # API'den gelen ilk müşteri verisini al

df = pd.DataFrame([test_data])

df_model = df[['location', 'sector', 'employee', 'printype', 'papersize', 'volume', 'mfp']]

print("\nTest verisindeki kategorik veriler sayısal verilere dönüştürülüyor...")

for column in df_model.columns:

    if column in label_encoders:

```

```

    print(f' {column} sütunu dönüştürülüyor...")

    df_model[column] = label_encoders[column].transform(df_model[column])

print("\nTest verisi özellikleri ölçeklendiriliyor...")

test_data_scaled = scaler.transform(df_model)

print("\nTest verisi üzerinde tahmin yapılıyor...")

test_predictions = rf.predict(test_data_scaled)

print("\nTest verisi tahminleri:")

print(test_predictions)

predicted_category = label_encoders['Model'].inverse_transform(test_predictions)

print("Tahmin edilen kategoriler:", predicted_category)

urunler_df = pd.read_excel('C:/Users/deniz.simsek/Desktop/urunler.xlsx')

product_row = urunler_df[urunler_df['Model İsmi'] == predicted_category[0]]

if not product_row.empty:

    purchase_price = product_row['Alış Fiyatı'].iloc[0]

    print(f'Model İsmi: {predicted_category[0]}, Alış Fiyatı: {purchase_price}')

else:

    print(f'Model İsmi '{predicted_category[0]}' bulunamadı.")

urunler_df = pd.read_excel('C:/Users/deniz.simsek/Desktop/urunler.xlsx')

y_proba = rf.predict_proba(test_data_scaled)

top_n_predictions = np.argsort(-y_proba, axis=1)

for i, probs in enumerate(top_n_predictions):

    stokta_var = False

    for rank, model_index in enumerate(probs[:5]):

        model_name = label_encoders['Model'].inverse_transform([model_index])[0]

        product_row = urunler_df[urunler_df['Model İsmi'] == model_name]

        if not product_row.empty:

```

```

    stok_miktari = product_row['Stok'].iloc[0]

    if stok_miktari > 0:

        purchase_price = product_row['Alış Fiyatı'].iloc[0]

        print(f"Test örneği {i}: {rank+1}. en uygun model {model_name}, Alış
        Fiyatı: {purchase_price} , Stok: {stok_miktari}")

        stokta_var = True

        if rank > 0:

            print("İlk tercih stokta olmadığı için stokta bulunan en uygun alternatifte
            geçildi.")

            break

    if not stokta_var:

        print(f"Test örneği {i}: Stokta uygun alternatif bulunamadı.")

    kurulum_maliyeti = 25 # Euro

    km_başına_tüketim = 0.0682 # Euro

    bakım_maliyeti_yillik = 100 # Euro yıllık

    enflasyon_orani = 0.25

    getiri_orani = 0.25

    salvage_value = 25 # Euro

    mesafe_df = pd.read_excel('C:/Users/deniz.simsek/Desktop/mesafe.xlsx',
    index_col=0) # A sütununu indeks olarak kullan

    response = requests.get('http://api2.kopitek.com.tr:8081/api/customers/')

    test_data_location=response.json()

    df = pd.DataFrame([test_data_location])

    lokasyon_df = df['location']

    lokasyon = lokasyon_df.iloc[0] # Get the first location as a string

    if lokasyon in mesafe_df.columns:

        en_yakin_mesafe = mesafe_df[lokasyon].min()

```

```

    en_yakin_merkez = mesafe_df[lokasyon].idxmin()

    print(f"İlgili şehir: {lokasyon}, En yakın merkez: {en_yakin_merkez}, Mesafe:
{en_yakin_mesafe} km")

else:

    print(f"{lokasyon} için mesafe bilgisi bulunamadı.")

