



**MÜŞTERİ ŞİKAYETLERİNİN
SINIFLANDIRILMASI İÇİN DERİN ÖĞRENME
VE MAKİNE ÖĞRENMESİ UYGULAMALARI**

Zeliha MAHMAT

Danışman: Doç. Dr. Burak ERKAYMAN

İkinci Danışman: Dr. Öğr. Üyesi Tolga AYDIN

Yüksek Lisans Tezi

Endüstri Mühendisliği Ana Bilim Dalı

2022

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

**MÜŞTERİ ŞİKAYETLERİNİN SINIFLANDIRILMASI İÇİN DERİN ÖĞRENME
VE MAKİNE ÖĞRENMESİ UYGULAMALARI**

(Deep Learning And Machine Learning Applications For Classification Of Customer
Complaints)

YÜKSEK LİSANS TEZİ

Zeliha MAHMAT

Danışman: Doç. Dr. Burak ERKAYMAN
İkinci Danışman: Dr. Öğr. Üyesi Tolga AYDIN

Erzurum
Mayıs, 2022

KABUL VE ONAY TUTANAĞI

Zeliha MAHMAT tarafından hazırlanan “Müşteri Şikayetlerinin Sınıflandırılması İçin Derin Öğrenme ve Makine Öğrenmesi Uygulalamaları” başlıklı çalışması 24/ 05 / 2022 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Endüstri Mühendisliği Ana Bilim Dalı, Yöneylem Bilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Başkanı:	Doç. Dr. Mustafa YILMAZ <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Danışman:	Doç. Dr. Burak ERKAYMAN <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Doç. Dr. Muhammed Emre KESKİN <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Dr. Öğr. Üyesi Hamid YILMAZ <i>Bayburt Üniversitesi</i>	Aslı Islak İmzalıdır
İkinci Tez Danışmanı	Dr. Öğr. Üyesi Tolga AYDIN <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır

Enstitü Yönetim Kurulunun
.../.../.... tarih ve sayılı
kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Saltuk Buğrahan CEYHUN

Enstitü Müdürü

Aslı Islak İmzalıdır

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

**FEN BİLİMLERİ ENSTİTÜSÜ**Graduate School of Natural and
Applied Sciences**T.C.
ATATÜRK ÜNİVERSİTESİ REKTÖRLÜĞÜ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ****ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU**

Yüksek Lisans Tezi olarak *Doç. Dr. Burak ERKAYMAN* danışmanlığında sunulan “Müşteri Şikâyetlerinin Sınıflandırılması İçin Derin Öğrenme ve Makine Öğrenmesi Uygulamaları” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	3	30
Kuramsal Temeller	0	30
Materyal ve Yöntem	9	35
Bulgular	1	20
Tartışma	0	20
Tezin Geneli	5	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Zeliha MAHMAT	Doç. Dr. Burak ERKAYMAN
24.5.2022	24.5.2022
İmza: Aslı Islak İmzalıdır	İmza: Aslı Islak İmzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/.../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/.../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Tezimi hazırlama sürecinde bana aktarmış olduğu değerli bilgileriyle, benim her soruma içtenlikle cevap verip tezimi yazmamda bana yardımcı olan çok değerli hocam Saygıdeğer Doç. Dr. Burak ERKAYMAN'a içtenlikle ve sonsuz bir saygı ile teşekkürlerimi sunuyorum.

Hayatım boyunca benim hep arkamda olan ve desteklerini hiçbir zaman esirgemeyen başta annem ve kız kardeşim olmak üzere aileme ve arkadaşlarıma çok teşekkür ediyorum.

Zeliha MAHMAT



ÖZET

YÜKSEK LİSANS TEZİ

MÜŞTERİ ŞİKAYETLERİNİN SINIFLANDIRILMASI İÇİN DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ UYGULAMALARI

Zeliha MAHMAT

Danışman: Doç. Dr. Burak ERKAYMAN
İkinci Danışman: Dr. Öğr. Üyesi Tolga AYDIN

Amaç: Bu çalışmada online bir müşteri şikayet çözüm sitesine gelen müşteri şikayetlerinden ve müşteri şikayet çözümlerinden kaynaklanan marka/işletme değişimi üzerine durulmuştur. Müşteri şikayetleri baz alınarak 16 farklı markaya ait marka değişimlerinin sınıflandırması yapılmıştır.

Yöntem: Bu çalışma kapsamında yapay zekanın alt dalları olan makine öğrenme, derin öğrenme sınıflandırma modelleri kullanılmış ve geliştirilmiştir. Derin öğrenme alanında yeni ResNET algoritması geliştirilerek klasik makine öğrenmesi sınıflandırma algoritmaları ile karşılaştırılması yapılmıştır. Aynı zamanda hem geliştirilen ResNET modeli hem de klasik makine öğrenmesi sınıflandırma algoritmaları veri artırmadan önce ve sonra çıkan sonuçlar bakımından karşılaştırılmıştır.

Bulgular: Uygulama yapılırken bir şikayette bulunan müşterinin şikayetin çözüm aşamasında memnuniyet ve memnuniyetsizliklerini belirleyen çok sayıda etkenin olduğu ortaya çıkmıştır. Müşterilerin, şikayetlerin çözüm aşamasındaki memnuniyet derecelerinin marka/işletme değişimleri açısından oldukça etkili olduğu gözlemlenmiştir.

Sonuç: Uygulama sonucunda elde edilen verilere göre veri artırmadan önce ve sonra geliştirilen yeni ResNET modeli klasik makine öğrenmesi sınıflandırma algoritmalarına benzer veya daha yüksek sonuçlar verdiği gözlemlenmiştir.

Anahtar Kelimeler: Müşteri Şikayetleri, Marka Değişimi, Yeni ResNET Modeli, Makine Öğrenmesi Sınıflandırma Algoritmaları

Mayıs 2022, 59 Sayfa

ABSTRACT

MASTER THESIS

DEEP LEARNING AND MACHINE LEARNING APPLICATIONS FOR CLASSIFICATION OF CUSTOMER COMPLAINTS

Zeliha MAHMAT

Supervisor: Assoc. Prof. Dr. Burak ERKAYMAN

Co-supervisor: Assist. Prof. Dr. Tolga AYDIN

Purpose: In this study, the focus is on the brand/business change resulting from customer complaints coming to an online customer complaint resolution site and customer complaint resolution. Based on customer complaints, brand changes belonging to 16 different brands were classified.

Method: Within the scope of this study, machine learning and deep learning classification models, which are sub-branches of artificial intelligence, were used and developed. In the field of deep learning, a new ResNET algorithm has been developed and compared with classical machine learning classification algorithms. At the same time, both the developed ResNET model and classical machine learning classification algorithms were compared in terms of results before and after data augmentation.

Findings: It has been revealed that there are many factors that determine the satisfaction and dissatisfaction of the customer who made a complaint during the application process. It has been observed that the satisfaction levels of the customers in the resolution phase of the complaints are quite effective in terms of brand/business changes.

Results: According to the data obtained as a result of the application, it has been observed that the new ResNET model developed before and after the data augmentation gives similar or higher results than the classical machine learning classification algorithms.

Keywords: Customer Complaints, Brand/Business Change, New ResNET Model, Machine Learning Classification Algorithms

May 2022, 59 Pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR DİZİNİ	x
GİRİŞ.....	1
KURAMSAL TEMELLER.....	8
Müşteri Şikâyeti	8
Müşteri şikâyetinin anlamı.....	8
Müşteri şikâyetinden yararlanma	9
Müşteri şikâyetlerinin önemi.....	9
Müşteri şikâyetlerinin çözümü.....	9
Yaygın müşteri şikâyetleri ve çözümleri.....	10
Müşteri şikâyetlerinin çözümünde dikkat edilmesi gerekenler.....	11
Müşteri memnuniyeti	11
Müşteri memnuniyetini yerine getirmek için yapılması gerekenler	12
Müşteri sadakati	12
MATERYAL VE YÖNTEM	13
Yapay Zeka	13
Makine Öğrenmesi	13
Denetimli/Gözetimli makine öğrenmesi	15
Denetimsiz/Gözetimsiz makine öğrenmesi.....	17
Takviyeli/Pekiştirmeli öğrenme	17
Kullanılan Denetimli/Gözetimli Makine Öğrenme Algoritmaları.....	18
Karar ağaçları	18
Diskriminant analizi	19
Lojistik regresyon.....	19
Naif bayes.....	19
Destek vektör makinaları	20

K-En yakın komşu	21
Sınıflandırma Algoritmaları Performans Ölçütleri	22
Karmaşıklık matrisi (confusion matrix)	22
ROC eğrisi.....	23
Derin Öğrenme.....	24
Kullanılan Derin Öğrenme Teknikleri	25
Evrişimsel sinir ağı.....	25
ESA Mimarisi Katmanları.....	26
Önerilen Resnet Algoritması.....	26
Derin Öğrenmede Dikkat Edilmesi Gerekenler	28
ARAŞTIRMA BULGULARI	29
Veri Artırma	32
Makine Öğrenme Algoritmaları ve Öneriler ResNET Modeli Sonuçları	32
TARTIŞMA VE SONUÇ.....	38
KAYNAKÇA	42
ÖZGEÇMİŞ.....	47

TABLÖLAR DİZİNİ

Tablo 1. Karmaşıklık Matrisi Örneği.....	22
Tablo 2. Verilerin Sütun Bazlı Özellikleri.....	30
Tablo 3. Verilerin Sütun Bazlı Numerik Değerleri.....	30
Tablo 4. Veri Seti Dağılımı.....	32
Tablo 5. Veri Artırmadan Önceki Değerler	32
Tablo 6. Veri Artırmadan Sonraki Değerler	33
Tablo 7. Veri Artırımından Önce Karmaşıklık Matrisi	33
Tablo 8. Veri Artırmadan Sonra Karmaşıklık Matrisi	34



ŞEKİLLER DİZİNİ

Şekil 1. Karar ağacı algoritması genel yapısı	18
Şekil 2. Destek vektör makinası genel görünüm	21
Şekil 3. K-en yakın komşu genel görünüm	21
Şekil 4. ROC eğrisi grafiği	23
Şekil 5. Yapay sinir ağları(sol) ve derin yapay sinir ağları(sağ) görünümü	24
Şekil 6. Önerilen ResNet Tabanlı Mimari	28
Şekil 7. Sırası ile veri artırmadan önce ve sonra önerilen ResNet1 sonuçları	34
Şekil 8. Sırası ile veri artırmadan önce ve sonra önerilen ResNet2 sonuçları	34
Şekil 9. Sırası ile veri artırmadan önce ve sonra SVM sonuçları	35
Şekil 10. Sırası ile veri artırmadan önce ve sonra Lojistik Regresyon sonuçları	35
Şekil 11. Sırası ile veri artırmadan önce ve sonra Karar Ağacı sonuçları	35
Şekil 12. Sırası ile veri artırmadan önce ve sonra Naive Bayes sonuçları	36
Şekil 13. Sırası ile veri artırmadan önce ve sonra k-NN sonuçları	36
Şekil 14. Sırası ile veri artırmadan önce ve sonra LDA sonuçları	36
Şekil 15. Veri artırmadan sonra önerilen ResNet2 sonuçları	37

KISALTMALAR DİZİNİ

AI	Yapay Zeka/ Artificial Intelligence
AI-CRM	Yapay Zeka Odaklı Müşteri İlişkileri Yönetimi
CRM	Müşteri İlişkileri Yönetimi/ Customer Relations Management
DA	Diskriminant Analizi/Discriminant Analysis
DBN	Derin İnanç Ağları/Deep Belief Networks
DenseNet	Yoğun Evrişimli Ağ/ Dense Convolutional Network
DSA/DNN	Derin Sinir Ağları/Deep Neural Networks
DT	Karar Ağaçları/Decision Trees
DVM/SVM	Destek Vektör Makinaları/Support Vector Machines
ESA/CNN	Evrişimli Sinir Ağları/Convolutional Neural Networks
k-NN	K-En Yakın Komşu/K-Nearest Neighbor
LDA	Lineer Diskriminant Analizi
LIBS	Lazer Kaynaklı Arıza Spektroskopisi/Laser Induced Breakdown Spectroscopy
LR	Lojistik Regresyon/Logistic Regression
LSTM	Uzun Kısa Süreli Bellek/Long Short Term Memory
MLR	Çok Değişkenli Doğrusal Regresyon/Multivariate Linear Regression
NB	Naif Bayes/Naive Bayes
NN	Sinir Ağları/Neural Networks
PR	Polinom Regresyon/Polynomial Regression
RBM	Sınırlı Boltzman Makinaları/Restricted Boltmann Machines
ReLu	Düzeltilmiş Doğrusal Birim/Rectified Linear Unit
ResNet	Artık Sinir Ağı/Residual Neural Network
RNN	Tekrarlayan Sinir Ağı/Recurrent Neural Network
ROC	Alıcı İşletim Karakteristiği/Receiver Operating Characteristic
SLR	Basit Doğrusal Regresyon/Simple Linear Regression
YSA/ANN	Yapay Sinir Ağları /Artificial Neural Networks

GİRİŞ

İşletmeler teknoloji ile birlikte gelişen dünya ekonomisinde rekabetçi bir ortamda bulunmaktadırlar. Her işletme bu rekabetçi ortamda ayakta durabilmek için müşteri öncelikli davranmak zorundadır. Müşteri memnuniyet ve şikayetlerinin işletmelerin geleceğini belirlemesi de kaçınılmaz bir durum olarak karşımıza çıkmaktadır. İşletmeler kendilerine gelen şikayetleri öğrenerek ve bu şikayetleri ortadan kaldırarak müşteri memnuniyetini maksimum noktaya getirmek istemektedirler.

İşletmeler kendileri ile ilgili şikayetleri hem birebir iletilen müşteri çağrı merkezlerinden hem de genel anlamda bütün işletme markalarının şikayetlerinin alındığı web sitelerinden öğrenme şansına sahipler. Müşteri şikayetlerinin alınması ile birlikte bu şikayetlerin nedenlerinin ortadan kaldırılması için hem işletmeler hem de müşteriler ile iletişime geçilerek sorun halledilmeye çalışılır. Sorunların çözüme ulaşp ulaşmaması durumunda müşteriler marka değişikliğine gitme ya da gitmeme kararı alabilirler. Tabi ki müşterilerin marka değiştirme kararları işletmeler açısından istenilen bir durum değildir. Bu konuyla ilgili müşteri memnuniyetinin artmasına yönelik yapılan çalışmaların müşteri şikayetini azaltacağı ve müşterilerin sadakatini artıracacağı su götürmez bir gerçektir (Baytekin 2005).

