



**HİZMET SEKTÖRÜNDE DERİN ÖĞRENME VE
MAKİNE ÖĞRENMESİ TEKNİKLERİYLE
AKILLI TEDARİK SİSTEMİ TASARIMI**

Zümrüt YILDIRIM

Danışman: Doç. Dr. Burak ERKAYMAN
Yüksek Lisans Tezi
Endüstri Mühendisliği Ana Bilim Dalı
2023
(Her Hakkı Saklıdır.)

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

**HİZMET SEKTÖRÜNDE DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ
TEKNİKLERİYLE AKILLI TEDARİK SİSTEMİ TASARIMI**
(Intelligent Supply System Design With Deep Learning and Machine Learning Techniques in
The Service Industry)

YÜKSEK LİSANS TEZİ

Zümrüt YILDIRIM

Danışman: Doç. Dr. Burak ERKAYMAN

Erzurum
Şubat, 2023



FEN BİLİMLERİ ENSTİTÜSÜ
Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

HİZMET SEKTÖRÜNDE DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ TEKNİKLERİ
İLE AKILLI TEDARİK SİSTEMİ TASARIMI

Doç. Dr. Burak ERKAYMAN danışmanlığında, Zümrüt YILDIRIM tarafından hazırlanan bu çalışma, 06/02/2023 tarihinde aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı Endüstri Mühendisliği Bilim Dalı'nda Yüksek Lisans tezi olarak **oybirliği / oy çokluğu (.../...)** ile kabul edilmiştir.

Jüri Başkanı:	Doç. Dr. Muhammed Emre KESKİN <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Danışman:	Doç. Dr. Burak ERKAYMAN <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Doktor Öğretim Üyesi Şeyma EMEÇ <i>Erzurum Teknik Üniversitesi</i>	Aslı Islak İmzalıdır

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



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 “Hizmet Sektöründe Derin Öğrenme ve Makine Öğrenmesi Teknikleriyle Akıllı Tedarik Sistemi Tasarımı” 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	1	30
Kuramsal Temeller	0	30
Materyal ve Metot	4	35
Araştırma Bulguları ve Tartışma	0	20
Sonuçlar ve Öneriler	0	20
Tezin Geneli	2	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
Zümrüt YILDIRIM	Doç.Dr Burak ERKAYMAN
7.2.2023	7.2.2023
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.

TEŐEKKÖR

BaŐta tez yazma sűrecim ve projelerim olmak űzere her konuda benden desteklerini ve bilgilerini eksik etmeyen , yol gűsteren kıymetli Hocam Doç. Dr. Burak ERKAYMAN'a,

Eđitim hayatım boyunca her noktada destek olan deđerli Abim Bilgisayar Műhendisi Orhan YILDIRIM'a,

Proje boyunca her noktada desteklerini, bilgilerini benimle paylaŐan deđerli Abim Yazılım Műhendisi Dr. İbrahim YILDIRIM'a,

Uzaktardan bilgi ve sevgilerini eksik etmeyen kıymetli dostlarım Endűstri Műhendisleri Elif KARADERELİ & Çađrı KURNAZ'a sonsuz teŐekkűrlerimi saygı ve sevgi ile sunuyorum.

Zűmrűt YILDIRIM

ÖZET

YÜKSEK LİSANS TEZİ

HİZMET SEKTÖRÜNDE DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE AKILLI TEDARİK SİSTEMİ TASARIMI

Zümrüt YILDIRIM

Danışman: Doç. Dr. Burak ERKAYMAN

Amaç: Kafe & Restoran bazlı işletmelerin satışlarına etki eden parametrelerinin araştırılması ve bu işletmeler için akıllı tedarik sistemi tasarımının yapılmasıdır. Bu çalışmada 154 farklı işletmenin satış verileri değerlendirilmeye alınmıştır.

Yöntem: Bu çalışma Yapay Zekâ Yöntemleri içerisinde bulunan Makine öğrenmesi sınıflandırma algoritmaları ve derin öğrenme yöntemleri kullanılarak geliştirilmiştir. Makine öğrenmesi sınıflandırma algoritmaları arasında karşılaştırma yapılmıştır ve bu çalışmaya en uygun makine öğrenmesi sınıflandırma algoritması belirlenmiştir. Aynı zamanda derin öğrenme ve makine öğrenmesi algoritmalarının sonuçları karşılaştırılmış ve bu çalışmaya en uygun yöntem belirlenmiştir.