def aylık_odeme_hesapla(ay_sayisi, purchase_price):

    nominal_indirim_orani = (1 + enflasyon_orani) * (1 + getiri_orani) - 1

    aylık_indirim_orani = (1 + nominal_indirim_orani) ** (1/12) - 1

    toplam_ek_maliyet = kurulum_maliyeti + en_yakin_mesafe*km_başına_tüketim +
bakim_maliyeti_yillik * (ay_sayisi / 12)

    toplam_maliyet = purchase_price + toplam_ek_maliyet

    pmt_toplam = toplam_maliyet * aylık_indirim_orani / (1 - (1 + aylık_indirim_orani)
** -ay_sayisi)

    return pmt_toplam

for ay_sayisi in [36, 48, 60]:

    pmt_toplam = aylık_odeme_hesapla(ay_sayisi, purchase_price)

    print(f"{ay_sayisi} ay için şehir içi aylık kira bedeli: {pmt_toplam:.2f} Euro")

api_url = "http://api2.kopitek.com.tr:8081/api/customers/"

response = requests.get(api_url)

if response.status_code == 200:

    customer_data = response.json()

else:

    print("Failed to connect to the API")

company_name = customer_data.get("companyname")

contact = customer_data.get("contact")

mail = customer_data.get("mail")

phone = customer_data.get("phone")

```

```

def write_to_excel(model, price_36, price_48, price_60):

    workbook = load_workbook(filename='C:/Users/deniz.simsek/Desktop//teklif.xlsx')

    worksheet = workbook['Table 1']

    worksheet['B8'] = model_name
    worksheet['D8'] = price_36
    worksheet['E8'] = price_48
    worksheet['F8'] = price_60
    worksheet['C2'] = company_name
    worksheet['C3'] = phone
    worksheet['C4'] = mail
    worksheet['F2'] = contact

    machine_model = model_name
    price_36 = aylık_odeme_hesapla(36, purchase_price)
    price_48 = aylık_odeme_hesapla(48, purchase_price)
    price_60 = aylık_odeme_hesapla(60, purchase_price)

    write_to_excel(machine_model, price_36, price_48, price_60)

    current_date = datetime.now().strftime("%Y-%m-%d")

    filename = f'C:/Users/deniz.simsek/Desktop/{company_name}_{machine_model}_{current_date}.xlsx'

    workbook.save(filename=filename)

    print("Values written to Excel successfully.")

```

EK B: Giriş Formu Kaynak Kodu

```
<template>
  <div class="surface-ground px-4 py-8 md:px-6 lg:px-8">
    <Toast />
    <div class="p-fluid flex flex-column lg:flex-row">
      <ul
        class="list-none m-0 p-0 flex flex-row lg:flex-column justify-content-
evenly md:justify-content-between lg:justify-content-start mb-5 lg:pr-8 lg:mb-0">
        <li>
          <a v-ripple
            class="flex align-items-center cursor-pointer p-3 border-round text-
800 hover:surface-hover transition-duration-150 transition-colors p-ripple">
            <i class="pi pi-user md:mr-2"></i>
            <span @click="showPasswordPage()" class="font-medium hidden
md:block">Admin Panel</span>
          </a>
        </li>
      </ul>
      <Dialog v-model:visible="visible" modal :style="{ width: '20vw' }"
        :breakpoints="{ '1199px': '75vw', '575px': '90vw' }">
        <div style="display: flex; flex-direction: column; align-items: center">
          <div style="margin-bottom: 10px">
            <InputText v-model="Password" type="text" />
          </div>
          <div>
            <Button label="Enter" @click="visible = false; goAdminPanel()" />
          </div>
        </div>
      </Dialog>

      <div class="surface-card shadow-2 border-round flex-auto">
        <div class="formbold-main-wrapper">
          <div class="formbold-form-wrapper">
            <div style="text-align: center; margin-bottom: 20px">
```

```


<h1 style="margin-top: 10px">Teklif Talep Formu</h1>
</div>
<form>
  <div class="formbold-input-group">
    <label for="Firma Ünvanı" class="formbold-form-label">Firma
    Ünvanı</label>
    <input type="text" v-model="company" name="Firma Ünvanı"
    id="Firma Ünvanı"
      placeholder="Firma Ünvanı" class="formbold-form-input" />
  </div>
  <div class="formbold-input-group">
    <label for="Yetkili İsmi" class="formbold-form-label">Yetkili
    İsmi</label>
    <input type="text" v-model="contact" name="Yetkili İsmi"
    id="Yetkili İsmi"
      placeholder="Yetkili İsmi" class="formbold-form-input" />
  </div>
  <div class="formbold-input-group">
    <label for="email" class="formbold-form-label">Email</label>
    <input type="email" v-model="mail" name="email" id="email"
      placeholder="Yetkili mail adresini giriniz." class="formbold-
    form-input" />
  </div>
  <div class="formbold-input-group">
    <label for="phone" class="formbold-form-label">Telefon
    Numarası</label>
    <input type="tel" v-model="phone" name="phone" id="phone"
      placeholder="Telefon numarasını giriniz." class="formbold-
    form-input" />
  </div>

```