Müşteri şikayetleri ve memnuniyetinin bütün iş sektörlerinde ne kadar önemli olduğu bilinen bir gerçektir. Müşteri şikayetleri hakkında yapılan akademik çalışmalar bu konunun ne kadar önemli olduğunu ortaya koymaktadır: Kamil vd. (2010) çalışmalarında paket turlar ile yolculuk yapanların seyahat acenteleriyle ilgili şikayetleri üzerine durmuşlardır. Albayrak (2013) restoran işletmelerinde müşteri şikayet ve davranışlarını inceleyen bir çalışma yapmıştır. Güler (2020) çalışmasında müşteri şikayeti alan online bir şikayet sitesine Koronavirüs (Covid-19) hastalığı günlerinde bankalar hakkında yapılan şikayetlerin kategorilerinin belirlenmesi, aynı zamanda müşteri isteklerinin neler olduğu üzerinde durmuş ve ayrıntılı incelemeler yapmıştır. Müşteri şikayet, istek ve görüşlerinin bu kadar önemli olduğu günümüz çağında ise teknolojik imkanlardan yararlanmak oldukça önemlidir. Çünkü teknolojinin gelişmesi ile birlikte insanların davranışlarını ve bu davranışlarının sonuçlarını önceden bilmek veya büyük çoğunluğunu tahmin etmek mümkündür. Gelişen teknolojinin en önemli sonuçlarından biri olan yapay zeka ve makine öğrenmesi, derin öğrenme gibi alt dalları bunun en güzel örneğini oluşturmaktadır. Günümüzde her alanda kolaylık sağlanan gelişmelere ek olarak müşteri

şikayetleri, memnuniyeti ve istekleri de yapay zeka ile analiz edilmektedir. Yapay zeka ile bir durum karşısında müşterilerin daha önceki davranışlarına bakılarak yeni ve benzer bir durum karşısında nasıl tepkiler vereceği ya da daha önce yaşanmamış bir durum karşısında nasıl tepkiler vereceği tahmin edilebilir hale gelmiştir. Teknolojik olarak gelişen günümüz koşullarında yapay zekanın ve makine öğrenmesinin her alanda yer alması, uygulanabiliyor olması bize bu konunun ne kadar önemli ve hayat kolaylaştırıcı olduğunu gözler önüne sermektedir. Yapay zeka ve makine öğrenmesi ile ilgili her alanda yapılan akademik araştırmalar da bize bunun açık bir örneğini göstermektedir. Bunlar içerisinde: Aydın (2018) çalışmasında itfaiye istasyonlarının makine öğrenme algoritmaları ile sınıflandırmasını yapmıştır. Karaoğlu (2015) çalışmasında spor müsabakalarının makine öğrenme algoritmaları ile modellenmesi üzerinde durmuştur. Avcı (2021) çalışmasında yapay zekayı vergi tahsilatında kullanmış ve önemi üzerine durmuştur. Şen ve Yurtoğlu (2020) çalışmalarında yapay zekayı istihbarat için analiz yapmada kullanmışlardır. Serçemeli (2018) ise çalışmasında yapay zekayı muhasebe alanında kullanmış ve analizlerini dijital dönüşüm çerçevesinde ele almıştır. Görüldüğü üzere yapay zeka ve makine öğrenmesi her türlü alanda kullanılabilir. İşletmeler için de makine öğrenmesi ve derin öğrenme müşteri davranışlarının sonuçlarının tahmini ya da sınıflandırması üzerinde kullanılarak fayda sağlama amacıyla kullanılabilir. Yine müşterilerin baz alınarak analiz edildiği akademik çalışmalarda bu konuyla ilgili yöntemler uygulanmıştır. Yapılan bazı araştırmalar ise şu şekildedir: Ramaswamy ve DeClerck (2018) tarafından yapılan çalışmada, müşteri görüşlerinin analize tutulması ile ilgili derin öğrenme ve doğal dil işleme teknolojileri sunulmuştur. Baydogan ve Alatas (2019) tarafından yapılan çalışmada ise müşteri memnuniyetinin makine öğrenme algoritmaları ile tespiti yapılmıştır.

Bu çalışmada da online şikayet toplama sitesine gelen şikayetler göz önüne alınarak marka değişikliğine gitmek isteyen müşterilerin sınıflandırılması yapılmıştır. En çok şikayet alan 16 farklı markanın şikayet ve çözüm aşamasındaki müşteri özellikleri çıkarılarak müşterilerin marka değiştirmek isteyip istememesi şeklinde iki seçenekli bir sınıflandırmanın derin öğrenme ve makine öğrenme teknikleri ile sonuçları analiz edilmiştir. Böylelikle müşteri şikâyetlerinin çözüme ulaştırılmasının işletmeler için ne kadar önemli olduğuna dikkat çekilmiştir. Aynı zamanda bu tez çalışmasında müşteri şikâyetinin ne anlama geldiği, müşteri şikâyetlerinden nasıl yararlanılması gerektiği, müşteri şikâyetlerinin işletmeler/markalar açısından neden önemli olduğu, müşteri şikâyetlerinin nasıl çözülmesi gerektiği, nelere dikkat edilmesi gerektiği, müşteri memnuniyeti derecesinden kişilerin marka değişikliğine gidip gitmemesi hakkında ayrıntılı bilgi verilmiştir.

Bu tez çalışmasının literatüre katkıları ise şu şekildedir: İlki, bilindiği kadarıyla elde edilen veri seti ilk kez kullanılmış ve elde edilen veri setine veri artırma işlemi uygulanmıştır; ikincisi ise literatürde mevcut modellere ek yeni iki ResNet tabanlı modelin sunulması ve önerilen bu modellerin makine öğrenme modelleri ile karşılaştırması yapılmıştır.

Bu tez çalışması kapsamında yapılan kaynak araştırması aşağıda verilmiştir:

De Cnudde and Martens (2015), müşteri sadakat programları üzerine yaptıkları çalışmada Belçika şehrinde yaşayan insanların katıldığı bir anket yapmışlardır. Müşterilere sadakat kartları dağıtılarak kullanıcıların sadakat kartlarını aktif bir şekilde kullanıp kullanmayacakları, müşterilerin hangi şehri ziyaret edecekleri üzerine sınıflandırma çalışması yapmışlardır. Makine öğrenme algoritmalarından Naive Bayes ve DVM modellerinin kullanıldığı bu çalışmada çıkan doğruluk sonuçları %92.5 ve %85.5 olarak bulunmuştur.

Vafeiadis *et al.* (2015), müşteri kayıplarının tahmini için makine öğrenme tekniklerini kullanmışlardır. Çalışmalarında bir telekomünikasyon sektöründeki müşterilerin çalkantı sorunları üzerinde durmuşlardır. Bu çalkantı sorunlarının tahminin de ise çok katmanlı YSA, DT, DVM, Naive Bayes ve Lojistik Regresyon tekniklerini kullanmışlardır. En yüksek doğruluk değerini ise %94 ile DT modeli vermiştir.

Vidya *et al.* (2015), Twitter'daki verilerden yararlanarak müşteri memnuniyetine dayalı olan marka itibarını ölçmüşlerdir. Endonezya'da yapılan çalışmada en iyi üç mobil sağlayıcı şirketin Ocak-Mart 2015 arasındaki 10.000 ham Twitter mesajından özellik çıkarımı yapmışlardır. Veri dengeleme ve veri temizleme işlemlerinden sonra veriler Naive Bayes, Destek Vektör Makinası ve Karar Ağacı modelleri ile sınıflandırılmıştır.

Takahashi *et al.* (2015), postayla sipariş endüstrisinde şüpheli müşterilerin müşteri özelliklerini makine öğrenme yöntemiyle analiz etmektedirler. Yaptıkları bu çalışmada Japonya'daki postayla sipariş müşterilerine yönelik teslimat adresi, ödeme yöntemi ve alıcının adı gibi bilinmesi zorunlu özelliklerden yararlanmışlardır. Çalışmanın sonucunda ise kasıtlı müşteriler ile dikkatsiz müşterilerin sınıflandırıldığı ortaya konmuştur.

Maldonado *et al.* (2015), çalışmalarında müşteriye elde tutma ve kar getirme amaçlı makine öğrenme tekniklerinden DVM'yi kullanmışlardır. Sınıflandırıcı yapımı ve DVM'ye dayalı eşzamanlı değişken seçimi için kâr odaklı bir yaklaşım önermişlerdir. Deneysel çıktılarından, uygulanan modellerin işle ilgili hedeflere oranla üstün performans sağlayan özellik seçimi için geleneksel yöntemlerden daha iyi performansa sahip olduklarını göstermişlerdir.

Kuswanto *et al.* (2015), müşterilerin hatalarını tahmin etmek üzerine çalışmışlardır. İnceleme amaçlı ele aldıkları şirket müşterilerin ürünleri belli bir süre sonra kusurlu hale

getirme veya elde tutma seçeneğine sahip üç ürün (düşük, orta ve yüksek fiyatlı) satmaktadır. Şirketin bu ürünleri alan müşteriler için çok yüksek veriler toplaması boyutsallık nedeniyle genel istatistiksel modellerin uygulanamamasına yol açtığından Lojistik Regresyon topluluğu “LOREANS” modelini kullanmışlardır. Elde edilen sonuçlarda LOREANS standart olarak kullanılan lojistik regresyon yöntemi kadar iyi bir tahmin yeteneğine sahip olduğunu ortaya çıkarmışlardır. Bu değerler %66 ile %77 arasında bir tahmin doğruluğunu vermektedir.

Coussement *et al.* (2015), birden fazla bilgi kaynağını tek bir Karar Destek Sisteminde birleştirerek Bayesci bir çerçeveye ile müşteri memnuniyeti tahmin modeli üzerinde durmuşlardır.

Cheng *et al.* (2015), makina sanayisinde kullanılan depolarda müşteri memnuniyetinin sağlanmasında Karar Destek Sistemi kullanmışlardır. Bunu yaparken de İş Akışı Karar Destek Sistemi kullanmışlardır. Gerçek zamanlı verileri yakalamak için radyo frekansı tanımlamasını kullanmışlardır.

Chen *et al.* (2016), çalışmalarında müşteri davranış verileri üzerine çalışmışlardır. Çalışmalarında yeni bir topluluk öğrenme modeli olan Çok Çekirdekli Destek Tensör Makinası geliştirmişlerdir. Bu model ile çok yönlü ve çok yollu veriler üzerinden özellik çıkarımı yapılabileceğini göstermişlerdir. Geliştirilen bu topluluk öğrenme modelinin diğer öneri yöntemlerinden daha iyi sonuçlar verdiğini göstermişlerdir.

Aguwa *et al.* (2017), bulanık tabanlı müşteri sesinin modellenmesinde iş karar analitiğinin uygulanmasına yönelik çalışma yapmışlardır. Müşterilerin bulanık sesinin yanlışsız bir şekilde analizi için yeni bir yaklaşım geliştirmişlerdir. Bunu da metin madenciliği ve birliktelik kuralını baz alarak yapmışlardır. Sonuç olarak müşterilerin ses analizinin bulanık olarak incelenmesi daha sağlıklı sonuçlar elde edileceğini göstermiştir. Böylelikle müşteri gereksinimlerinin belirlenmesine de katkı sağlamaktadır.

Stevens *et al.* (2018), çevrimiçi müşteri şikayetleriyle ilgilenmek için birkaç pratik çözüm üzerinde durmuşlardır. Bu çalışmalarında yöneticilerin ve destek ekiplerinin çevrimiçi şikayetlere mantıklı ve anlaşılır bir şekilde yanıt vermelerine yardımcı olacak şekilde tasarlanmış bir çerçeve sunmuşlardır.

Béal and Sabadie (2018), müşterilerin firmaya katılımlarının müşteriler üzerinde nasıl bir etkisinin olacağı üzerine teorik bir çalışma yapmışlardır. Müşterilerin firma yönetimine dâhil edilmesiyle hem bağlılıkları hem de sözel iletişim açısından gelişme gösterdikleri görülmüştür.

Segar-Guttmann *et al.* (2018), müşteri mal iade koşullarının ve çalışan tepkilerinin müşterilerin sadakatleri üzerindeki etkisini ve bu etkinin etik uyumsuzluk kapsamında değerlendirmesini yapmışlardır.

Yang Y. *et al.* (2018), müşteri şikâyetlerini ele almak için yeni bir karar destek sistemi oluşturmuşlardır. Müşteri şikâyetlerini belirsiz bilgilerle sınıflandırmak için kanıta dayalı akıl yürütme kural tabanlı bir sınıflandırıcı geliştirmiş ve makine öğrenmesi tekniklerini kullanmışlardır. Kanıta dayalı akıl yürütme kuralını daha sonra birden fazla kanıtı birleştirmek ve müşteri şikâyetlerini olasılıklarla farklı kategorilerde sınıflandırmak için denemişlerdir. Çalışmalarını bir telekomünikasyon şirketinde ve ampirik olarak yapmışlardır. Sonuçlarda, önerilen kanıta dayalı akıl yürütme kural tabanlı sınıflandırma modelinin diğer makine öğrenmesi algoritmalarına göre yüksek performans sağladığını görmüşlerdir.

Zhong *et al.* (2019), bina kalitesi şikâyetlerini metinsel olarak sınıflandırmak için derin öğrenme tabanlı evrimsel sinir ağlarını (CNN) kullanmışlardır.

Kwon *et al.* (2020) çalışmalarında, bir restoran ortamında müşterilerin değerlerini belirleyen faktörlerin çevrimiçi incelemesini makine öğrenme tabanlı doğal dil işleme tekniklerini kullanarak analiz etmişlerdir. Elde edilen sonuçlar ile müşterilerin değerlerine yönelik nicel ölçümlerinin test edilmesini sağlayan bir çerçeve sunmuşlardır.

Khedkar and Shinde (2020) çalışmalarında, müşterilerin ürün veya hizmet alması sonucunda övgü ve şikâyetlerin sınıflandırması üzerine durmuştur. Makine öğrenmesi teknikleri, topluluk sınıflandırıcı, yoğun sinir ağları, derin öğrenme tabanlı CNN tekniğini kullanarak çıkan sonuçları karşılaştırmıştır. Sonuçlar dikkate alındığında topluluk sınıflandırıcı ve derin öğrenme tabanlı tekniklerin doğruluk oranlarının daha iyi olduğu görülmüştür.

Nilashi *et al.* (2021) çalışmalarında, vejetaryen dostu restoranlarda müşteri segmentasyonu ve tercihlerinin tahmin edilmesi için etkili öğrenme teknikleri aracılığıyla yeni bir metin madenciliği yöntemi geliştirmişlerdir. Vejetaryen dostu restoranlarda müşterilerin hizmet kalitesinden memnuniyet düzeylerini ortaya çıkarmak için küme analizi (Kendi Kendini Düzenleyen Harita) ve tahmine dayalı öğrenme tekniği (Sınıflandırma ve Regresyon Ağaçları) kullanmışlardır. Bangkok'taki vejetaryen dostu restoran verileri üzerinde yaptıkları deneylerin elde edilen sonuçlarına dayanarak, Sınıflandırma ve Regresyon Ağaçları ile oluşturulan modeller, restoranların kalite faktörlerine dayalı olarak müşterilerin tercihlerinin doğru bir tahminini verebilmiştir.

Singh *et al.* (2021), müşteri şikayetlerinin tanımsal olarak çözmek için yarı denetimli bir öğrenme üzerinde çalışmışlardır. Sınıflandırmada grafik tabanlı bir yaklaşımla denetimli öğrenmeyi müşteri şikayetlerini ele alarak incelemişlerdir.

Gupta *et al.* (2021), demiryolu şikayetlerinin sınıflandırması üzerine bir çalışma yapmışlardır. Çalışmada Hindistan demiryolu hakkında elde edilen şikayetler baz alınmıştır. Kullanıcıların şikayet girişlerini analiz eden, karakter seviyesini yakalayan ve gelen şikayetleri ilgili departmana göndererek sınıflandırma yapan bir Uzun-Kısa Vadeli Bellek (LSTM) modeli geliştirmişlerdir.

Vo *et al.* (2021), müşteri kaybı tahmin modeli üzerine çalışma yapmışlardır. Bir çağrı merkezinden elde edilen veri seti üzerinde kapsamlı deneyler gerçekleştirmişlerdir. Müşteri kaybı riskini doğru bir şekilde tahmin edebilmek için yorumlanabilir makine öğrenmesi kullanmışlardır. Sonuç olarak anlamlı bilgilerin elde edildiği ortaya çıkmıştır.

Albrecht *et al.* (2021), çevrimiçi müşteri şikayet ve destek incelemesini 174.5 hafta boyunca yaparak makine öğrenme algoritmaları ve en çok kullanılan zaman serisi modellerini karşılaştırmışlardır.

Osorio-Arjona *et al.* (2021) çalışmalarında, Twitter'daki Madrid Metro hesabına gelen müşteri şikayetlerinin mekânsal dağılımı üzerine bir çalışma yapmışlardır. Gelen şikayetlerin metinsel değerlerini ve bu şikayetlerinin nüfus, gelir düzeyi gibi faktörlere bağlı olarak mekânsal dağılımını analiz etmişlerdir. Bu amaçla Madrid Metro Twitter hesabına gelen mesajları iki ay boyunca toplamışlardır. Müşteri şikayetlerinin duygu analizi üzerinden belirlenmesi için ise metin madenciliği ve makine öğrenme algoritmalarını birlikte kullanmışlardır. En son ise bir coğrafi ağırlıklı regresyon modeli kullanmış ve şikayetçilerin mekânsal dağılımının nedenselliğini araştırmışlardır. Çıkan sonuçlara göre atılan mesajlardan gelen müşteri şikayetlerinin yakın bölgelerde oturan ve işyerlerine gitmekte olan orta gelirli işçiler tarafından atıldığını tespit etmişlerdir.