Bulgular: Çalışma yapılırken hizmet sektöründeki satışlar üzerine Hava Durumu(Sıcaklık, Yağış Miktarı, Nispi Nem, Rüzgâr Hızı), Şehir, Gün parametrelerinin etkilerinin değerleri ölçülmüştür. Çalışmada önce hava durumunun satışlara etkisine bakılmıştır hava durumu değerleri tek başına satış değerlerine üzerine etkisinin az olduğuna saptanmıştır. Hava Durumu ile birlikte işletmenin bulunduğu İl ve satışın gerçekleştiği günün hafta içi veya hafta sonu olması durumu birlikte ele alındığında satışlar üzerindeki etkinin arttığı görülmüştür.

Sonuç: Hizmet sektöründeki satışlara hava durumunun etkisi incelenmiş ve Makine öğrenmesi sınıflandırma algoritmaları ve derin öğrenme yöntemleri ile yapılan bu çalışma sonucunda bu uygulama için en uygun sınıflandırma algoritmasının Gradyan Artırma Sınıflandırma Algoritması olduğu belirlenmiştir.

Anahtar Kelimeler: Akıllı Tedarik Sistemi, Akıllı Depo Tasarımı, Akıllı Stok Yönetimi, Envanter Planlama, Hizmet Sektörü, Hava Durumu, Kafe ve Restoran Satışları, Yapay Zekâ, Makine Öğrenmesi Sınıflandırma Algoritmaları, Derin Öğrenme Teknikleri.

Şubat 2023, 53 sayfa

ABSTRACT

MASTER THESIS

SMART STOCK MANAGEMENT SYSTEM DESIGN WITH DEEP LEARNING AND MACHINE LEARNING TECHNIQUES IN THE SERVICE INDUSTRY

Zümürüt YILDIRIM

Supervisor: Assoc. Prof. Dr. Burak ERKAYMAN

Purpose: Researching the parameters that affect the sales of Cafe & Restaurant based businesses and designing a smart supply system for these businesses. In this study, sales data of 154 different businesses were evaluated.

Method: This study was developed by using Machine learning classification algorithms and deep learning methods in Artificial Intelligence Methods. A comparison was made between machine learning classification algorithms and the most suitable machine learning classification algorithm for this study was determined. At the same time, the results of deep learning and machine learning algorithms were compared and the most suitable method for this study was determined.

Findings: During the study, the values of the effects of Weather (Temperature, Precipitation, Relative Humidity, Wind Speed), City, Day parameters on sales in the service sector were measured. In the study, the effect of the weather on the sales was examined first and it was determined that the weather values alone had little effect on the sales values. It has been observed that the effect on sales increases when the city where the business is located, together with the weather and whether the day of the sale is a weekday or weekend is considered together.

Results: The effect of weather conditions on sales in the service sector was examined, and as a result of this study conducted with machine learning classification algorithms and deep learning methods, it was determined that the most suitable classification algorithm for this application was Gradient Boost Classification Algorithm.

Keywords: Smart Supply System, Intelligent Warehouse Design, Intelligent Stock Management, Inventory Planning, Service Industry, Weather, Cafe and Restaurant Sales, Artificial Intelligence, Machine Learning Classification Algorithms, Deep Learning Techniques.

February 2023, 53 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.....	11
KURAMSAL TEMELLER.....	16
Satış Miktarı Tahmini	16
Hava Durumu Parametreleri	17
Ürünler	17
Müşteri	18
MATERYAL VE YÖNTEM	19
Yapay Zekâ	19
Makine Öğrenmesi	20
Denetimli/Gözetimli Makine Öğrenmesi Algoritmaları	21
A. Sınıflandırma algoritmaları	23
B. Regresyon algoritmaları	23
Denetimsiz/Gözetimsiz Makine Öğrenmesi Algoritmaları.....	24
A. Kümeleme	24
B. İlişkilendirme Kuralı	25
Takviyeli/Pekiştirmeli Öğrenme	25
Çalışmada Kullanılan Denetimli/Gözetimli Makine Öğrenme Algoritmaları	26
Karar ağaçları	26
Destek vektör makinaları	27
K-En yakın komşu	28
Rasgele orman modeli.....	28
Gradyan artırma modeli	29

Sınıflandırma Algoritmaları Performans Ölçütleri	30
Karmaşıklık matrisi (confusion matrix).....	30
Yapay Sinir Ağı (ANN)	30
Derin öğrenme.....	31
Çalışmada Kullanılan Derin Öğrenme Yöntemleri.....	33
ARAŞTIRMA BULGULARI	34
Veri Seti	34
1. Ürün	34
2. Müşteri	35
3. Satış.....	35
Hava Durumu Verileri.....	36
Veri Ön İşleme (Data Preproceesing)	36
Ürün Gruplama İşlemi.....	37
Makine Öğrenme Algoritmaları ve Derin Sinir Ağı Modeli Sonuçları	45
SONUÇ.....	46
KAYNAKÇA	47
ÖZGEÇMİŞ.....	51