```
<div class="formbold-input-group">
  <label class="formbold-form-label">Firma Lokasyonu:</label>
  <select class="formbold-form-select" v-model="location"
name="location" id="location">
    <option value="Adana">Adana</option>
    <option value="Adıyaman">Adıyaman</option>
    <option value="Afyonkarahisar">Afyonkarahisar</option>
    <option value="Ağrı">Ağrı</option>
    <option value="Amasya">Amasya</option>
    <option value="Ankara">Ankara</option>
    <option value="Antalya">Antalya</option>
    <option value="Artvin">Artvin</option>
    <option value="Aydın">Aydın</option>
    <option value="Balıkesir">Balıkesir</option>
    <option value="Bilecik">Bilecik</option>
    <option value="Bingöl">Bingöl</option>
    <option value="Bitlis">Bitlis</option>
    <option value="Bolu">Bolu</option>
    <option value="Burdur">Burdur</option>
    <option value="Bursa">Bursa</option>
    <option value="Çanakkale">Çanakkale</option>
    <option value="Çankırı">Çankırı</option>
    <option value="Çorum">Çorum</option>
    <option value="Denizli">Denizli</option>
    <option value="Diyarbakır">Diyarbakır</option>
    <option value="Edirne">Edirne</option>
    <option value="Elazığ">Elazığ</option>
    <option value="Erzincan">Erzincan</option>
    <option value="Erzurum">Erzurum</option>
    <option value="Eskişehir">Eskişehir</option>
    <option value="Gaziantep">Gaziantep</option>
    <option value="Giresun">Giresun</option>
    <option value="Gümüşhane">Gümüşhane</option>
```

<option value="Hakkari">Hakkari</option>
<option value="Hatay">Hatay</option>
<option value="Isparta">Isparta</option>
<option value="Mersin">Mersin</option>
<option value="İstanbul">İstanbul</option>
<option value="İzmir">İzmir</option>
<option value="Kars">Kars</option>
<option value="Kastamonu">Kastamonu</option>
<option value="Kayseri">Kayseri</option>
<option value="Kırklareli">Kırklareli</option>
<option value="Kırşehir">Kırşehir</option>
<option value="Kocaeli">Kocaeli</option>
<option value="Konya">Konya</option>
<option value="Kütahya">Kütahya</option>
<option value="Malatya">Malatya</option>
<option value="Manisa">Manisa</option>
<option value="Kahramanmaraş">Kahramanmaraş</option>
<option value="Mardin">Mardin</option>
<option value="Muğla">Muğla</option>
<option value="Muş">Muş</option>
<option value="Nevşehir">Nevşehir</option>
<option value="Niğde">Niğde</option>
<option value="Ordu">Ordu</option>
<option value="Rize">Rize</option>
<option value="Sakarya">Sakarya</option>
<option value="Samsun">Samsun</option>
<option value="Siirt">Siirt</option>
<option value="Sinop">Sinop</option>
<option value="Sivas">Sivas</option>
<option value="Tekirdağ">Tekirdağ</option>
<option value="Tokat">Tokat</option>
<option value="Trabzon">Trabzon</option>
<option value="Tunceli">Tunceli</option>
<option value="Şanlıurfa">Şanlıurfa</option>

```

<option value="Uşak">Uşak</option>
<option value="Van">Van</option>
<option value="Yozgat">Yozgat</option>
<option value="Zonguldak">Zonguldak</option>
<option value="Aksaray">Aksaray</option>
<option value="Bayburt">Bayburt</option>
<option value="Karaman">Karaman</option>
<option value="Kırıkkale">Kırıkkale</option>
<option value="Batman">Batman</option>
<option value="Şırnak">Şırnak</option>
<option value="Bartın">Bartın</option>
<option value="Ardahan">Ardahan</option>
<option value="Iğdır">Iğdır</option>
<option value="Yalova">Yalova</option>
<option value="Karabük">Karabük</option>
<option value="Kilis">Kilis</option>
<option value="Osmaniye">Osmaniye</option>
<option value="Düzce">Düzce</option>
</select>
</div>