Gaur *et al.* (2021) çalışmalarında, 50 küresel ölçekli otel müşterilerinin 45.500 adet yorumlarını çeşitli çevrimiçi inceleme sitelerinden elde ederek makine öğrenmesinde doğal dil işleme, metin madenciliği, duygu analizi gibi teknikleri kullanmışlardır. Yaptıkları çalışmada otellerde konaklayan hem tatmin olmuş hem de hayal kırıklığına uğramış müşterilerinin yemek, konaklama, servis, personel ve odalar olmak üzere 5 kategorinin üzerinde durduklarını ortaya çıkarmışlardır.

Li and Xu (2022) çalışmalarında, müşteri ilişkileri yönetiminde (CRM) yapay zeka odaklı bir teknoloji önermişlerdir. Önerdikleri modelde girdi ve çıktılar arasında ilişki kurmak

için süreç, sistem ve matematiksel modeller düzeyinde mimari tasarlamışlardır. Anket tekniği kullanarak elde ettikleri ilk verilerden bir veri seti oluşturmuşlardır. Yaptıkları çalışma sonucunda müşterilerin yapay zeka tabanlı teknolojilerin farkında olduklarını, müşterilerin sadık müşteri olduklarını ve önerilen modelin başarılı olduğunu ortaya koymuşlardır.

Bedi and Toshniwal (2022) çalışmalarında, bir sosyal medya sistemi olan Twitter’a atılan mesajların sayısal temsili için kullanılan “Kelime Torbası (BoW)” modelinin eksiklikleri üzerinde durmuşlardır. Yaptıkları çalışmada popüler kelimeler üzerinden yola çıkarak derin öğrenme tabanlı sınıflandırma yapmışlardır. Elde edilen bu popüler kelimeleri iki sınıflandırma veri seti için kullanmışlardır. İlk veri setini duygu sınıflandırma, ikinci veri setini ise şikayet sınıflandırma olarak almışlardır. Kelimeler arasındaki anlamsal ilişkiyi kurmak için farklı kelime yerleştirme modelleri kullanmışlardır. Daha sonra da atılan mesajlardan derin öğrenme tabanlı duygu sınıflandırma modeli oluşturmuşlardır. En son aşamada ise olumsuz duyguları ifade eden mesajların şikayet sınıflandırma modelini oluşturmuşlardır. Sınıflandırmada kullandıkları iki etiket sınıfını ise toplu şikayetler ve bireysel şikayetler olarak belirlemişlerdir.

Chang *et al.* (2022) çalışmalarında, COVID-19’un yolcu seyahat duyarlılığına etkisini ölçmek istemişlerdir. Yolcuların görsel analizleri ve duygu analizleri yoluyla müşteri memnuniyetlerinin ne düzeyde olduklarını araştırmışlardır. Çalışmada Ocak 2016 ile Ağustos 2020 zamanları arasında TripAdvisor’daki uçuş yorumları toplanmış ve incelenmiştir. Müşterilerin duygularını belirlemeyi, bazı kategoriler içindeki derecelendirilmemiş duyguları tahmin etmeyi amaçladıkları bu çalışmada derin öğrenme, doğal dil işleme ve bilgi görselleştirme üzerinde durmuşlardır.

Bu çalışmanın ilerleyen bölümleri şu şekildedir; giriş bölümünde çalışma hakkında hazırlık niteliğinde bilgi verilip kaynak araştırması bölümünde literatür taramasından bahsedilmiştir. Kuramsal temeller bölümünde müşteri şikâyetleri ve çözümleri, müşteri şikayetleri karşısında yapılması gerekenler anlatılacaktır. Materyal ve yöntem bölümünde yapay zekâ, makine öğrenmesi ve derin öğrenme tekniklerinden bahsedilecektir. Araştırma bulguları bölümünde veriler ve yapılmak istenen çalışmanın uygulaması hakkında ayrıntılı bilgi verilecektir. Sonuç kısmında ise makine öğrenme ve derin öğrenme teknikleri karşılaştırılacak, çeşitli önerilerde bulunulacaktır.

KURAMSAL TEMELLER

Müşteri Şikâyeti

Müşterilerin işletmeler açısından ne kadar önemli oldukları bilinen en önemli gerçeklerin başında gelmektedir. Gelişen ve değişen teknoloji ile birlikte işletmeler de müşterilerin görüşlerini daha fazla dikkate almaktadırlar. Müşteri odaklı yapılan çalışmalarda da gelişen teknoloji ile birlikte yapay zeka ve makine öğrenmesi kullanılmakta ve çağımız işletmeleri açısından oldukça fayda sağlamaktadır. Makine öğrenmesi ve derin öğrenme alanında kullanılan algoritmalar müşteri odaklı yapılan çalışmalarda ise şu şekilde karşımıza çıkmaktadır: Ghazzawi ve Alharbi (2019) tarafından yapılan çalışmada şikayet verileri analiz edilerek şirketlerin hizmet kalitesini iyileştirmek ve düşük müşteri memnuniyetine sebebiyet veren faktörlerin tespit edilmesi amaçlanmıştır. Analiz işlemi, veri madenciliği teknikleri kullanılarak yapılmıştır. Kaynar vd. (2017) tarafından yapılan çalışmada telekomünikasyon sektöründe müşteri kaybı tahmini yapılmıştır. Kullanılan sınıflandırma algoritmaları; destek vektör makineleri, naif bayes ve yapay sinir ağlarıdır. 4667 müşteriden oluşan veri tabanı üzerinde gerçekleştirilen analiz sonuçlarında, YSA daha yüksek başarı göstermiştir. Choi (2018) tarafından yapılan çalışmada Koreli bir mobil Telekom şirketinin müşteri şikayetlerini tahmin etmek için makine öğrenimi algoritmaları (ANN, SVM, k-NN, DT) uygulanmıştır. Kullanılan veri tabanı, 10.000 Koreli aboneye ait cinsiyet, yaş, şikayet durumu, hizmet kalitesi değişkenlerini içermektedir. Yapılan deneyler sonucunda, en yüksek başarı %87,3'lük tahmin ile ANN algoritmasından alınmıştır. Müşteri memnuniyetinin önemli olduğu diğer bir sektör bankacılık sektörüdür. Erduran (2017) tarafından yapılan çalışmada, bankaların online müşteri şikayetleri ele alınmıştır. Veri madenciliği yöntemlerinden, birliktelik kuralı, kümeleme yöntemleri ve metin madenciliği algoritmaları ile şikayetler belirlenmiş ve işletmelere müşteri kazanmaları açısından bir şans olarak değerlendirilmiştir.

Müşteri şikâyetinin anlamı

Müşteri şikâyeti işletmelerin/markaların müşterileri ile yaşadıkları olumsuz durumların varlığıdır. Diğer bir deyişle müşterinin işletmeden/markadan beklediği mal ve hizmetteki noksanlığın dışı vurumu olarak da düşünülebilir. Tabi ki müşteri şikâyetlerinin iletişim eksikliği, ürün kalitesi vb. birçok farklı nedeni olabilir. Yine de müşteri şikâyetlerinin işletmeler için bir fırsat olduğu unutulmamalıdır. Bu fırsat markaların kendilerini daha iyi noktalara taşıyabilmelerine yardımcı olmaktadır. Ancak işletmeler ellerindeki fırsatları değerlendirmede

başarısız olurlarsa müşteriler marka değişikliğine gider ve büyük maddi kayıplar ile karşı karşıya gelebilirler (Yeni İş Fikirleri, 2021).

Müşteri şikâyetinden yararlanma

İşletmeler/markalar müşteri şikâyetlerinin gelecekleri açısından çok önemli olduklarının farkında olmalı ve bu şikâyetlerin çözümünde attıkları her adımla avantajlı fırsatlar yakaladıklarını unutmamalıdır. Avantajlı fırsatlar, markaların hizmet/ürün geliştirmesini daha iyi yapabilir, müşterilerin değer gördüklerini ve markaya olan bağlılıklarının artmasını sağlayabilir, çalışanların yetkinlik ve donanımlarının artmasına sebep olabilir (Yeni İş Fikirleri, 2021).

Müşteri şikâyetlerinin önemi

Müşteri şikâyetleri ile işletmeler:

- ❖ Pazar araştırmasına ve geri bildirim anketlerine gerek duymadan ilk ağızdan eksik oldukları alanları fark edebilir, gerekli düzenlemeleri doğru biçimde yapabilirler,
- ❖ Mevcut durumlarının farkına varabilir ve müşterilerin marka değişikliğine gitmesini engelleyebilirler,
- ❖ Müşterileri daha iyi anlamaya başlarlar,
- ❖ Ürün/hizmet geri dönüşlerini daha iyi alırlar, bu da işletmeler/markalar için benzersiz bir büyüme fırsatı olarak karşılına çıkar, iyileştirilmesi gereken alanlara dikkat çeker,
- ❖ Çevrim içi itibarlarının korunmasını sağlayabilirler. Bir taraftan internet ortamında 7/24 aktif olunması diğer taraftan müşteri şikâyetlerinin azaltılmaya çalışılması işletmelere kazanç getirir.
- ❖ Yardımcı ve destek alanlardaki ekiplerin gelişmesini sağlayabilirler.
- ❖ Hızlı ve etkin bir şekilde çözüme ulaştırdıkları her şikâyet sonucunda sadık müşteriler kazanabilirler(Yeni İş Fikirleri, 2021). Bu da marka değişikliği gibi olumsuz durumların yaşanmasına engel olmaktadır.

Müşteri şikâyetlerinin çözümü

Müşteriler bir işletmenin olmazsa olmaz unsurlarından bir tanesidir. Yani müşterilerin memnuniyetini temel almayan bir işletme rekabetçi ortamlarda ayakta durabilecek güce sahip değildir. Müşteri memnuniyetinin sağlanması için ise müşteri şikâyetlerinin üstünde durmak ve hızlı bir şekilde çözümünün yapılması gerekmektedir. Çözüm sürecinde en önemli pay ise müşteri şikâyet ekiplerine düşmektedir. Bu ekipler en kötü ve hırçın müşteriler için eğitilmiş ve

en olumsuz senaryolarda dahi sakinliklerini koruyabilmeli ve çözüm odaklı olmalıdırlar. Çünkü işletmelerin imajları onların iş becerilerine bağlıdır artık (Yeni İş Fikirleri, 2021).

Yaygın müşteri şikâyetleri ve çözümleri

Bekleme süresinin uzunluğu: Çağrı merkezlerinde karşılaşılan ve müşterilerin cevap verilmediği takdirde en fazla iki dakika içerisinde kapatması ile sonuçlanan bir sorundur. Bu sorunun temeli iki nedene dayanmaktadır. Birincisi eleman yetersizliğinden dolayı, ikincisi ise sistem yetersizliğinden dolayıdır. Birinci neden eleman eksikliği giderilerek, ikinci neden ise sistem yazılımlarından yararlanılabilir ya da ilgili elamanlar otomasyon alanında eğitilerek bekleme süresinin uzunluğuna çözüm bulunabilir (Yeni İş Fikirleri, 2021).

Stokta Bulunmayan Ürün: Bir ürünün stokta olmaması işletmeler için iyiye işarettir. Ancak müşterilerin ihtiyacının karşılanmaması durumu istenmeyen bir olaydır. Bu sorunun çözümü için müşteri temsilcilerinin bilgisi olması beklenemez ama konuyla ilgili satış ekibi olaydan haberdar edilmeli ve müşterilere ürün ile ilgili bilgi verileceğinin garantisi verilmelidir (Yeni İş Fikirleri, 2021).

Müşterilerin sürekli sorunlarını anlatması: Bir müşterinin her müşteri temsilcisine sorununu tekrar tekrar anlatmak zorunda kalması halinde yaşanan bir sorundur. Böyle bir sorunla karşı karşıya kalan bir müşteriyi başka temsilcilere bağlamak yerine ilgili temsilci sorunu kendisi çözmeli, uzman görüşüne ihtiyacı olsa dahi bunu bizzat kendisi vermelidir (Yeni İş Fikirleri, 2021).

Müşteri temsilcisinin ilgisizliği: Bir müşteri temsilcisinin konuşma şekli, ses tonu ve üslubu müşterilerin işletme hakkındaki düşüncelerinin belirlenmesinde oldukça önemlidir. Böyle bir sorun ya müşterilerin beklentilerinin fazla olmasından ya da gerçekten müşteri temsilcilerinin ilgisizliği ile ortaya çıkabilir. Sorunun çözülmesi için ise kullanılan prosedürler gerekli görüldüğü takdirde esnetilmeli, müşteri temsilcilerinin en azından ses tonuna dikkat etmeleri istenmelidir (Yeni İş Fikirleri, 2021).

Ürün/hizmet eksikliği: Müşteriler bir ürünün özelliklerinin eksik olması, ürünü kullanamama gibi sorunlar da dâhil olmak üzere yetersiz ürün/hizmet sunmuş algısına kapılabilirler. Ancak bu durumlarda bile rakip işletmeler düşünülerek müşterilerin ihtiyaçlarına hızlı ve etkin çözümler sunulmalıdır. Bunun içinde işletme kaynaklı hata olduğu düşünülmendiğinde müşterilerin sorunları tam anlamıyla öğrenilmeli ve müşteriler nazik bir şekilde konuyla ilgili eğitilmelidir (Yeni İş Fikirleri, 2021).

Soruna ilk çağrıda çözüm bulamama: Müşterilerin sorunlarına ilk aramada çözüm bulunamayabilir. Ancak ilgili sorunun çözümü için çaba harcanmalıdır. Müşterilerin sorunları

hakkında zamana duyarlı notlar bırakılmalı ve yakından takip edilmelidir (Yeni İş Fikirleri, 2021).

Soruna yönelik takip eksikliği: Bazı müşteriler sorunların çözümleri karşısında sabırlı davranabilirken bazıları ise sürekli bir güncellik bekleyebilirler. İşte bu yüzden hangi müşteri tipi olursa olsun müşterilerin ve temsilcilerin uygun gördükleri düzenli aralıklarla bilgi verilmelidir. Böylelikle müşteriler daha uzun süre sorunun çözümü için bekleyebilirler (Yeni İş Fikirleri, 2021).

Ürün/hizmet yeniliği talebi: Aslında böyle bir sorun olmamakla birlikte müşteri temsilcilerinin karşılaştığı bir durumdur. Tabi ki bazı müşteriler yeni ürün veya hizmet alabilmeyi istemektedirler. Ancak bunun için müşteri temsilcileri yerine ürün geliştirme gibi konuyla ilgili çalışan bir ekibin olması işletmeye daha çok fayda sağlayacaktır (Yeni İş Fikirleri, 2021).

Müşteri şikâyetlerinin çözümünde dikkat edilmesi gerekenler

Müşteri şikâyetlerinin çözüm süreci müşterilerden gelen olumsuz geri dönüşleri alma, bunlara neyin sebep olduğunu araştırma ve sorunun çözümünü ifade etmektedir. Bu süreç aşağıdaki maddeler ile daha etkin bir şekilde ifade edilebilir (Timur 1998):

- ❖ Müşteriler için çözüm sürecinde erişilebilir olmak
- ❖ Müşterilerinizi dinlediğinizi göstermek
- ❖ Müşterilerinizin yerine kendinizi koyun ve anlayışlı olun
- ❖ Müşterilerin sizin tarafınızdan anlaşıldığını belli edin
- ❖ Müşterilerin sizi ilk aramalarında sorunlarını çözmeye odaklı olmak
- ❖ Müşterilere karşılaştıkları çözüm süreçlerini ayrıntılı bir şekilde anlatmak

Müşteri memnuniyeti

İnsanoğlunun ilk değiş tokuş zamanlarından itibaren müşteri memnuniyeti ticaret için önemli bir unsur olmuştur. Günümüzde de ticaretin devam edebilmesi müşteri memnuniyetine bağlıdır. Müşteri memnuniyeti ise herhangi bir ürün/hizmet alımından önceki beklentiler ile aldıktan sonra ürün/hizmet kalitesinin müşterideki karşılığı olarak ifade edilmektedir (Burucuoğlu 2011). Tabi ki müşteri memnuniyeti ya da memnuniyetsizliği kişiden kişiye değişen çevresel birçok faktörün kişilerin üstünde etkisini gösterdiği kavramlardır (Banar ve Ekergil 2010). Bu faktörlerin en başında kişilerin yaşam koşulları gelmektedir (Burucuoğlu 2011).