TABLÖLAR DİZİNİ

Tablo 1. Sınıflandırma Algoritmaları İçin Performans Değerlendirmesi	45
---	----



ŞEKİLLER DİZİNİ

Şekil 1. Denetimli/gözetimli öğrenme.....	22
Şekil 2. Karar ağaçlarının genel yapısı.....	26
Şekil 3. Destek vektör makinaları genel yapısı	27
Şekil 4. K-en yakın komşu algoritmasının çalışma biçimi.....	28
Şekil 5. Rastgele orman algoritması.....	29
Şekil 6. İkili sınıflandırma için karmaşıklık matrisi ve performans metrikleri.....	30
Şekil 7. Yapay sinir ağları genel yapısı.....	31
Şekil 8. Derin sinir ağları genel görünüm	32
Şekil 10. Ürün veri setinden alınan 8 örnek	34
Şekil 11. Müşteri gruplarına ait veri setinden örnek	35
Şekil 12. Satış veri seti	35
Şekil 13. Birleştirilmiş son tablo	36
Şekil 14. Ortalama hava durumu veri setinden örnek	37
Şekil 15. Ürün grup örnek tablo	38
Şekil 16. Aykırı veriler kutu grafiği gösterimi.....	39
Şekil 17. Makine öğrenmesine girecek veri seti.....	40
Şekil 18. Korelasyon grafiği.....	41
Şekil 19. Veri seti istatistiksel açıklama.....	41
Şekil 20. Veri setinde satış miktarı ve tatil günlerine ait kutu grafiği.....	42
Şekil 21. Veri seti birleştirme için oluşturulan mimari yapı	42
Şekil 22. Akıl tedarik sistemi tasarımında farklı modellerin karşılaştırılmasında kullanılan mimari	43
Şekil 23. Derin sinir ağı eğitim geçmişi	43
Şekil 24. Loss fonksiyonun grafiği	44
Şekil 25. Gradyan artıma sınıflandırıcısı karmaşıklık matrisi.....	45

KISALTMALAR DİZİNİ

AI	: Yapay Zekâ/ Artificial Intelligence
DA	: Diskriminant Analizi /Discriminant Analysis
DL	: Derin Öğrenme/Deep Learning
DN	: Doğru Negatif/True Negative
DNN	: Derin Sinir Ağları /Deep Neural Network
DP	: Doğru Pozitif/True Positive
DRL	: Derin pekiştirmeli öğrenme/ Deep Reinforcement Learning
DT	: Karar Ağaçları /Decision Trees
GB	: Gradyan Artırma/Gradient Boostin
KNN	: K-En Yakın Komşu K/-Nearest Neighbor
LR	: Lojistik Regresyon /Logistic Regression
LSTM	: Uzun Kısa Vadeli Bellek /Long Short Term Memory
ML	: Makine Öğrenmesi/Machine Learning
MLR	: Çok Değişkenli Doğrusal Regresyon /Multivariate Linear Regression
NB	: Naif Bayes /Naive Bayes
NN	: Sinir Ağları /Neural Networks/NN
PR	: Polinom Regresyon /Polynomial Regression
RF	: Rasgele Orman/Random Forest
RNN	: Tekrarlayan Sinir Ağı /Recurrent Neural Network
SLR	: Basit Doğrusal Regresyon /Simple Linear Regression
SNN	: Yapay Sinir Ağı /Simple Neural Network
SSS	: Akıllı Tedarik Sistemi /Smart Supply System
SVM	: Destek Vektör Makinası /Support Vector Machine
YN	: Yanlış Negatif/False Negative
YP	: Yanlış Pozitif/ False Positive