<div class="formbold-input-radio-wrapper">
  <label class="formbold-form-label">Çoklu Lokasyon:</label>
  <div class="formbold-radio-flex">
    <label
      class="formbold-radio-label"
      for="multipleLocationsYes">
      <input
        type="radio"
        v-model="multipleLocations"
        name="multipleLocations"
        id="multipleLocationsYes" value="1" class="formbold-
input-radio" />
      Evet
      <span class="formbold-radio-checkmark"></span>
    </label>
  </div>
</div>

```

```

<label class="formbold-radio-label"
for="multipleLocationsNo">
    <input type="radio" v-model="multipleLocations"
name="multipleLocations"
id="multipleLocationsNo" value="0" class="formbold-
input-radio" />

```

Hayır

```
<span class="formbold-radio-checkmark"></span>
```

```
</label>
```

```
</div>
```

```
</div>
```

```

<div class="formbold-input-group">
    <label class="formbold-form-label">Sektör:</label>
    <select v-model="sector" class="formbold-form-select"
name="sector" id="sector">
        <!-- Sektörler Eklenecek -->
        <option value="Finans">Finans</option>
        <option value="İmalat">İmalat</option>
        <option value="Hukuk">Hukuk</option>
        <option value="Sağlık">Sağlık</option>
        <option value="Eğitim">Eğitim</option>
        <option value="Kamu">Kamu</option>
        <option value="Perakende">Perakende</option>
        <option value="Bilgi Teknolojileri">Bilgi
Teknolojileri</option>
        <option value="Gayrimenkul">Gayrimenkul</option>
        <option value="Diğer">Diğer</option>
    </select>
</div>
<div class="formbold-input-group">
    <label class="formbold-form-label">Çalışan Sayısı:</label>
    <select v-model="employeeCount" class="formbold-form-select"
name="employeeCount"

```

```

        id="employeeCount">
        <option value="1">1-20 Çalışan</option>
        <option value="2">20-50 Çalışan</option>
        <option value="3">50-100 Çalışan</option>
        <option value="4">100+ Çalışan</option>
    </select>
</div>

<div class="formbold-input-radio-wrapper">
    <label class="formbold-form-label">Baskı Türü:</label>
    <div class="formbold-radio-flex">
        <label class="formbold-radio-label" for="printTypeColor">
            <input v-model="prinType" type="radio" name="printType"
id="printTypeColor"
            value="1" class="formbold-input-radio" />
            Renkli & Siyah/Beyaz
            <span class="formbold-radio-checkmark"></span>
        </label>
        <label
            class="formbold-radio-label"
for="printTypeOnlyBW">
            <input v-model="prinType" type="radio" name="printType"
id="printTypeOnlyBW"
            value="2" class="formbold-input-radio" />
            Yalnızca Siyah/Beyaz
            <span class="formbold-radio-checkmark"></span>
        </label>
    </div>
</div>

<div class="formbold-input-radio-wrapper">
    <label class="formbold-form-label">Kağıt Türü:</label>
    <div class="formbold-radio-flex">
        <label class="formbold-radio-label" for="paperTypeA3">

```

```

<input      v-model="paperType"      type="radio"
name="paperType" id="paperTypeA3" value="1"
      class="formbold-input-radio" />
A3 & A4
<span class="formbold-radio-checkmark"></span>
</label>
<label class="formbold-radio-label" for="paperTypeOnlyA4">
  <input      v-model="paperType"      type="radio"
name="paperType" id="paperTypeOnlyA4"
      value="2" class="formbold-input-radio" />
  Yalnızca A4
  <span class="formbold-radio-checkmark"></span>
</label>
<label class="formbold-radio-label" for="other">
  <input      v-model="paperType"      type="radio"
name="paperType" id="other" value="3"
      class="formbold-input-radio" />
  Diğer
  <span class="formbold-radio-checkmark"></span>
</label>
</div>
</div>
<div class="formbold-input-group">
  <label    for="phone"    class="formbold-form-label">Baskı
Hacmi</label>
  <input    type="tel"    v-model="volume"    name="volume"
id="volume"
      placeholder="Aylık    Baskı    Hacminizi    Giriniz"
class="formbold-form-input" />
</div>
<div class="formbold-input-radio-wrapper">
  <label class="formbold-form-label">Cihaz Türü</label>
  <div class="formbold-radio-flex">
    <label class="formbold-radio-label" for="mfp">

```