Müşteri memnuniyetini yerine getirmek için yapılması gerekenler

Yapılan araştırmalara göre müşteri hizmetlerinin önemi insanlar için işletme/marka değişimi açısından oldukça önem arz etmektedir. Sırf müşteri hizmetleri kötü olduğu için ve memnuniyetsiz müşteriler yarattığı için insanlar sürekli kullandıkları markaları bile değiştirme yoluna gitmektedirler. Böyle bir durumda işletmeler müşteri memnuniyeti sağlama konusunda bazı temelleri ortaya koymalıdır. Bu temeller şunlardır (İnnova 2007 , Burucuoğlu 2011):

- ❖ Müşterilerin ürün/hizmet ile ilgili sorunlarını rahat bir şekilde ortaya koyabilmeleri için gerekli ortamı hazırlamak
- ❖ Müşterilerle ilgilendiğini belli etmek amaçlı sürekli iletişimde bulunmak
- ❖ Müşterilerle ve işletme ile teması sağlayan çalışanların konforunu ve memnuniyetini arttırmak
- ❖ Sadece ürün/hizmet alımından önce değil sonrasında da müşteriler ile iletişime geçilerek memnuniyet derecelerini ölçmek
- ❖ Müşterilerden gelen şikayetlerin üzerinde durmak ve çözüm için çabalamak
- ❖ Müşterilerin kişilik özellikleri ve ürün/hizmet alımındaki tutum ve davranışları gözlenmeli, müşteriye tanıma yoluna gidilmeli
- ❖ Müşteriler ile iletişimde bulunurken saygı ve teşekkür ifadeleri sık sık kullanılmalı

Müşteri sadakati

Her işletme için müşteri tabanlı çalışmalar gelecekle için vazgeçilmez unsurlardan biridir. Hem gelecek müşteriler hem de mevcut müşterileri elde tutmak, rekabetçi iş ortamlarındaki paylarını elde tutmak adına büyük önem arz etmektedir. Gelecek olan ve mevcut olan müşterileri elde tutmak yani sadakatli müşteriler oluşturmak işletmenin müşteri odaklı çalışması ve müşterilerden gelen her türlü geri dönüşün çok iyi bir şekilde değerlendirilmesi ile olur (Alper 2010). Böylelikle müşteriler ürün/hizmet aldıkları işletme/markaları değiştirme yoluna gitmeyeceklerdir. Bu da müşteri sadakati denilen kavramın varlığını ortaya koymaktadır. Diğer bir deyişle müşteri sadakati bir ürüne veya hizmete bağlı olma sıklığı ve pozitif duygular olarak ifade edilebilir (Alper 2010).

MATERYAL VE YÖNTEM

Yapay zekâ, makine öğrenmesi ve derin öğrenme alanında yapılan çalışmalar giderek artmaktadır. Makine öğrenmesi ve derin öğrenme yapay zeka olarak adlandırılrsa da bu üç terim birbirlerinden farklıdır. Bölüm x de yapay zeka, makine öğrenmesi ve derin öğrenme hakkında ayrıntılı bilgi verilmeye çalışılmıştır.

Yapay Zeka

Zekâ terimi insanlar için kullanılan bir kavram olup düşünme, hareket etme, karar verme, algılama ve etrafındaki olaylar örgüsünden sonuç çıkaran bir yetenek olarak karşımıza çıkmaktadır. Yapay zekâ ise insanlara ait bu özelliklerin makineler tarafından yapılmasını ifade etmektedir. Yani başka bir deyiş ile makinaların insanların yapabildiği bazı işlemleri insanlar kadar becerikli bir şekilde yapabilmesini ifade etmektedir(Endüstri 4.0).

Yapay zekanın en önemli kurucu babalarından biri John McCarthy'dir. Bu konuyla ilgili düzenlemiş olduğu bir konferans sonrası katılımcılar yapay zekanın daha ileri bir seviyeye getirilmesi gerektiğini düşünmüşlerdir(Endüstri 4.0). Yapay zekanın diğer kurucu üyelerinden bir olan Alan Turing ise kendi adıyla bilinen Turing Testini oluşturmuştur. Bu testin amacı ise makinaların düşündüğünü söylemenin mantıksal olarak doğru olup olmadığı üzerinedir. Marvin Minsky, Allen Newell, Herbert A. Simon. McCarthy, Minsky, Nathaniel Rochester, -Claude E. Shannon yapay zekanın icadına yardımcı olan diğer kişiler arasında gösterilmektedirler (Wikipedia 2001).

Yapay zeka 'sadece yaptıklarınızı harfiyen yapabilen zayıf yapay zeka ve hatalarınızdan öğrenebilen daha da gelişmiş kuvvetli yapay zekalar olmak üzere ayrılırlar' (Endüstri 4.0). Yapay zekanın bu ayrımları zaman geçtikçe büyük verilerin ortaya çıkmasıyla yerini makine öğrenmesine ve makine öğrenmesinden de yerini derin öğrenmeye bırakmıştır. Yani aslında derin öğrenme makine öğrenmesinden, makine öğrenmesi de yapay zekadan daha karmaşık ve ileri seviyelerdir.

Makine Öğrenmesi

Makinelere genel bir bakış atacak olursak, insanlar işlerini basitleştirmek ve iş yaparken gereken süreyi azaltmak için basit araçlar yapmışlardır. Herhangi bir bilimsel yasayı bilmeden en basitinden kaldıraçlardan başlamışlardır. Tekerleğin bulunmasının da mekanik yasaların bilinmesi ile ilgili değil yine insanların ve hayvanların iş yükünü basitleştirmek için icat edildiği

de unutulmamalıdır. Ancak daha sonraları bu basit icatlar geliştirilmiş ve zeka kavramı ile birleştirilmiştir. İşte bu da otomatik makinaların bulunmasına öncülük etmiştir. Görüldüğü üzere basit araçlar basit makinelere, basit makineler de akıllı makinelere dönüşmüştür. İnsanoğlunun bu değişim ve gelişim süreciyle birlikte yapay zekanın önemli bir alt dalı olan makine öğrenmesi de hayatımıza girmiş ve hemen hemen her alanda kullanılmaya başlanmıştır(Bonaccorso 2017).

Öğrenme kelimesinin anlamına bakacak olursak, dış uyaranlara göre değişme ya da önceki deneyimlerin birçoğunu hatırlama şeklinde karşımıza çıkmaktadır. Dolayısıyla makine öğrenmesi değişme eğilimini arttıran veya geliştiren her tekniğe en fazla önemi veren bir mühendislik yaklaşımıdır diyebiliriz(Bonaccorso 2017). Mesela mekanik bir saat düşünüldüğü zaman insan eliyle yapılmış en muhteşem eserlerin başında gelmektedir. Ancak yapısı gereği mekanik olarak ayarlanmaktadır, yani herhangi bir değişim olursa işe yaramaz hale gelmektedir. Yaşanan değişimleri fark etmek insanlara ve hayvanlara özgü bir durumdur. Bundan dolayı makine öğrenmesinin amacı, genel olarak sağlanan verilerle eğitilebilen matematiksel modelleri incelemek, mühendislik uygulamaları yapmak ve geliştirmek, gelecek ile ilgili çıkarımlar yapmak, eksiksiz kararlar alabilmektir. Başka bir deyişle bir ortamdan alınan bilgiyle belirli bir amaca ulaşmak için belirli bir eylemi seçen ve o eylemin sonuçlarını gözleyebilen bir yazılımın varlığıdır(Bonaccorso 2017).

Son birkaç yılda makine öğrenmesi en önemli yapay zeka dallarından biri haline gelmektedir. Her iş alanında yeni uygulamalarla kendini göstermesi buna örnektir(Bonaccorso 2017). Makine öğrenmesinin kullanıldığı bazı alanlar aşağıda verilmiştir (Wikipedia 2001);

- ❖ Makine Algılaması
- ❖ Bilgisayarlı Görme
- ❖ Bilgisayarlı Görmede Nesne Tanıma
- ❖ Yazılım Mühendisliği
- ❖ Kredi Kartı Dolandırıcılığı Denetimi
- ❖ Borsa Çözümlemesi
- ❖ Oyun Oynama
- ❖ Uyarlamalı Web Siteleri
- ❖ Arama Motorları
- ❖ Doğal Dil İşleme
- ❖ Sözdizimsel Örüntü Tanıma
- ❖ Tıbbi Tanı
- ❖ Biyoinformatik

- ❖ Beyin-Makine Arayüzleri ve Kiminformatik
- ❖ DNA Dizilerinin Sınıflandırılması
- ❖ Konuşma ve Elyazısı Tanıma
- ❖ Robot Gezisi

Bir bilgisayar bilimcisi olan Arthur Samuel tarafından 1959’da birleştirilen makine öğrenmesi en temelde “bilgisayarın açıkça programlanmadan öğrenme yeteneği” olarak ifade edilmektedir. Bilgisayar bu öğrenme yeteneğini geliştirirken çıktı sonuçlarını sınıflandırma ve tahmin etmek için girdi verilerini işleme katarak analiz eden algoritmalar kullanır (Prowmes). Makine öğrenme algoritmaları çıkan bu sonuçların hedeflerine göre birkaç sınıfa ayrılmaktadır (Batı 2020). Başlangıç verileri ile çıkış verileri bilinen denetimli/gözetimli öğrenme iken, sadece başlangıç verileri ile belli sonuçlara ulaşmaya çalışan denetimsiz/gözetimsiz öğrenme algoritmalarının yanında bağımlı ve art arda gelen olayların çıktı verilerini bulmaya çalışan takviyeli/pekiştirmeli öğrenme algoritmaları olmak üzere üç makine öğrenme algoritmasında bahsedilebilir (Batı 2020).

Denetimli/Gözetimli makine öğrenmesi

Adından da anlaşılacağı üzere bu makine öğrenmesinde denetlenen bir senaryo mevcuttur. Yani hem girdi verileri hem de çıktı verileri bulunmakta ve programlanmış algoritmalar tarafından eğitilme durumu söz konusudur (Bonaccorso 2017). Makinenin eğitilmesi kullanılan girdi ve çıktıların bilindiği bir veri seti üzerinden yapılır. Girdi ve çıktı verileri arasında bağlantı kurmak ve sonuçlar elde etmek için bazı fonksiyonlar kullanılır. Bu fonksiyon denklem 1’de girdi değişkeni x , çıktı değişkeni y olarak ifade edilebilir.

$$y = F(x) \quad (1)$$

Fonksiyonları belirlemede regresyon ve sınıflandırma algoritmaları kullanılır. Regresyon algoritmalarının kullanılması için çıktı verilerinin sürekli değerler alması yani nümerik olması gerekmektedir. Sınıflandırma algoritmalarında ise çıktı verilerinin belirli sayıda olası sonucunun olması yani kategorik bir alana girmesi söz konusudur (Bonaccorso 2017). Bazı algoritmalar ise hem sınıflandırmada hem de regresyonda kullanılmaktadır (Elektrikport). Regresyon ve sınıflandırma algoritmalarının da kullanıldığı en yaygın denetimli öğrenme uygulamaları aşağıda verilmiştir (Bonaccorso 2017):

- ❖ Spam (istenmeyen posta) algılama
- ❖ Örüntü algılama
- ❖ Doğal dil işleme
- ❖ Duygu analizi

- ❖ Otomatik görüntü sınıflandırma
- ❖ Otomatik sıra işleme (müzik, konuşma vb.)

Sınıflandırma Algoritmaları: Sınıflandırma veri analitiği ve örüntü tanımada gereklidir. Ön bilgilerden gelen verileri kategorize ettiği için denetimli bir öğrenme tekniğidir. Sınıflandırma yapılacak olan veri kümesi eğitim ve test olarak ikiye ayrılır. Test verilerinin analizinin yapılması için eğitim setindeki her sınıf için ortak özellikler çıkarılır. Bundan sonrası için sınıflandırma iki aşamadan oluşur. Birinci aşamada eğitim veri setlerine bir sınıflandırma algoritması uygulanarak bir model çıkarılır. İkinci aşamada ise çıkarılan model etiketli bir test verisine karşı doğrulanır (Singh *et al.* 2016). Kullanılan en yaygın sınıflandırma algoritmaları aşağıda verilmiştir:

- ❖ Destek Vektör Makinası (Support Vector Machine/SVM)
- ❖ Karar Ağaçları (Decision Trees/DT)
- ❖ K-En Yakın Komşu (K-Nearest Neighbor/KNN)
- ❖ Naif Bayes (Naive Bayes/NB)
- ❖ Diskriminant Analizi (Discriminant Analysis/DA)
- ❖ Lojistik Regresyon (Logistic Regression/LR)
- ❖ Sinir Ağları (Neural Networks/NN)

Regresyon Algoritmaları: Regresyon algoritmaları iki amaçla kullanılır. Birincisi tahmin yapmak, ikincisi ise gerekli olan bazı alanlarda bağımlı ve bağımsız değişkenler arasındaki nedensel ilişkileri belirlemek içindir. Daha da önemlisi, regresyon algoritmaları tek başına yalnızca bağımlı bir değişken ile farklı değişkenlerden oluşan sabit bir veri kümesi seti arasındaki ilişkileri gösterir (Maulud and Abdulazeez 2020). Kullanılan bazı regresyon algoritmaları aşağıda verilmiştir (Maulud and Abdulazeez 2020, Elektrikport):

- ❖ Basit Doğrusal Regresyon (Simple Linear Regression/SLR)
- ❖ Çok Değişkenli Doğrusal Regresyon (Multivariate Linear Regression/MLR)
- ❖ Polinom Regresyon (Polynomial Regression/PR)
- ❖ K-En Yakın Komşu (K-Nearest Neighbor/KNN)
- ❖ Destek Vektör Makinası (Support Vector Machine/SVM)
- ❖ Karar Ağaçları (Decision Trees/DT)

Bazı algoritmalar hem sınıflandırma hem de regresyonda yukarıda görüldüğü gibi kullanılabilir. Bu algoritmalar k-en yakın komşu, destek vektör makinaları ve karar ağaçlarıdır.

Denetimsiz/Gözetimsiz makine öğrenmesi

Bu yaklaşım herhangi bir denetimcinin olmamasına ve dolayısıyla da mutlak hata ölçütlerine dayanmaktadır. Bir dizi ögenin benzerliklerine veya uzaklık ölçütlerine göre nasıl gruplanabileceğini (kümelenebileceğini) öğrenmek için kullanılır(Bonaccorso 2017). Başka bir şekilde ifade etmek gerekirse denetimli öğrenmede verilerin etiketlenmesi durumu söz konusuysa denetimsiz öğrenmede veri etiketleri olmadan algoritmaların kendi etiketlerini bulabildiği yani kendi kendine öğrenme durumu mevcuttur. Denetimsiz makine öğrenmesinde kullanılan yöntemler kümeleme ve ilişkilendirme olmak üzere iki çeşittir(Tükmen 2021). Denetimsiz öğrenme algoritmalarının kullanıldığı bazı alanlar ise aşağıda verilmiştir (Bonaccorso 2017):

- ❖ Nesne segmentasyonu (ürünler, filmler, şarkılar vb.)
- ❖ Benzerlik algılama
- ❖ Otomatik etiketleme

Kümeleme: Sınıf etiketlerini bilmeden veriler üzerinden sınıfları tanımlamakla uğraşır. Kümeleme algoritmalarının amacı, diğer kümelerden daha çok birbirine benzeyen nesne gruplarını veya kümeleri belirlemektir. Yani mevcut veri kümesinin ilgili yönleri üzerinde basit özellik kümesi oluşturmak ister. Kümeleme yöntemleri genellikle denetimli makine öğrenmesi yöntemlerinden daha çok özelliğe ihtiyaç duyar (Rodriguez et al 2019).

İlişkilendirme Kuralı: İlişkilendirme tabanlı makine öğrenmesinde algoritma etiketsiz gelen verilerin çoğunu açıklayan kurallar geliştirir. Örneğin bir veri kümesinde satın alan insanların olduğunu ve başka insanların da satın alma eylemi içinde olup olmadığını belirlemede kullanılır. Yani bir ürünü satın alanlar başka bir ürünü de satın almaya eğilimlidir denebilir (Akoğlu 2018).

Takviyeli/Pekiştirmeli öğrenme

Takviyeli öğrenme sayısal bir ödül sinyalini maximum noktaya çıkarmak için ne yapılacağını başka bir ifade ile durumları eylemlerle nasıl eşleştireceğinizi gösteren bir makine öğrenmesi alanıdır. Takviyeli öğrenme makine öğrenimi alanındaki en güncel konularda incelenen denetimli öğrenmeden farklıdır. Denetimli öğrenmede bilgili bir denetimci tarafından sağlanan etiketli örneklerden oluşan bir eğitim veri setinden öğrenme gerçekleştirilir. Her veride sistem bir eyleme yani etiketlenmiş olana gider. Yani veriler kategorize edilmiştir. Takviyeli öğrenme aynı zamanda etiketlenmemiş veri setlerinde gizlenmiş yapıyı bulmakla ilgilenen denetimsiz öğrenmeden de farklıdır (Sutton and Barto 2018). Bir santraç oyununu göz önüne alacak olursak her hamle aslında bir girdidir ve her hamle kendinden önceki ve sonraki

hamleler ile bağımlı haldedir. Oyunun sonunda kazanıp kaybetme ise çıktı verilerini oluşturmaktadır. Girdi ve çıktı değerlerinin birbirine bağımlı olması ile takviyeli öğrenme denetimli ve denetimsiz öğrenmeden ayrılır.

Bu çalışma kapsamı itibariyle elde edilen veriler denetimli makine öğrenmesi algoritmalarıyla sınıflandırılacağından bir sonraki bölümde denetimli makine öğrenmesi yöntemleri ayrıntılı bir şekilde anlatılacaktır.


Kullanılan Denetimli/Gözetimli Makine Öğrenme Algoritmaları

Bu tez çalışması kapsamında kullanılacak olan veriler altı adet denetimli makine öğrenme algoritması kapsamında ele alınmıştır. Bunlar; karar ağaçları, diskriminant analizi, lojistik regresyon, naif bayes, destek vektör makinaları ve k-en yakın komşudur.

Karar ağaçları

Denetimli öğrenme algoritmalarından biri olan karar ağaçları hem sınıflandırma hem de regresyon örneklerinde kullanılmaktadır. Sınıflandırma yapılacak olan veri kümesi de aynı zamanda hem sayısal hem de sınıfsal olarak ifade edilebildiğinden bu yöntem sıklıkla kullanılmaktadır.

Karar Ağaçları, örnekleri özellik değerlerine göre sıralayarak sınıflandıran ağaçlardır. Karar ağacındaki her düğüm, sınıflandırılacak bir örnekteki bir özelliği temsil eder ve her dal, düğümün yapabileceği bir değeri temsil eder. Örnekler, kök düğümünden başlayarak sınıflandırılır ve özellik değerlerine göre sıralanır (Osisanwo *et al.* 2017). Aşağıda basit bir karar ağacı yapısı gösterilmiştir (Türkmen 2021).



Şekil 1. Karar ağacı algoritması genel yapısı

Diskriminant analizi

Değişkenleri, önceden tanımlanmış gruplar arasındaki farkları en üst düzeye çıkaracak şekilde birleştirir. Diskriminant analizi doğrusal ve kuadratik (ikinci dereceden) olmak üzere ikiye ayrılır. Doğrusal diskriminant analizi tahmin edicilerin normal dağıldığı ve her sınıfın kovaryansının (eldeki iki değişkenin birbirleri ile olan değişkenlik durumları yani birbirlerini ne kadar değiştirdiklerinin ölçüsüdür) aynı olduğu varsayıldığında uygulanır. Bu yöntemde elde edilen verilerin özniteklelerinin doğrusal birleşimini bulunur ve sınıflandırma işlemi yapılır. Kuadratik diskriminant analizinin böyle bir varsayımı yoktur. İkinci dereceden bir yüzey (yani bir konik bölüm) kullanarak sınıfları ayırır. Her ikisi de sınıflandırıcı olarak kullanılır. Ancak doğrusal diskriminant analizi aynı zamanda boyutsal küçültme aracı da olduğundan daha yaygın bir şekilde kullanılır (Singh *et al.* 2016).

Lojistik regresyon

Lojistik regresyon, denetimli sınıflandırma için güçlü bir yöntemdir. Sıradan regresyonun bir uzantısı olarak kabul edilebilir ve yalnızca bir olayın meydana gelip gelmediğini temsil eden ikili bir değişkeni modelleyebilir. Başka bir ifade ile yeni bir örneğin belirli bir sınıfa ait olma olasılığını bulmaya yardımcı olur. Bu algoritma bir olasılık olduğundan, sonuç 0 ile 1 arasındadır. Bu nedenle lojistik regresyonu ikili sınıflandırıcı olarak kullanmak için, iki sınıfı ayırt etmek ve bir eşik atanması gerekir (Uddin *et al.* 2019). Lojistik regresyonda ikili sınıf bağımlı değişkenler için yani çıktı değerlerini ifade edilen bir kavramdır, ancak girdi değişkenleri için öyle bir durum söz konusu değildir. Lojistik regresyon algoritması aşağıda gösterilen şekliyle formüle edilmektedir (Güneş 2020):

$$P = \frac{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k}}{1 + e^{\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k}} \quad (2)$$

P=Olasılık Değeri

β_0 =Sabit Değer

$\beta_1, \beta_2, \dots, \beta_k$ =Regresyon Katsayıları (Bağımsız değişkenlere ait)

$x_1, x_2, \dots, x_k$ =Bağımsız Değişkenler

k=Bağımsız değişken sayısı

e=Euler Sayısı

Naif bayes

Denetimli makine öğrenmelerinden biri olan naif bayes sınıflandırıcıları Bayes Teoremi'ne dayandığı için istatistiksel sınıflandırıcılardır. Sınıf üyeliği olasılığını, yani belirli bir örneğin belirli bir sınıfa ait olma olasılığını tahmin ederler. Naif bayes sınıflandırıcı, büyük veri

tabanlarına uygulandığında hem hızlı hem de yüksek doğruluk göstermektedir. Tüm değişkenlerin sınıflandırmaya katkıda bulunduğunu ve karşılıklı olarak ilişkili olduğunu varsaydığı için ‘Naif’ olarak adlandırılır. Bu varsayıma sınıf koşullu bağımsızlık denir(Bhavsar and Ganatra 2012). Başka bir ifade ile bir özelliğin sınıflandırmadaki etkisinin, diğer özellik değerlerinin ifadelerinden bağımsız olduğunu belirten bir varsayımdır(Burkart and Huber 2021). Çoğu veri seti için bu gerçekçi olmayan bir varsayımdır, ancak birçok pratik durumda şaşırtıcı derecede iyi sonuç veren basit bir tahmin çerçevesine yol açtığı görülmektedir(Bhavsar and Ganatra 2012).

Naif bayes teoreminin formüle edilmiş hali aşağıda verilmiştir (Bhavsar and Ganatra 2012);

$$P(Y/X) = \frac{P(X/Y) * P(Y)}{P(X)} \quad (3)$$

P: Olasılık Terimi

P(Y/X): X olayı gerçekleştiği zaman Y olayının gerçekleşme olasılığı

P(X/Y): Y olayı gerçekleştiği zaman X olayının gerçekleşme olasılığı


P(Y): Y olayının gerçekleşme olasılığı

P(X): X olayının gerçekleşme olasılığı

Naif bayes sınıflandırıcılarından olan Gauss Naif Bayes ve Kernel Naif Bayes de sınıflandırma çalışmalarında kullanılan çeşitlerindendir. Gauss naif bayes adından da anlaşılacağı üzere Gauss dağılımından örnek olarak oluşturulur yani tahmin ediciler sürekli değerler alırlar. Kernel parametrik olmayan tahmin tekniklerinde kullanılan bir ağırlıklandırma işlevidir. Diğer bir ifade ile rastgele bir değişkenin koşullu beklentisini tahmin etmek için çekirdek regresyonunda kullanılır.

Destek vektör makinaları


Destek vektör makinaları hem sınıflandırma hem de regresyonda kullanılmaktadırlar. Destek vektör makinalarını genel olarak ifade edecek olursak istatistiksel öğrenme teorisine ve yapısal risk minimizasyonu ilkesine dayanır ve sınıfların optimal ayrılmasını üreten hiper düzlem olarak da bilinen karar sınırlarının yerini belirleme amacına sahip bir denetimli makine öğrenme algoritmasıdır (Bhavsar and Ganatra 2012). Bu algoritma iki veri sınıfını ayıran bir hiper düzlemin her iki tarafı olan bir “marj” kavramı etrafında döner(Osisanwo *et al.* 2017). Veri kümesinin (iki sınıflı) doğrusal olarak ayrıldığı durumlar için doğrusal (lineer) destek vektör makinaları kullanılır. Aşağıda destek vektör makinası çalışma biçimi gösterilmiştir (Türkmen 2021).



Şekil 2. Destek vektör makinası genel görünüm

K-En yakın komşu

Denetimli makine öğrenme türlerinin en basitlerinden birisi olan k-en yakın komşu algoritması hem regresyon hem de sınıflandırmada kullanılmaktadır. Birbirine benzeyen örneklerin birbirine yakın olduğu ilkesine dayanır ve etiketlenmemiş bir örnek verildiğinde sınıflandırıcı, kendisine en yakın olan k-nesneleri için desen uzayını arar ve en sık görülen sınıf etiketini belirleyerek sınıfa atar (Bhavsar and Ganatra 2012). K-en yakın komşu modelleri, eğitim verilerinden açıkça bir model oluşturmaz, bunun yerine test veri örneğinin en yakın komşularını hesaplamak için bir benzerlik ölçüsü kullanır (Burkart and Huber 2021). Aşağıda bu algoritmanın çalışma şekli gösterilmiştir (Türkmen 2021).



Şekil 3. K-en yakın komşu genel görünüm

Sınıflandırma Algoritmaları Performans Ölçütleri

Sınıflandırma algoritmalarının performansları belirlenirken karmaşıklık matrisinden elde edilen doğruluk, kesinlik, duyarlılık, özgüllük, F-ölçüm değerlerinin oranları ile birlikte ROC eğrisinden yararlanılır.

Karmaşıklık matrisi (confusion matrix)

Karmaşıklık matrisi, kullanılan sınıflandırma algoritmalarının tahmin edilen değerleri ve gerçek değerlerini sayısal ifadeler ile gösteren bir performans ölçüm aracıdır. Sınıflandırma sonucunda algoritmaların test edilmesi için girilen verilerin kaç tanesini doğru tahmin ettiği, kaç tanesini yanlış tahmin ettiği performans ölçümü için kullanılan değerlerin oranlarını belirlemede önemlidir. Örneğin; test veri setindeki verilerin pozitif veya negatif olmak üzere iki sınıftan birine girmesi gereken ikili bir sınıflandırma yapılmak istendiğinde karmaşıklık matrisi dört alana bölünür. Bunlar doğru tahmin edilen pozitif veriler (DP), yanlış tahmin edilen pozitif veriler (YP), doğru tahmin edilen negatif değerler (DN) ve yanlış tahmin edilen negatif değerler (YN) olarak karşımıza çıkar. Aşağıda örnek bir karmaşıklık matrisi verilmiştir(Güneş 2020):

Tablo 1. Karmaşıklık Matrisi Örneği

		Gerçek Veri	
		Pozitif	Negatif
Tahmin Edilen Veri	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif(YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif(DN)

DP: Gerçek verilerde pozitif olup da tahmin edilen değer pozitif olması durumu

YP: Gerçek verilerde negatif olup da tahmin edilen değer pozitif olması durumu

YN: Gerçek verilerde pozitif olup da tahmin edilen değer negatif olması durumu

DN: Gerçek verilerde negatif olup da tahmin edilen değer negatif olması durumu

Doğruluk Oranı (Accuracy Rate): Doğru bilinen veri sayısının bütün verilere oranını gösterir. Aşağıdaki şekilde formüle edilir:

$$\text{Doğruluk Oranı} = \frac{DP + DN}{DP + DN + YP + YN} \quad (4)$$

Duyarlılık Oranı (Sensitivity Rate): Doğru tahmin edilen pozitif verilerin bütün pozitif verilere oranını ifade etmektedir. Aşağıdaki şekilde formüle edilir:

$$\text{Duyarlılık Oranı} = \frac{DP}{DP + YN} \quad (5)$$

Kesinlik Oranı (Precision Rate): Doğru tahmin edilen pozitif verilerin pozitif olarak tahmin edilmiş bütün verilere oranı olarak ifade edilir. Aşağıdaki şekilde formüle edilir:

$$Kesinlik\ Oranı = \frac{DP}{DP + YP} \quad (6)$$

Özgüllük Oranı (Specificity Rate): Negatif olarak doğru tahmin edilmiş verilerin gerçekte negatif olan verilere oranını ifade etmektedir. Aşağıdaki şekilde formüle edilir:


$$Özgüllük\ Oranı = \frac{DN}{DN + YP} \quad (7)$$

F-Ölçütü Oranı: Bu performans ölçütü hem kesinlik ölçütünü hem de duyarlılık ölçütünü kullanarak yeni bir oran vermektedir. Aşağıdaki şekilde formüle edilir:

$$F - Ölçütü\ Oranı = \frac{2 * Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (8)$$

ROC eğrisi


ROC (Receiver Operating Characteristic – Çalışma Karakteristiği) eğrisi Duyarlılık/Özgüllük ölçütlerinin birbirlerine oranı olarak ifade edilir. Eğri üzerindeki her nokta bir karar eşliğine denk gelir ve her biri duyarlılık/özgüllük oranını temsil eder. Eğri altında kalan alan ise AUC (Area Under Curve/Eğri Altındaki Alan) olarak ifade edilir ve 0 ile 1 aralığında değer alır. Bu değer 1'e ne kadar yakın olursa sınıflandırıcı algoritma o kadar iyi performans göstermiştir. Aşağıda örnek bir ROC eğrisi verilmiştir (Güneş 2020):



Şekil 4. ROC eğrisi grafiği

Derin Öğrenme

Derin öğrenme yapay sinir ağlarının daha fazla katmandan oluşmuş bir halidir ve makine öğrenmesinin bir alt dalıdır. Daha ayrıntılı bir tanım olarak ise; bilgisayarların görüntü ve konuşma tanıma gibi algısal sorunları çözmesini sağlayan güçlü bir makine öğrenimi biçimidir. Yapay sinir ağları genel görüntüsü itibariyle giriş katmanı (input layer), bir adet gizli katman (hidden layer) ve çıkış katmanından (output layer) oluşur. Derin öğrenme mimarilerindeki derin yapay sinir ağlarına bakacak olursak giriş ve çıkış katmanlarının arasında birden fazla gizli katman bulunmaktadır. Derin yapay sinir ağları çok büyük veri kümelerindeki kalıpları ve yapıyı keşfetmek için birden çok işleme katmanı kullanır. Her katman, sonraki katmanların üzerine inşa ettiği verilerden bir kavram öğrenir; seviye ne kadar yüksekse, öğrenilen kavramlar o kadar soyut olur. Derin öğrenme, önceki veri işlemeye bağlı değildir ve özellikleri otomatik olarak çıkarır. Derin öğrenmeyi oluşturmak için kaç katman gerektiğine dair kesin ve hızlı bir kural yoktur, ancak çoğu uzman ikiden fazlasının gerekli olduğu konusunda hemfikirdir(Shrestha and Mahmood 2019). Aşağıdaki şekilde basit bir yapay sinir ağı (simple neural network) ile derin sinir ağının (deep learning neural network) görseli verilmiştir (Medium).