```

        <input v-model="mfp" type="radio" name="paperType"
id="paperTypeA3" value="1"
        class="formbold-input-radio" />
        MFP
        <span class="formbold-radio-checkmark"></span>
    </label>
    <label class="formbold-radio-label" for="sfp">
        <input v-model="mfp" type="radio" name="paperType"
id="paperTypeOnlyA4" value="2"
        class="formbold-input-radio" />
        SFP
        <span class="formbold-radio-checkmark"></span>
    </label>
</div>
</div>
<button @click="submit()" class="formbold-
btn">Gönder</button>
</form>
</div>
</div>
</div>
</div>
</div>
</template>

<script>
import axios from 'axios';
export default {
  data() {
    return {
      Password: "",
      visible: false,
      company: "",
      contact: "",

```

```

        mail: "",
        phone: "",
        location: "",
        multipleLocations: "",
        sector: "",
        employeeCount: "",
        prinType: "",
        paperType: "",
        volume: "",
        mfp: ""
    };
},
methods: {
    goAdminPanel() {
        if (this.Password === '5224') {
            this.$router.push('/admin');
        } else {
            this.$toast.add({ severity: 'error', summary: 'Hata', detail: 'Şifre Yanlış !',
life: 3000 });
            this.Password = "";
        }
    },
    showPasswordPage() {
        this.visible = true;
    },
    submit() {
        var self = this;
        const apiGet = axios.create({
            baseURL: '',
            headers: {
                // 'Authorization': 'bearer ' + token
            }
        });
    });

```

apiGet

```
.post('http://api2.kopitek.com.tr:8081/api/customers', {
  companyname: self.company,
  contact: self.contact,
  mail: self.mail,
  phone: self.phone,
  location: self.location,
  multiplelocation: self.multipleLocations,
  sector: self.sector,
  employee: self.employeeCount,
  printype: self.prinType,
  papersize: self.paperType,
  volume: self.volume,
  mfp: self.mfp
})
.then(() => {
  alert('Form gönderildi');
})
.catch(function (error) {
  if (error.response) {
    console.log(error.response.data);
    console.log(error.response.status);
    console.log(error.response.headers);
  }
});
}
}
};
</script>

<style>
@import
url('https://fonts.googleapis.com/css2?family=Inter:wght@400;500;600;700&display=swap');

```

```
.formbold-main-wrapper {
  display: flex;
  align-items: center;
  justify-content: center;
  padding: 48px;
}

.formbold-form-wrapper {
  margin: 0 auto;
  max-width: 570px;
  width: 100%;
  background: white;
  padding: 40px;
}

.formbold-input-group {
  margin-bottom: 18px;
}

.formbold-form-select,
.formbold-form-input {
  width: 100%;
  padding: 12px 22px;
  border-radius: 5px;
  border: 1px solid #dde3ec;
  background: #ffffff;
  font-size: 16px;
  color: #536387;
  outline: none;
  resize: none;
}

.formbold-input-radio-wrapper {
  margin-bottom: 25px;
}

.formbold-radio-flex {
  display: flex;
  flex-direction: column;
```

```

    gap: 15px;
}
.formbold-radio-label {
    font-size: 14px;
    line-height: 24px;
    color: #07074d;
    position: relative;
    padding-left: 25px;
    cursor: pointer;
    -webkit-user-select: none;
    -moz-user-select: none;
    -ms-user-select: none;
    user-select: none;
}
.formbold-input-radio {
    position: absolute;
    opacity: 0;
    cursor: pointer;
}
.formbold-radio-checkmark {
    position: absolute;
    top: -1px;
    left: 0;
    height: 18px;
    width: 18px;
    background-color: #ffffff;
    border: 1px solid #dde3ec;
    border-radius: 50%;
}
.formbold-radio-label .formbold-input-radio:checked~.formbold-radio-checkmark {
    background-color: #6a64f1;
}
.formbold-radio-checkmark:after {
    content: "";

```