Şekil 5. Yapay sinir ağları(sol) ve derin yapay sinir ağları(sağ) görünümü

Derin öğrenme içerisinde çok sayıda mimari mevcuttur. Bunlar(Şeker vd. 2017, Ser ve Bati 2019):

- ❖ Derin Sinir Ağları (Deep Neural Network/DNN)
- ❖ Evrişimli Sinir Ağları/ESA (Convolution Neural Network/CNN)
- ❖ Tekrarlayan Sinir Ağı (Recurrent Neural Network/RNN)
- ❖ Uzun Kısa Vadeli Bellek (Long Short Term Memory/LSTM)
- ❖ Sınırlı Boltzmann makineleri (Restricted Boltzmann Machines/RBM)
- ❖ Derin İnanç Ağları (Deep Belief Networks/DBN)
- ❖ Derin Oto-Kodlayıcılar (Deep Autoencoders/DA)

CNN mimarileri de kendi içinde önemli mimari ağlara ayrılmaktadır. Bu mimari ağlardan bazıları şunlardır(Ecevit 2016):

- ❖ LeNet
- ❖ AlexNet
- ❖ VGGNet
- ❖ GooleLeNet
- ❖ DenseNet
- ❖ ResNet

Kullanılan Derin Öğrenme Teknikleri

Evrişimsel sinir ağı

Derin öğrenme alanında ESA en ünlü ve yaygın olarak kullanılan bir mimari türüdür. ESA'nın diğerlerine kıyasla ana yararı, herhangi bir insan denetimi olmaksızın ilgili özellikleri otomatik olarak tanımlamasıdır. ESA'lar, bilgisayarla görme, konuşma işleme, yüz tanıma dâhil olmak üzere birçok farklı alanda kapsamlı bir şekilde uygulanmıştır. ESA'ların yapısı, geleneksel bir sinir ağına benzer şekilde insan ve hayvan beyinlerindeki nöronlardan esinlenmiştir(Alzubaidi *et al.* 2021).

Evrişimli sinir ağı mimarisinin en az bir katmanında evrişim işlemi uygulayan basit özelleşmiş yapay sinir ağı çeşididir. Ancak katmanlarına evrişim işlemi uyguladığı için yapay sinir ağlarından farklılık gösterir(Kılıç 2016).

Standart bir ESA mimarisinin adımları şu katmanlardan oluşmaktadır: Giriş verilerinin eklendiği giriş katmanı (input layer). En az bir katmanında evrişim işlemi olan evrişim katmanı (convolution layer). Ağı daha hızlı çalışmasını sağlayan düzeltilmiş doğrusal birimler katmanı(relu layer) katmanı. Çıktı boyutunu küçültmek için bazı fonksiyonların kullanıldığı havuzlama katmanı (pooling layer). Bir önceki bölümlerden çıkan bilgilerin girdi olarak kullanıldığı ve yapay sinir ağı gibi olan tam bağlı katman (fully-connected layer). Hata azaltma olarak görev yapan bırakma katmanı (dropout layer). Son olarak da sınıflandırma işleminin yapıldığı sınıflandırma katmanı (classification layer).

Yapay sinir ağları ve derin öğrenme mimarileri bazı hiperparametre değerlerine göre oluşturulur. Bu hiperparametreler aşağıda verilmiştir(<https://medium.com/> , Kurt 2018):

- ❖ Veri setinin boyutu
- ❖ Öğrenme hızı
- ❖ Momentum katsayısı
- ❖ Eğitim tur (epoch) sayısı
- ❖ Başlangıç ağırlıkları belirleme
- ❖ Aktivasyon fonksiyonu

- ❖ Seyreltme (dropout) değeri
- ❖ Katman sayısı ve gizli katmandaki nöron sayısı
- ❖ Kernel boyut
- ❖ Havuzlama boyutu

ESA Mimarisi Katmanları

Giriş Katmanı (Input Layer): Bu katman girdi olarak kullanılan verilerin giriş yapıldığı katmandır. Bu katmanın doğru bir şekilde girilmesi ağ mimarisi için önemli bir ölçüttür(Ecevit 2016).

Evrişim Katmanı (Convolution Layer): Bu katman evrişimli sinir ağlarının temelini oluşturur. Bu katmanda kullanılan filtreleme boyutları farklı olabilir. Kullanılan bu filtreleme bir önceki katmandaki verilere evrişim işlemi uygular(Ecevit 2016).

Düzeltilmiş Doğrusal Birimler Katmanı (ReLU): Relu katmanı evrişim katmanından sonra kullanılmaktadır ve ağı normalden hızlı çalışmasını sağlamaktadır(Ecevit 2016).

Havuzlama Katmanı (Pooling Layer): Havuzlama alt örnekleme katmanı olarak da bilinir ve matris boyutunda küçülmeyi ifade eder(Syarifudin *et al.* 2021). Bu katmanın amacı hesaplama işlemlerini azaltmak ve daha doğru sonuçlar almaktır (Kara 2021). Maksimum havuzlama (Max pooling) ve ortalama havuzlama (Average pooling) olmak üzere iki tür havuzlama katmanı vardır. Maksimum havuzlama matriste bulunan en büyük değeri alarak matrisin boyutunda bir azalmaya gider. Ortalama havuzlama, matristeki değerlerin ortalamasını alarak matrisin boyutunda azalmaya gider (Syarifudin *et al.* 2021).

Toplu Normalleştirme Katmanı (Batch Normalization): Bu katmanda veriler üzerinde hem normalleştirme işlemi hem de eğitmek esas amaçtır. Modelin daha iyi performans göstermesini ve kayıp verilerin azalmasını sağlayan bir katmandır(Mutluoğlu 2019).

Softmax: Bu adım girdi vektörü olarak alınan ve yapılan mimarinin sonunda softmax fonksiyonu kullanılarak çıkış vektörü değerlerini vermektedir (Evrişimli Sinir Ağları 2022).


Önerilen Resnet Algoritması

ResNet, ImageNet yarışmasını 2015 yılında kazanmıştır (ImageNet 2022). ImageNet veri tabanında yer alan görüntüler üzerinde eğitilmiştir. Resnet ağının ana fikri, artık öğrenmeyi gerçekleştirmek için sık bir ağ temelinde sabit haritalama katmanını üst üste bindirdiği, derin özellik çıkarmanın kesinliğini geliştirdiği ve kaybolan gradyan sorununu çözdüğü artık bloğu tanıtmaktır(Xia *et al.* 2019). Katman girişini toplam operatörüne taşıyan kısa yol bağlantısına artık bağlantı denir. Bu bağlantıları içeren bloklara artık blok denir. Bu bloklar sayesinde, girdi

verileri katmanlar arasında kalan artık bağlantılar vasıtasıyla daha hızlı ilerleyebilir. Resnet ağının orijinal girdi örneklerinin çok katmanlı ağ eşlemesinden sonra elde edildiğini varsayarsak kimlik eşlemesinden sonra, bir veya daha fazla katmanı atlayabilen, kaybolan gradyan sorununu ortadan kaldıran bir atlama bağlantısı oluşturmak için girdi verisinin evrişim çıktı verisinin üzerine bindirildiği ve ağ derinliğinin yüzlerce katmana dönüştürülebildiği görülür(Xia *et al.* 2019).

ResNet yapısını oluşturan artık blok iki evrişim katmanına sahiptir. Blokda yer alan her evrişim katmanını, “Toplu Normalleştirme (Batch Normalization)” katmanı ve “Düzeltilmiş Doğrusal Birimler Katmanı (ReLU)” katmanı izlemektedir. Daha sonra bu evrişim işlemleri atlanır ve giriş doğrudan son “ReLU” katmanından önce eklenir. Ekleme işleminin yapılabilmesi daha önce iki evrişimsel katmandan alınan çıktıların, girdi ile aynı şekilde olması gerekir. ResNet artık bloklardan oluşan 4 modül kullanır (Dive into Deep Learning 2021). Model ortalama havuzlama katmanı ve ardından eklenen softmax katmanı ile sonlanmaktadır.

Şekil 6’da verilen yapıda model 3 aşamadan oluşmaktadır. Önerilen ResNet1: İlk olarak girdi, “Batch Normalization” katmanına verilmektedir. Daha sonra ResNet modeli baz alınarak 3 aşama belirlenmiştir. Her aşama artık bloktan oluşmaktadır. Her aşama kendi içerisinde 3 evrişim katmanı içermektedir. İlk katman 3x3 kernel boyutunda “Convolution”, “Batch Normalization” ve “ReLU” katmanlarından oluşmaktadır. İkinci katman, 7x7 kernel boyutunda “Convolution”, “Batch Normalization” ve “ReLU” katmanlarından oluşmaktadır. Üçüncü katman, 3x3 kernel boyutunda “Convolution”, “Batch Normalization” katmanlarından oluşmaktadır. Her aşamada sırası ile 64, 128, 128 filtre kullanılmıştır. Ayrıca artık bağlantıda 1x1 “Convolution” işlemi uygulanmaktadır. Önerilen ResNet2 modeli ise ilk modeldeki her aşamada yer alan ikinci evrişimsel katmanların kaldırılmış halidir.



Şekil 6. Önerilen ResNet Tabanlı Mimari

Derin Öğrenmede Dikkat Edilmesi Gerekenler

Bu tez çalışması kapsamında derin sinir ağları oluşturulurken geri yayılım algoritması, döngü sayısı (epoch) ve aktivasyon fonksiyonları dikkate alınmıştır. Oluşturulan ağın performansı ise ortalama mutlak hata ve R değerlerine bakılarak analiz edilmiştir.

Aktivasyon fonksiyonu: Yapay sinir ağlarında girdi ve bu girdiler ile çarpılması gereken ağırlık değerleri bulunmaktadır. Bu işlem sonucunda ağın çıktı katmanına bir fonksiyon iletiriz yani aktivasyon işlemi uygularız. Bu fonksiyon yapay sinir ağlarına uygulanmadığı takdirde öğrenme gücü zayıf kalır. Aşağıda bazı aktivasyon fonksiyonlarından söz edilmiştir(Ser ve Bati 2019).

Geri yayılım algoritması: Bir sinir ağında denetimli sınıf için kullanılan bir algoritmadır. Denetimli sınıflarda etiketli veri üzerinden yapılan işlemlerde gerçek çıktı değerleri ile sinir ağlarından elde edilen çıktı değerleri arasındaki fark hata birimi bulunmaktadır. Geri yayılım algoritması ise bu hata birimini tüm ağırlıklar ile etkileşime sokarak toplam hata fonksiyonunun etkisini en aza indirmektir.

ARAŞTIRMA BULGULARI

Bu bölümde çalışmada ele alınan problem, amaç ve kapsamının yanında makine öğrenmesi algoritmalarının kullanılabilmesi için gerekli olan veri hakkında ayrıntılı bilgi verilmiş ve sınıflandırma algoritmalarının sonuçları verilmiştir.

Çalışmada Ele Alınan Problem ve Amacı: Müşteri şikayetleri ve çözüm süreçleri düşünüldüğünde işletmeler açısından büyük öneme sahip oldukları görülmektedir. Bir taraftan müşteri şikayetleri işletme/marka açısından gelişme olanağı sağlarken bir taraftan da müşterilerin şikayetlerine çözüm bulmak ve bu çözüm sürecinde müşterileri tatmin edici bir memnuniyet seviyesinde tutmak gerekmektedir. Çünkü bu tatmin derecesi ile müşteriler şikayetçi oldukları markaları değiştirme ya da değiştirmeme kararını alabilmektedir. Tabi ki de her müşterinin şikayetlerin çözüm sürecindeki memnuniyet derecesi farklı olabilmektedir. Bu da müşterilerin cinsiyet, yaş, eğitim durumu, medeni hali ve yaşadığı ortama göre değişkenlik göstermektedir. Bu çalışmada da ele alınan problem şikayette bulunan müşterilerin kişisel özellikleri ve şikayetlerin çözüm sürecindeki memnuniyet ölçütleri ile kullandıkları markaları değiştirme durumunun olup olmadığının sınıflandırması üzerinedir.

Şikayette bulunan müşterilerin kişisel özellikleri, hangi markadan şikayetçi oldukları ve şikayetlerin çözüm sürecine ilişkin memnuniyet/memnuniyetsizlik ölçütlerine dair anket bilgileri şikayetvar.com web adresine bağlı çalışanlar ile irtibata geçilerek alınmıştır.

Çalışmada Kullanılan Veri Özellikleri: Şikayet sitesi aracılığıyla elde edilen veriler 2020-2021(Mayıs ayı dahil olmak üzere) son iki yılı kapsamaktadır. Son iki yılda en çok şikayet alan markalar göz önünde bulundurularak 10.000 adet veri (10.000 adet müşteri) alınmıştır. Verilerin sınıflandırma algoritmalarında kullanılacak hale getirilmesi ile elde kalan veri adeti 9879 olmuştur. Veri setinde 10 adet özellik sütunu 1 adet sınıflandırma sütunu(Evet ve Hayır olacak şekilde ikili sınıflandırma) mevcuttur. Özelliklerin olduğu tablo aşağıda verilmiştir.

Tablo 2. Verilerin Sütun Bazlı Özellikleri

Özellik Numarası	Özellik Adı
1	Marka Adı
2	Şikayet Tarihi
3	Sonuçtan Memnuniyet Derecesi
4	Memnun Olmama Nedeni
5	Memnun Olma Nedeni
6	Şikayetçi Doğum Yılı
7	Şikayetçi Medeni Durum
8	Şikayetçi Cinsiyet
9	Şikayetçi Öğrenim Durumu
10	Şikayet Gelen Şehir
11	Marka Değiştirme Durumu

Yukarıdaki tabloda verilen özelliklerin hepsi sayısal değerler çerçevesinde puanlanmış olup özelliklere ait sayısal puanlama aşağıdaki tabloda gösterilmiştir.

Tablo 3. Verilerin Sütun Bazlı Numerik Değerleri

Özellik	Açıklama
Marka Adı	0:Amazon 1:Aras Kargo 2:Çiçek Sepeti 3:Gitti Gidiyor 4:Hepsi Burada 5:Hepsijet 6:MNG Kargo 7:Morhipo 8:N11 9:PTT Kargo 10:PTT AVM 11:Sürat Kargo 12:Trendyol 13:Trendyol Express 14:UPS Türkiye 15:Yurtiçi Kargo
Şikâyet Tarihi	Şikayetlerin geldiği tarih(2020,2021)
Sonuçtan Memnuniyet Derecesi	0:Hiç memnun değilim 1:Memnun değilim 2:Kararsızım 3:Memnunum 4:Çok memnunum
Memnun Olmama Nedeni	0:Çözüm bulamadılar 1:Süreç çok uzadı 2:Beklentimi karşılamadılar 3:Personel davranışı 4:İletişime geçmediler 5:Bunlardan birkaçı 6:Diğer 7:Hepsi 8:Boş bırakılan

Tablo 3. (Devamı)

Memnun Olma Nedeni	0:İlgili ve sorumlu yaklaştılar 1:Personel davranışı iyiydi 2:Sorunumu çözdüler 3:İletişim/çözüm zamanlaması iyiydi 4:Bunlardan birkaçı 5:Diğer 6:Hepsi 7:Boş bırakılan
Şikâyetçi Doğum Yılı	Şikâyetçilerin doğum yılları
Şikâyetçi Medeni Durum	0:bekâr 1:evli
Şikâyetçi Cinsiyet	0:Kadın 1:Erkek
Şikâyetçi Öğrenim Durumu	0:Okuryazar değil 1:İlkokul 2:Ortaokul ve dengi 3:İlköğretim 4:Açık Lise 5:Açık Ortaokul 6:Açık lise 7:Lise ve dengi
Şikâyet Gelen Şehir	Şikâyetin hangi şehirden geldiği (Plaka Kodları)
Marka Değiştirme (Tahmin edilmesi istenen özellik)	1:Evet markayı değiştirmek istiyorum 2:Hayır markayı değiştirmek istemiyorum

İlk özellik marka adı olarak verilmiştir. Burada kullanılan ve en çok şikâyet alan markalar 16 adet olup tabloda gösterilmiştir. İkinci özellik şikâyetlerin geldiği tarihtir. Son iki yıl baz alındığı için sadece iki tarih mevcuttur. Üçüncü özellik sonuçtan memnuniyet derecesini gösterir. Müşteri şikâyetlerinin çözüm sürecine ilişkin yapılan tüm uğraşların genel bir memnuniyet derecesini gösterir. Dördüncü özellik eğer bir müşteri şikâyetine dair çözüm sürecinden memnun olmadıysa verilen bir puanı gösterir. Ama müşteri durumdan memnun ise bu ölçüt değerini boş bırakabilmektedir. Boş bırakması halinde ifade edilen sayısal bir değer yine mevcuttur. Beşinci özellik memnun olma derecesidir. Bu özellik de tıpkı memnun olmama özelliği gibi bir müşterinin şikâyet çözüm sürecinden memnun ayrılması durumunda verdiği puanı göstermektedir. Yine bu özellik sütununda da boş bırakmayı ifade eden sayısal bir değer mevcuttur. Özellik 6,7,8,9 ve 10 ise şikâyetçi olan müşterilerin kişisel özelliklerine (doğum yılı, medeni durum, cinsiyet, öğrenim durumu) hakkında bilgi vermektedir. Doğum yılı özelliğine ait sayısal değerler değiştirilmemiştir. Medeni durum özelliği ise 0 ve 1 (0:Bekar, 1: Evli) olarak sayısallaştırılmıştır. Cinsiyet özelliği de medeni durum gibi 0 ve 1 (0:Kadın, 1:Erkek) şeklinde sayısallaştırılmıştır. Öğrenim durumu özelliğinde ise 8 farklı derece(0:Okuryazar değil, 1:İlkokul, 2:Ortaokul ve dengi, 3:İlköğretim, 4:Açık Lise, 5:Açık Ortaokul, 6:Açık lise, 7:Lise ve dengi) karşımıza çıkmaktadır. En son olarak sınıflandırma yapılmak istenen sütunda marka

değiştirme ya da değiştirmeme ifadeleri sayısallaştırılıp(1:Evet markayı değiştirmek istiyorum, 2:Hayır markayı değiştirmek istemiyorum) veri seti düzenlenmiştir. Bundan sonrası için hazırlanan veri seti %80 eğitim ve %20 test seti olarak ikiye ayrılmıştır.

Veri Artırma

Veri setinde yer alan her satırdaki özelliklerden rastgele %50'si seçilmiştir. Seçilen özelliklerin gerçek dağılımından rastgele örneklenmiş değeri yer değiştirilmiştir. Önce etiketi “2” olan yani marka değiştirmek istemeyen (memnun müşteri) veri seti kendi içerisinde artırılmıştır. Daha sonra etiketi “1” olan yani marka değiştirmek isteyen (memnun olmayan müşteri) veri seti kendi içerisinde artırılmıştır. Toplam veri seti büyüklüğü yaklaşık ~2,38 katına çıkartılmıştır. Veri seti dağılımı Tablo 4’de gösterilmiştir.

Tablo 4. Veri Seti Dağılımı

	Veri Artırmadan Önce	Veri Artırmadan Sonra
1’lerin Sayısı	7280	9955
2’lerin Sayısı	2598	13548

Makine Öğrenme Algoritmaları ve Öneriler ResNET Modeli Sonuçları

Veri seti, %80 train ve %20 test olarak rastgele ayrılmıştır. Modellerin doğruluğu eğitim ve test verilerine göre değiştiğinden dolayı ortalama 10 kere çalıştırmanın sonucunda her bir model için elde edilen en iyi sonuçlar dikkate alınmıştır. Her deneme sonucunda: hem veri artırmadan önceki doğruluk değerleri ve ROC eğrileri (Tablo 5), karmaşıklık matrisi (Tablo 7) hem de veri artırmadan sonraki doğruluk değerleri ve ROC eğrileri (Tablo 6), karmaşıklık matrisi (Tablo 8) verilmiştir.

Tablo 5. Veri Artırmadan Önceki Değerler

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Ölçüm	AUC	Train Accuracy
Önerilen ResNet1	86.99	73.69	78.65	76.09	84.3	88.6
Önerilen ResNet2	86.58	74.01	75.57	74.78	83.0	88.29
Destek Vektör Makinası	87.14	73.83	79.23	76.43	84.6	91.06
Lojistik Regresyon	87.19	74.22	78.65	76.37	84.5	91.06
Karar Ağacı	79.55	61.19	60.96	61.07	73.6	91.06
Naive Bayes	87.14	74.09	78.65	76.30	84.4	91.06
k-En Yakın Komşu	85.57	73.17	71.34	72.24	81.0	91.06
Lineer Diskriminant Analizi	87.19	74.22	78.65	76.37	84.5	91.06

Tablo 6. Veri Artırmadan Sonraki Değerler

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Ölçüm	AUC	Train Accuracy
Önerilen ResNet1	90.47	91.58	91.98	91.78	90.02	91.09
Önerilen ResNet2	90.83	92.40	91.69	92.04	90.07	91.06
Destek Vektör Makinaları	87.15	91.10	86.21	88.59	87.03	91.06
Lojistik Regresyon	87.19	91.17	86.21	88.62	87.4	91.06
Karar Ağacı	88.25	91.27	88.12	89.67	88.3	91.06
Naive Bayes	86.87	92.62	84.00	88.10	87.4	91.06
k-En Yakın Komşu	88	91.08	87.86	89.44	88	91.06
Lineer Diskriminant Analizi	86.13	91.06	84.30	87.55	86.5	91.06

Tablo 4 üzerinde inceleme yapıldığında, en yüksek başarı %87.19 doğruluk ile Lojistik Regresyon ve Lineer Diskriminant Analizinden (LDA) alınmıştır. Destek Vektör Makinası (DVM) ve Naive Bayes'den %87.14 başarı alınmıştır. Önerilen ResNet1 ve ResNet2 için sırası ile %86.99 ve %86.58 doğruluk ile başarılı sonuçlar alınmıştır. k-En yakın komşu (k-NN) %85.57 başarı göstermiştir. En düşük başarı ise %79.55 doğruluk oranı ile Karar Ağacından alınmıştır. Tablo 5 üzerinde inceleme yapıldığında, en yüksek başarı %90.83 doğruluk ile önerilen ResNet2'den alınmıştır. Bu başarı oranını %90.47 ile ResNet1 takip etmiştir. Karar Ağacı %88.25, k-NN %88, Lojistik Regresyon %87.19, DVM %87.15, Naive Bayes %86.87 ve LDA %86.13 doğruluk oranlarını vermiştir. Bu sonuçlara göre veri artırmadan önce en yüksek doğruluk oranını LDA verirken veri artırımından sonra ise ResNet2 modeli en yüksek doğruluk oranını vermiştir.

Elde edilen sonuçlara göre veri artırmadan önceki (Tablo 6) karmaşıklık matrisi ve veri artırımından sonraki (Tablo 7) karmaşıklık matrisi verilmiştir. Veri artırmadan önce ve sonra elde edilen karışıklık matrisi sonuçları incelendiğinde, önerilen ResNet1 ve önerilen ResNet2'nin diğer modeller gibi başarılı sonuçlar verdiği gözlemlenmiştir (Tablo 6-7).



Tablo 7. Veri Artırımından Önce Karmaşıklık Matrisi


Modeller	Gerçek Sınıflar	Tahmin Edilen	
		1	2
Önerilen ResNet1	1	1310	146
	2	111	409
Önerilen ResNet2	1	1318	138
	2	127	393
DVM	1	1310	146
	2	108	412
Lojistik Regresyon	1	1314	142
	2	111	409
Karar Ağacı	1	1255	201
	2	203	317
Naive Bayes	1	1313	143
	2	111	409
k-NN	1	1320	136
	2	149	371
LDA	1	1314	142
	2	111	409

Tablo 8. Veri Artırmadan Sonra Karmaşıklık Matrisi


Model	Gerçek Sınıflar	Tahmin Edilen	
		1	2
Önerilen ResNet1	1	1751	230
	2	218	2502
Önerilen ResNet2	1	1776	205
	2	226	2494
DVM	1	1752	229
	2	375	2345
Lojistik Regresyon	1	1754	227
	2	375	2345
Karar Ağacı	1	1752	229
	2	323	2397
Naive Bayes	1	1799	182
	2	435	2285
k-NN	1	1747	234
	2	330	2390
LDA	1	1756	225
	2	427	2293

Gözlemlenen diğer performans ölçütü ROC eğrisidir. ROC eğrisinde, çıkan sonuçlara göre eğri grafiğin sol üst kenarına ne kadar yakınsa model o kadar başarılı olur. Şekil 7 ile Şekil 14 arasındaki sonuçlar incelendiğinde genel olarak veri artırdıktan sonra modellerin başarı oranının arttığı gözlemlenmiştir.


**Şekil 7.** Sırası ile veri artırmadan önce ve sonra önerilen ResNet1 sonuçları**Şekil 8.** Sırası ile veri artırmadan önce ve sonra önerilen ResNet2 sonuçları




Şekil 9. Sırası ile veri artırmadan önce ve sonra SVM sonuçları




Şekil 10. Sırası ile veri artırmadan önce ve sonra Lojistik Regresyon sonuçları




Şekil 11. Sırası ile veri artırmadan önce ve sonra Karar Ağacı sonuçları



Şekil 12. Sırası ile veri artırmadan önce ve sonra Naive Bayes sonuçları




Şekil 13. Sırası ile veri artırmadan önce ve sonra k-NN sonuçları




Şekil 14. Sırası ile veri artırmadan önce ve sonra LDA sonuçları


Önerilen derin öğrenme modellerinin performans sonuçlarını karşılaştırmak için loss-accuracy grafikleri çizdirilmiştir. Veri artırılmadan önce önerilen ResNet1 ve ResNet2 modellerinde aşırı öğrenme durumu gözlemlenmiştir (Şekil 15, Şekil 17). Bu durumun veri artırılmadan sonra azaldığı çok net görülmüştür (Şekil 16, Şekil 18).



. Veri artırmadan önce önerilen ResNet1 sonuçları



. Veri artırmadan sonra önerilen ResNet1 sonuçları



. Veri artırmadan önce önerilen ResNet2 sonuçları



Şekil 15. Veri artırmadan sonra önerilen ResNet2 sonuçları

TARTIŞMA VE SONUÇ

Makine öğrenmesi ve derin öğrenme algoritmalarının kullanıldığı bu tez çalışmasında elde edilen sonuçlar aşağıdaki gibidir:

- ResNet1 modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %86.99 iken modelin doğru sınıflandırdığı sınıf sayısı 1719, yanlış sınıflandırdığı sınıf sayısı 257'dir. Bunlardan etiket numarası 1 olan (marka değiştirmek isteyen müşteri)1456 adet müşteriden 1310 adet müşteriyi doğru 146 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan (marka değiştirmek istemeyen müşteri) 520 adet müşteriden 409 adet müşteriyi doğru 111 adet müşteriyi yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %90.47 olup modelin doğru sınıflandırdığı sınıf sayısı 4253, yanlış sınıflandırdığı sınıf sayısı 448'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1751 adet müşteriyi doğru 230 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2502 adet müşteriyi doğru 218 adet müşteriyi yanlış sınıflandırmıştır.
- ResNet2 modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %86.58 iken modelin doğru sınıflandırdığı sınıf sayısı 1711, yanlış sınıflandırdığı sınıf sayısı 265'dir. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1318 adet müşteriyi doğru 138 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 393 adet müşteriyi doğru 127 adet müşteriyi yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %90.83 olup modelin doğru sınıflandırdığı sınıf sayısı 4270, yanlış sınıflandırdığı sınıf sayısı 431'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1776 adet müşteriyi doğru 205 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2494 adet müşteriyi doğru 226 adet müşteriyi yanlış sınıflandırmıştır.
- DVM modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %87.14 iken modelin doğru sınıflandırdığı sınıf sayısı 1722, yanlış sınıflandırdığı sınıf sayısı 254'tür. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1310 adet müşteriyi doğru 146 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 412 adet müşteriyi doğru 108 adet müşteriyi yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %87.15 olup modelin doğru sınıflandırdığı sınıf sayısı 4097, yanlış sınıflandırdığı sınıf sayısı

674'tür. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1752 adet müşteriye doğru 229 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2345 adet müşteriye doğru 375 adet müşteriye yanlış sınıflandırmıştır.

- Lojistik Regresyon modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %87.19 iken modelin doğru sınıflandırdığı sınıf sayısı 1723, yanlış sınıflandırdığı sınıf sayısı 253'tür. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1314 adet müşteriye doğru 142 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 409 adet müşteriye doğru 111 adet müşteriye yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise yine %87.19 olup modelin doğru sınıflandırdığı sınıf sayısı 4099, yanlış sınıflandırdığı sınıf sayısı 602'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1754 adet müşteriye doğru 227 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2345 adet müşteriye doğru 375 adet müşteriye yanlış sınıflandırmıştır.
- Karar Ağacı modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %79.55 iken modelin doğru sınıflandırdığı sınıf sayısı 1572, yanlış sınıflandırdığı sınıf sayısı 404'tür. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1255 adet müşteriye doğru 201 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 317 adet müşteriye doğru 203 adet müşteriye yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %88.25 olup modelin doğru sınıflandırdığı sınıf sayısı 4149, yanlış sınıflandırdığı sınıf sayısı 552'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1752 adet müşteriye doğru 229 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2397 adet müşteriye doğru 323 adet müşteriye yanlış sınıflandırmıştır.
- Naive Bayes modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %87.14 iken modelin doğru sınıflandırdığı sınıf sayısı 1722, yanlış sınıflandırdığı müşteri sayısı 254'tür. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1313 adet müşteriye doğru 143 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 409 adet müşteriye doğru 111 adet müşteriye yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %86.87 olup modelin doğru sınıflandırdığı sınıf sayısı 4084, yanlış sınıflandırdığı sınıf sayısı 617'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1799 adet müşteriye doğru 182 adet müşteriye yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2285 adet müşteriye doğru 435 adet müşteriye yanlış sınıflandırmıştır.

- K-NN modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %85.57 iken modelin doğru sınıflandırdığı sınıf sayısı 1691, yanlış sınıflandırdığı sınıf sayısı 285'tir. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1320 adet müşteriyi doğru 136 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 371 adet müşteriyi doğru 149 adet müşteriyi yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %88 olup modelin doğru sınıflandırdığı sınıf sayısı 4137, yanlış sınıflandırdığı sınıf sayısı 564'tür. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1747 adet müşteriyi doğru 234 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2390 adet müşteriyi doğru 330 adet müşteriyi yanlış sınıflandırmıştır.
- LDA modelinden elde edilen sonuçlara göre: Veri artırma işlemi uygulanmadan önce elde edilen doğruluk değeri %87.19 iken modelin doğru sınıflandırdığı sınıf sayısı 1723, yanlış sınıflandırdığı sınıf sayısı 253'tür. Bunlardan etiket numarası 1 olan 1456 adet müşteriden 1314 adet müşteriyi doğru 142 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 520 adet müşteriden 409 adet müşteriyi doğru 111 adet müşteriyi yanlış sınıflandırmıştır. Veri artırımından sonra elde edilen doğruluk değeri ise %86.13 olup modelin doğru sınıflandırdığı sınıf sayısı 4049, yanlış sınıflandırdığı sınıf sayısı 652'dir. Bunlardan etiket numarası 1 olan 1981 adet müşteriden 1756 adet müşteriyi doğru 225 adet müşteriyi yanlış sınıflandırmıştır. Etiket numarası 2 olan 2720 adet müşteriden 2293 adet müşteriyi doğru 427 adet müşteriyi yanlış sınıflandırmıştır.