```

    position: absolute;
    display: none;
}
.formbold-radio-label .formbold-input-radio:checked~.formbold-radio-
checkmark:after {
    display: block;
}
.formbold-radio-label .formbold-radio-checkmark:after {
    top: 50%;
    left: 50%;
    width: 10px;
    height: 10px;
    border-radius: 50%;
    background: #ffffff;
    transform: translate(-50%, -50%);
}
.formbold-form-input::placeholder {
    color: #536387;
}
.formbold-form-input:focus {
    border-color: #6a64f1;
    box-shadow: 0px 3px 8px rgba(0, 0, 0, 0.05);
}
.formbold-form-label {
    color: #07074d;
    font-size: 14px;
    line-height: 24px;
    display: block;
    margin-bottom: 10px;
}
.formbold-btn {
    text-align: center;
    width: 100%;
    font-size: 16px;

```

```
border-radius: 5px;
padding: 14px 25px;
border: none;
font-weight: 500;
background-color: #6a64f1;
color: white;
cursor: pointer;
margin-top: 25px;
}
.formbold-btn:hover {
  box-shadow: 0px 3px 8px rgba(0, 0, 0, 0.05);
}</style>
```



EK C: API Kaynak Kodu

```
const sql = require("mssql");
const config = {
  user: "sa",
  password: "0SB8@C1#%3U4^2V",
  server: "213.128.67.70",
  database: "Tez",
  options: {
    trustedconnection: true,
    enableArithAbort: true,
    instancename: "MSSQLEXPRESS",
  },
  port: 1433,
};
const connectionPool = new sql.ConnectionPool(config);
async function getCustomers() {
  try {
    await connectionPool.connect();
    const customers = await connectionPool
      .request()
      .query("SELECT * FROM Customers");
    return customers.recordset;
  } catch (error) {
    console.error(error);
    throw new Error("Bir hata oluştu: " + error.message);
  }
}
async function getCustomer(id) {
  try {
    await connectionPool.connect();
    const customer = await connectionPool
      .request()
      .input("id", sql.Int, id)
      .query("SELECT * FROM dbo.Customers WHERE id = @id");
```

```

    return customer.recordset;
} catch (error) {
    console.error(error);
    throw new Error("Bir hata oluřtu: " + error.message);
}
}

async function addCustomer(customerData) {
    try {
        await connectionPool.connect();
        const result = await connectionPool
            .request()
            .input("companyname", sql.NVarChar(100), customerData.companyname)
            .input("contact", sql.NVarChar(50), customerData.contact)
            .input("mail", sql.NVarChar(50), customerData.mail)
            .input("phone", sql.NVarChar(20), customerData.phone)
            .input("location", sql.NVarChar(20), customerData.location)
            .input("multiplelocation", sql.Bit, customerData.multiplelocation)
            .input("sector", sql.NVarChar(50), customerData.sector)
            .input("employee", sql.SmallInt, customerData.employee)
            .input("printype", sql.SmallInt, customerData.printype)
            .input("papersize", sql.SmallInt, customerData.papersize)
            .query(
                "INSERT INTO Customers (companyname, contact, mail, phone, location,
multiplelocation, sector, employee, printype, papersize) VALUES (@companyname,
@contact, @mail, @phone, @location, @multiplelocation, @sector, @employee,
@printype, @papersize)"
            );
        return result.recordset;
    } catch (error) {
        console.error(error);
        throw new Error("Bir hata oluřtu: " + error.message);
    }
}

async function updateCustomer(customerData) {

```

```

try {
  await connectionPool.connect();
  const result = await connectionPool
    .request()
    .input("id", sql.Int, customerData.id)
    .input("companyname", sql.NVarChar(100), customerData.companyname)
    .input("contact", sql.NVarChar(50), customerData.contact)
    .input("mail", sql.NVarChar(50), customerData.mail)
    .input("phone", sql.NVarChar(20), customerData.phone)
    .input("location", sql.NVarChar(20), customerData.location)
    .input("multiplelocation", sql.Bit, customerData.multiplelocation)
    .input("sector", sql.NVarChar(50), customerData.sector)
    .input("employee", sql.SmallInt, customerData.employee)
    .input("printype", sql.SmallInt, customerData.printype)
    .input("papersize", sql.SmallInt, customerData.papersize)
    .query(
      "UPDATE Customers SET companyname = @companyname, contact =
      @contact, mail = @mail, phone = @phone, location = @location, multiplelocation =
      @multiplelocation, sector = @sector, employee = @employee, printype = @printype,
      papersize = @papersize WHERE id = @id"
    );
  return result.recordset;
} catch (error) {
  console.error(error);
  throw new Error("Bir hata oluştu: " + error.message);
}
}