Yukarıdaki sonuçlardan da anlaşılacağı üzere Önerilen ResNet1 ve Önerilen ResNet2 modelleri doğruluk değerleri bakımından hem veri artırımından önce(Önerilen ResNet1 %86.99 ve Önerilen ResNet2 %86.58) hem de veri artırımından sonra(Önerilen ResNet1 %90.47 ve Önerilen ResNet2 %90.83) iyi sonuçlar vermiştir. Aynı zamanda ROC eğrileri grafiklerinde de eğrinin veri artırımından sonra sol üst köşeye daha çok yaklaştığı görülmüştür. Makine öğrenme modellerinin doğruluk değerleri ise veri artırmadan önce SVM %87.14, Lojistik Regresyon %87.19, Karar Ağacı %79.55, Naive Bayes %87.14, k-NN %85.57, LDA %87.19 ve veri artırımında sonra doğruluk değerleri SVM %87.15, Lojistik Regresyon %87.19, Karar Ağacı %88.25, Naive Bayes %86.87, k-NN %88, LDA %86.13 şeklindedir. Veri artırımından önce en yüksek doğruluk oranına sahip modeller Lojistik Regresyon ve LDA iken veri artırımından sonra en yüksek doğruluk oranına sahip model Karar Ağacıdır. Yine veri artırımından sonra makine öğrenme modellerinin ROC eğrileri grafiklerinde de eğrinin sol üst köşeye yaklaştığı görülmüştür. Sonuç olarak en iyi değerleri Önerilen ResNet1 ve Önerilen ResNet2 modelleri vermiştir. Yapılan bu tez çalışması kapsamında ve literatürde yer alan diğer

alışmalar da göstermiştir ki makine öğrenmesi ve derin öğrenme birçok iş alanında fayda sağlamakta ve işletmelere büyük ölçüde yardımcı olmaktadır.



KAYNAKÇA

- Aguwa, C., Olya, M. H., & Monplaisir, L. 2017. Modeling of fuzzy-based voice of customer for business decision analytics. *Knowledge-Based Systems*, 125, 136-145.
- Akoğlu, S., 2018. Makine öğrenmesi, <https://deepinsightr.com/> (15.07.2021).
- Albrecht, T., Rausch, T. M., & Derra, N. D. 2021. Call me maybe: Methods and practical implementation of artificial intelligence in call center arrivals' forecasting. *Journal of Business Research*, 123, 267-278.
- Alper, B., 2010. Müşteri ilişkileri yönetimi açısından şikayetlerin yönetilmesi: Otel işletmesi üzerine bir uygulama. Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, Balıkesir Üniversitesi, Balıkesir.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L., 2021. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 1-74.
- Amidi, S., 2022. Evrişimli sinir ağları el kitabı. <https://stanford.edu/~shervine/l/tr/> (02.04.2022).
- Avcı, O., 2021. Vergi tahsilatında yapay zekânın kullanımı ve önemi. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 22(1), 51-63.
- Aydın, C., 2018. Makine öğrenmesi algoritmaları kullanılarak itfaiye istasyonu ihtiyacının sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (14), 169-175.
- Banar, K. ve Ekergil, V., 2010. Muhasebe meslek mensuplarının hizmet kalitesi: sunulan hizmetlerin kalitesi ile müşteri memnuniyeti ilişkisi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*. Cilt: 10, sayı: 1, ss: 39-60
- Batı, F., 2020. Makine öğrenmesi sınıflandırma algoritmaları kullanılarak meme kanseri tahmini. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Aydın Üniversitesi, İstanbul.
- Baytekin, E. P. 2005. Toplam kalite hedefinde müşteri memnuniyetinden müşteri sadakatine. *Ege Üniversitesi İletişim Fakültesi Yeni Düşünceler Hakemli E-Dergisi*, (1), 41-52.
- Bedi, J., & Toshniwal, D. (2022). CitEnergy: A BERT based model to analyse Citizens' Energy-Tweets. *Sustainable Cities and Society*, 80, 103706.
- Bhavsar, H., & Ganatra, A., 2012. A comparative study of training algorithms for supervised machine learning. *International Journal of Soft Computing and Engineering (IJSCE)*, 2(4), 2231-2307.
- Bonaccorso, G., 2017. Machine learning algorithms. Packt Publishing Ltd.
- Burkart, N., & Huber, M. F., 2021. A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, 70, 245-317.
- Burucuoğlu, M., 2011. Müşteri memnuniyeti ve sadakatini arttırmada müşteri şikayetleri yönetiminin etkinliği: Bir örnek olay incelemesi. Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, Karamanoğlu Mehmetbey Üniversitesi, Karaman.
- Chang, Y. C., Ku, C. H. & Le Nguyen, D. D., 2022. Predicting aspect-based sentiment using deep learning and information visualization: The impact of COVID-19 on the airline industry. *Information & Management*, 59(2), 103587.

- Chen, Z. Y., Fan, Z. P., & Sun, M. (2016). A multi-kernel support tensor machine for classification with multitype multiway data and an application to cross-selling recommendations. *European Journal of Operational Research*, 255(1), 110-120.
- Cheng, S. W., Choy, K. L., & Lam, H. Y. (2015). A workflow decision support system for achieving customer satisfaction in warehouses serving machinery industry. *IFAC-PapersOnLine*, 48(3), 1714-1719.
- Choi, C. (2018). Predicting customer complaints in mobile telecom industry using machine learning algorithms (Doctoral dissertation, Purdue University).
- Coussement, K., Benoit, D. F., & Antioco, M. (2015). A Bayesian approach for incorporating expert opinions into decision support systems: A case study of online consumer-satisfaction detection. *Decision Support Systems*, 79, 24-32.
- De Cnudde, S., & Martens, D. (2015). Loyal to your city? A data mining analysis of a public service loyalty program. *Decision Support Systems*, 73, 74-84.
- Dive into deep learning, 2021. https://d2l.ai/chapter_convolutional-modern/resnet.html#residual-blocks (02.04.2022).
- Ecevit, M.İ., 2016. A Theoretical Comparison of Resnet and Densenet Architectures on the Subject of Shoreline Extraction. Master Thesis, Institute of Science, Işık University, İstanbul.
- Elektrikport. Regresyon algoritmaları, <https://www.elektrikport.com/> (15.07.2021).
- Endüstri 4.0., Yapay zeka, <https://www.endustri40.com/> (15.07.2021).
- Gaur, L., Afaq, A., Solanki, A., Singh, G., Sharma, S., Jhanjhi, N. Z., ... & Le, D. N. (2021). Capitalizing on big data and revolutionary 5G technology: Extracting and visualizing ratings and reviews of global chain hotels. *Computers & Electrical Engineering*, 95, 107374.
- Ghazzawi, A., & Alharbi, B., 2019. Analysis of customer complaints data using data mining techniques. *Procedia Computer Science*, 163, 62-69.
- Gupta, M., Singh, A., Jain, R., Saxena, A., & Ahmed, S., 2021. Multi-class railway complaints categorization using Neural Networks: RailNeural. *Journal of Rail Transport Planning & Management*, 20, 100265.
- Güler, H. N., 2020. Koronavirüsü (Covid-19) günlerinde bankalara iletilen müşteri itiraz ve şikayetlerinin incelenmesi. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, 7(4), 85-99.
- Güneş, O.M., 2020. Makine öğrenmesi yöntemleri kullanılarak karaciğer sirozu hastalığını etkileyen faktörlerin sınıflandırılması. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü İstatistik Anabilim Dalı, Ondokuz Mayıs Üniversitesi, Samsun.
- ImageNet, 2021. <http://www.image-net.org> (02.04.2022).
- İnnova, 2007. Müşteri memnuniyeti, <https://www.innova.com.tr/tr> (15.07.2021).
- Kamil, U., Çakıcı, C. ve Taştan, A. G. H., 2010. Paket turlardaki müşteri şikayetleri ve seyahat acentalarının bu şikayetlerle karşılaşma sıklıkları üzerine bir araştırma. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 19(3), 391-408.
- Kara, F. B., 2021. evrişimli sinir ağları ile histopatolojik görüntülerden melanom tespiti. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Düzce Üniversitesi, Düzce.

- Karaoğlu, B., 2015. Makine öğrenmesi ile spor karşılaşmalarının modellenmesi. *Emo Bilimsel Dergi*, 5(9), 1-5.
- Kaynar, O., Tuna, M. F., Görmez, Y. and Deveci, M. A., 2017. Makine öğrenmesi yöntemleriyle müşteri kaybı analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(1), 1-14.
- Khedkar, S., & Shinde, S., 2020. Deep learning and ensemble approach for praise or complaint classification. *Procedia Computer Science*, 167, 449-458.
- Kılıç, E., 2016. Evrişimli sinir ağları ile mitotik figür sınıflandırması. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Erciyes Üniversitesi, Kayseri.
- Kurt, F., 2018. Evrişimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Hacettepe Üniversitesi, Ankara.
- Kuswanto, H., Asfihani, A., Sarumaha, Y., & Ohwada, H. (2015). Logistic regression ensemble for predicting customer defection with very large sample size. *Procedia Computer Science*, 72, 86-93.
- Kwon, W., Lee, M., & Back, K. J. (2020). Exploring the underlying factors of customer value in restaurants: A machine learning approach. *International Journal of Hospitality Management*, 91, 102643.
- Li, F., & Xu, G. (2022). AI-driven customer relationship management for sustainable enterprise performance. *Sustainable Energy Technologies and Assessments*, 52, 102103.
- Maldonado, S., Flores, Á., Verbraken, T., Baesens, B., & Weber, R. (2015). Profit-based feature selection using support vector machines—General framework and an application for customer retention. *Applied Soft Computing*, 35, 740-748.
- Maulud, D., & Abdulazeez, A. M., 2020. A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(4), 140-147.
- Medium, <https://medium.com/> (20.07.2021).
- Mutluoğlu, S. E., 2019. Road image segmentation by using resnet autoencoder hybrid model. Master Thesis, Graduate School of Natural and Applied Sciences, Electronic-Communication Education Department, Electronics Engineering Department, Istanbul Technical University, Istanbul.
- Nilashi, M., Ahmadi, H., Arji, G., Alsalem, K. O., Samad, S., Ghabban, F., ... & Alarood, A. A., 2021. Big social data and customer decision making in vegetarian restaurants: A combined machine learning method. *Journal of Retailing and Consumer Services*, 62, 102630.
- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J., 2017. Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Osorio-Arjona, J., Horak, J., Svoboda, R., & García-Ruiz, Y. (2021). Social media semantic perceptions on Madrid Metro system: Using Twitter data to link complaints to space. *Sustainable Cities and Society*, 64, 102530.
- Prowmes. <http://www.prowmes.com/index.html> (15.07.2021).
- Ramaswamy, S., & DeClerck, N., 2018. Customer perception analysis using deep learning and NLP. *Procedia Computer Science*, 140, 170-178.

- Rodriguez, M. Z., Comin, C. H., Casanova, D., Bruno, O. M., Amancio, D. R., Costa, L. D. F., & Rodrigues, F. A., 2019. Clustering algorithms: A comparative approach. *PloS one*, 14(1), e0210236.
- Seeger-Guttmann, T., Vilnai-Yavetz, I., Wang, C. Y., & Petruzzellis, L. 2018. Illegitimate returns as a trigger for customers' ethical dissonance. *Journal of Retailing and Consumer Services*, 45, 120-131.
- Ser, G. ve Bati, C. T., 2019. Derin sinir ağıları ile en iyi modelin belirlenmesi: mantar verileri üzerine keras uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417.
- Serçemeli, M. (2018). Muhasebe ve denetim mesleklerinin dijital dönüşümünde yapay zekâ. *Electronic Turkish Studies*, 13(30).
- Shrestha, A., & Mahmood, A., 2019. Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040-53065.
- Singh, A., Saha, S., Hasanuzzaman, M., & Jangra, A. 2021. Identifying complaints based on semi-supervised mincuts. *Expert Systems with Applications*, 186, 115668.
- Singh, A., Thakur, N., & Sharma, A., 2016. A review of supervised machine learning algorithms. In 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom) (pp. 1310-1315). Ieee.
- Stevens, J. L., Spaid, B. I., Breazeale, M., & Jones, C. L. E. 2018. Timeliness, transparency, and trust: A framework for managing online customer complaints. *Business Horizons*, 61(3), 375-384.
- Strateji co, 1987. Yapay zeka ve makine öğrenme uygulamaları, <https://stratejico.com/> (15.01.2022).
- Sutton, R. S., & Barto, A. G., 2018. Reinforcement learning: An introduction. MIT press.
- Syarifudin, M. A., Novitasari, D. C. R., Marpaung, F., Wahyudi, N., Hapsari, D. P., Supriyati, E., ... & Setiawan, F., 2021. Hotspot prediction using 1d convolutional neural network. *Procedia Computer Science*, 179, 845-853.
- Şeker, A., Diri, B., & Balık, H. H., 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Şen, Y. F. ve Yurtoğlu, D., 2020. Teknoloji ve güvenlik ilişkisi bağlamında yapay zekânın istihbarat analizindeki önemi. *Güvenlik Çalışmaları Dergisi*, 22(1), 24-48.
- Şikayetvar.com., 2011. <https://www.sikayetvar.com/> (15.05.2021).
- Takahashi, M., Azuma, H., & Tsuda, K. (2015). A study on deliberate presumptions of customer payments with reminder in the absence of face-to-face contact transactions. *Procedia Computer Science*, 60, 968-975.
- Timur, N., 1998. Büyük mağazalarda müşteri şikayetlerinin ele alınması ve düzeltici önlemler. *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(2), 111-121.
- Türkmen, E., 2021. makine öğrenmesi yöntemleri ile banka pazarlama tahmini. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Kültür Üniversitesi, İstanbul.
- Uddin, S., Khan, A., Hossain, M. E., & Moni, M. A., 2019. Comparing different supervised machine learning algorithms for disease prediction. *BMC medical informatics and decision making*, 19(1), 1-16.

- Vafeiadis, T., Diamantaras, K. I., Sarigiannidis, G., & Chatzisavvas, K. C. (2015). A comparison of machine learning techniques for customer churn prediction. *Simulation Modelling Practice and Theory*, 55, 1-9.
- Vidya, N. A., Fanany, M. I., & Budi, I. (2015). Twitter sentiment to analyze net brand reputation of mobile phone providers. *Procedia Computer Science*, 72, 519-526.
- Vo, N. N., Liu, S., Li, X., & Xu, G. (2021). Leveraging unstructured call log data for customer churn prediction. *Knowledge-Based Systems*, 212, 106586.
- Wikipedia, 2001. <https://tr.wikipedia.org/wiki/Anasayfa> (15.07.2021).
- Xia, K. J., Yin, H. S., & Zhang, Y. D. 2019. Deep semantic segmentation of kidney and space-occupying lesion area based on SCNN and ResNet models combined with SIFT-flow algorithm. *Journal of medical systems*, 43(1), 1-12.
- Yang, Y., Xu, D. L., Yang, J. B., & Chen, Y. W., 2018. An evidential reasoning-based decision support system for handling customer complaints in mobile telecommunications. *Knowledge-Based Systems*, 162, 202-210.
- Yeni iş fikirleri, 2021. Müşteri şikayetleri, <https://www.yeniisfikirleri.net/> (15.01.2022)
- Yılmaz, Ö. Ü. A. & Yayın, K. 2021. Derin öğrenme. Kodlab Yayın Dağıtım Yazılım LTD.ŞTİ.
- Yıldız Erduran, G., 2017. Online müşteri şikayetlerinin veri madenciliği ile incelenmesi.
- Zhong, B., Xing, X., Love, P., Wang, X., & Luo, H., 2019. Convolutional neural network: Deep learning-based classification of building quality problems. *Advanced Engineering Informatics*, 40, 46-57.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı :	Zeliha MAHMAT
Doğum tarihi :	
Doğum Yeri :	
Uyruğu :	
Adres :	
Tel :	
E-mail:	
Eğitim	
Lise :	Atatürk Anadolu Lisesi (ELAZIĞ/MERKEZ)
Lisans :	Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü (KOCAELİ/İZMİT)
Yüksek lisans:	Atatürk Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Ana Bilim Dalı
Yabancı Dil Bilgisi	
İngilizce :	Orta