async function deleteCustomer(id) {
  try {
    await connectionPool.connect();
    const result = await connectionPool
      .request()
      .input("id", sql.Int, id)
      .query("DELETE FROM Customers WHERE id = @id");
  }
}

```

```
    return result.recordset;
  } catch (error) {
    console.error(error);
    throw new Error("Bir hata oluştu: " + error.message);
  }
}

module.exports = {
  getCustomers,
  getCustomer,
  addCustomer,
  updateCustomer,
  deleteCustomer,
};
```

EK D: Validasyon Kaynak Kodu

```
import pandas as pd

from sklearn.model_selection import train_test_split, cross_val_score

from sklearn.ensemble import RandomForestClassifier

from sklearn.metrics import accuracy_score, confusion_matrix, classification_report

from sklearn.preprocessing import LabelEncoder, StandardScaler

import matplotlib.pyplot as plt

import seaborn as sns

import numpy as np

data_path = 'C:/Users/deniz.simsek/Desktop/Machine Data.xlsx'

data = pd.read_excel(data_path)

label_encoders = {}

for column in data.select_dtypes(include=['object']).columns:

    le = LabelEncoder()

    data[column] = le.fit_transform(data[column])

    label_encoders[column] = le

X = data.drop('Model', axis=1)

y = data['Model']

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)

scaler = StandardScaler()

X_train_scaled = scaler.fit_transform(X_train)

X_test_scaled = scaler.transform(X_test)

rf = RandomForestClassifier(n_estimators=100, random_state=42)

rf.fit(X_train_scaled, y_train)

y_pred = rf.predict(X_test_scaled)
```

```

accuracy = accuracy_score(y_test, y_pred)

print(f'Model Doğruluğu: {accuracy:.4f}')

cv_scores = cross_val_score(rf, X_train_scaled, y_train, cv=5) # 5 katlı çapraz
doğrulama

print(f'\nÇapraz Doğrulama Skorları: {cv_scores}')

print(f'Ortalama Çapraz Doğrulama Skoru: {np.mean(cv_scores)}')

conf_mat = confusion_matrix(y_test, y_pred)

print(f'\nKarışıklık Matrisi:\n{conf_mat}\n')

print("Sınıflandırma Raporu:")

print(classification_report(y_test, y_pred))

feature_importances = rf.feature_importances_

indices = np.argsort(feature_importances)[-5:]

print("\nEn önemli 5 özellik ve önem dereceleri:")

for i in indices:

    print(f'{X.columns[i]}: {feature_importances[i]:.4f}')

plt.figure(figsize=(10, 6))

sns.boxplot(cv_scores)

plt.title('Çapraz Doğrulama Skorları')

plt.xlabel('Random Forest Modeli')

plt.ylabel('Doğruluk Skoru')

plt.show()

plt.figure(figsize=(10, 8))

sns.heatmap(conf_mat, annot=True, fmt="d", cmap="Blues")

plt.title('Karışıklık Matrisi')

plt.xlabel('Tahmin Edilen Etiketler')

plt.ylabel('Gerçek Etiketler')

```

```
plt.show()

plt.figure(figsize=(10, 8))

sorted_idx = np.argsort(feature_importances)

plt.barh(range(X.shape[1]), feature_importances[sorted_idx], align='center')

plt.yticks(range(X.shape[1]), X.columns[sorted_idx])

plt.xlabel('Özellik Önemi')

plt.title('Model Özelliklerinin Önemi')

plt.show()
```



EK E: Kullanıcı Arayüzü Tasarım Kodu

```
from PySide6 import QtCore, QtGui, QtWidgets

class Ui_Form(object):

    def setupUi(self, Form):

        Form.setObjectName("Form")

        Form.resize(373, 288)

        self.gridLayout_2 = QtWidgets.QGridLayout(Form)

        self.gridLayout_2.setObjectName("gridLayout_2")

        self.gridLayout = QtWidgets.QGridLayout()

        self.gridLayout.setObjectName("gridLayout")

        self.horizontalLayout = QtWidgets.QHBoxLayout()

        self.horizontalLayout.setObjectName("horizontalLayout")

        self.verticalLayout = QtWidgets.QVBoxLayout()

        self.verticalLayout.setObjectName("verticalLayout")

        spacerItem = QtWidgets.QSpacerItem(20, 40,
QtWidgets.QSizePolicy.Minimum, QtWidgets.QSizePolicy.Expanding)

        self.verticalLayout.addItem(spacerItem)

        self.pushButton_musteriTalebi = QtWidgets.QPushButton(Form)

        self.pushButton_musteriTalebi.setObjectName("pushButton_musteriTalebi")

        self.verticalLayout.addWidget(self.pushButton_musteriTalebi)

        self.pushButton_modelBelirle = QtWidgets.QPushButton(Form)

        self.pushButton_modelBelirle.setObjectName("pushButton_modelBelirle")

        self.verticalLayout.addWidget(self.pushButton_modelBelirle)

        self.pushButton_teklifVer = QtWidgets.QPushButton(Form)

        self.pushButton_teklifVer.setObjectName("pushButton_teklifVer")

        self.verticalLayout.addWidget(self.pushButton_teklifVer)
```

```

        spacerItem1 = QtWidgets.QSpacerItem(20, 40,
QtWidgets.QSizePolicy.Minimum, QtWidgets.QSizePolicy.Expanding)

        self.verticalLayout.addItem(spacerItem1)

        self.horizontalLayout.addLayout(self.verticalLayout)

        self.gridLayout.addLayout(self.horizontalLayout, 0, 0, 1, 1)

        self.verticalLayout_2 = QtWidgets.QVBoxLayout()

        self.verticalLayout_2.setObjectName("verticalLayout_2")

        self.textBrowser_log = QtWidgets.QTextBrowser(Form)

        self.textBrowser_log.setObjectName("textBrowser_log")

        self.verticalLayout_2.addWidget(self.textBrowser_log)

        self.gridLayout.addLayout(self.verticalLayout_2, 0, 1, 1, 1)

        self.gridLayout_2.addLayout(self.gridLayout, 0, 0, 1, 1)

        self.retranslateUi(Form)

        self.pushButton_musteriTalebi.clicked.connect(Form.pushButton_musteriTalebi_clicked)
# type: ignore

        self.pushButton_modelBelirle.clicked.connect(Form.pushButton_modeliBelirle_clicked)
# type: ignore

        self.pushButton_teklifVer.clicked.connect(Form.pushButton_teklifVer_clicked)
# type: ignore

        QtCore.QMetaObject.connectSlotsByName(Form)

    def retranslateUi(self, Form):
        _translate = QtCore.QCoreApplication.translate

        Form.setWindowTitle(_translate("Form", "Form"))

        self.pushButton_musteriTalebi.setText(_translate("Form", "Yeni Müşteri Talebi"))

        self.pushButton_modelBelirle.setText(_translate("Form", "Modeli Belirle"))

        self.pushButton_teklifVer.setText(_translate("Form", "Teklif Oluştur"))

```

```

        self.textBrowser_log.setHtml(_translate("Form",
        "<!DOCTYPE    HTML
PUBLIC   \"/>

```

ÖZGEÇMİŞ

Ad-Soyad : Deniz Işıl ŞİMŞEK

ÖĞRENİM DURUMU:

- **Lisans** : 2019, İstanbul Teknik Üniversitesi, İşletme Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2024, İstanbul Teknik Üniversitesi, İşletme Fakültesi, Endüstri Mühendisliği (YL)

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2019-2021 yılları arasında Eczacıbaşı Tüketim Ürünleri'nde proje ve yatırımlar uzmanı olarak görev aldı.
- 2021 yılından itibaren Kopitek Kopyalama Sistemleri LTD ŞTİ firmasında satış müdürü olarak görev alıyor.
- 2024 yılında İstanbul Teknik Üniversitesi'nde yüksek lisansını tamamladı.