GİRİŞ

Hizmet Sektörü gelişen teknolojik değişimler ile daha da kaliteli hale gelmiştir. Değişen ve gelişen teknoloji ile insanların yaşam kalite ve standartları da değişmektedir. Müşterinin taleplerinin doğru ve eksiksiz bir şekilde tam zamanında karşılanması hizmet yönetiminin temel amaçları arasındadır. Hizmet sektörü müşterinin isteklerini önceden tahmin edebilir ve buna yönelik işlemler yapabilir. Yapılan tahminlerin doğru ve eksiksiz olması hizmet yönetiminin kalitesini etkileyen önemli bir parametredir. İşletmeler kâr amacı güderek müşterilerin isteklerini en uygun şekilde karşılamaya çalışırlar. Hem müşteri isteğine yönelik çalışmak hem de kar elde etmek işletmeleri oldukça zorlamaktadır. Hizmet sektöründe müşterinin isteğini tahmin etmek noktasında nelerin etkili olduğu oldukça önemlidir. Bu sektörde işletmeler müşterinin istekleri doğrultusunda envanter planlaması yapmalı ve depolarının stok durumunu bu planlama doğrultusunda ayarlamalıdır. Fazla stok her zaman için bir maliyettir ve işletmeler fazla stok maliyetine katlanmak istemezler. Eksik stok noktasında ise müşteri isteği doğru zamanda karşılanamadığından işletmenin satışları üzerinde hem anlık hem de ileri vadede olumsuzluklara neden olur ve satış değerlerinde azalmalar olabilir. Doğru envanter planlamasının doğru zamanda yapılması gerekmektedir. Birçok dönem boyunca fazla stok ve süreç gecikmesi riskleri ortaya çıkabilir. Tam da bu noktalarda Endüstri 4.0 ve Akıllı Tedarik Sistemleri çözüm noktası olarak ele alınmıştır. İşletmeler ileriye dönük planlar ve tahminler yapmak isterler ve bu tahminlerin doğruluk derecesi geçmişten elde edilen verilerle yapılır. Veri depolama ve veriyi doğru kullanma Endüstri 4.0' ın temel prensipleri arasındadır.

Endüstri 4.0 akıllı fabrikaların üretim sistemlerinin dikey ve yatay entegre olmasını sağlayan, süreçlerin veriye bağlı olarak takip edildiği ve bilimsel yöntemlerle yönetildiği, Nesnelerin İnterneti (IOT), Makineler arasında etkileşim ve iletişim, Büyük Veri ile ilgilenen Sanayi Devrimidir.

Sanayi devrimlerinin amacı verimlilik artırmaktır. Bu sanayi devrimi, verimlilik artışı ile birlikte ürün geliştirme, lojistik ve mühendislik süreçlerinin tamamını kapsayarak bütün tedarik zincirini etkileyecektir. Tedarik zinciri ve tedarikçiler bu sanayi devriminde önemli bir rol oynamaktadır. Dijitalleşme ile gelen bilgi akışları ve kendini yönetebilen akıllı makine ve akıllı ürünler ile entegre olan mükemmel bir tedarik zinciri oluşmaktadır. Bu tedarik zinciri birbirine bağlı olan sistemleri desteklemekte ve bu sistemleri koordine etmektedir. Bu faktörler özellikle satın alma merkezleri, üretim aşaması, dağıtım noktaları için maliyet azaltmaları için

fırsatlar doğurmaktadır. Aynı zamanda şeffaf süreçler, tedarik zincirinde optimizasyon ve esneklikler oluşmaktadır. Tedarik 4.0 'da akıllı sistemler sayesinde bir malzemenin talebi belirlenebilir, insan müdahalesine ihtiyaç duymadan akıllı teknolojiler ile olarak tedarikçilere siparişler oluşturmaktadır.

Akıllı Tedarik Sisteminde tedarik zincirindeki her halkanın birbirleriyle mümkün olduğu kadar işbirlikçi ilişkilerin olduğu bir sistem geliştirilmiştir. Bu sistemler, daha etkin kararlar vermek için daha fazla ürüne sensörler yerleştirilip veri depoladıklarından daha dijital, akıllı ve daha fazla değer odaklı bir sistem haline gelmiştir.

SSS 'leri hızlı şekilde yönetilen ve akıllı teknolojik gelişmeleri kullanan esnek bir sistem olarak tasarlanır. Bu sistem insan müdahalesi olmayan bir sistemdir. Kendi kendine öğrenme ve karar alma yeteneklerine sahiptir. Bu öğrenme ile sadece reel zamanlı karar verme ile kalmayıp geleceğe yönelik tahminler yapmaktadır. Gelişmiş modelleme algoritmaları ve simülasyon yetenekleri ile oluşturulmuş bu sistem tahmin etme, tepki verme ve harekete geçme noktalarının ötesine gitmektedir.

Akıllı Tedarik Sistemi maliyetleri minimum yapmayı amaçlarken, hizmet kalitesinin, verimliliğin ve etkinliğinin de maksimum olmasını amaçlar. Akıllı tedarik sistemi tasarımı işletmelerin perakende dijital dönüşüm teknolojilerinden tam olarak faydalanabilmesi ile mümkün hale gelmektedir. Bu durum Yapay Zekâ (AI) ve Makine Öğrenmesi (ML) ile yapılacak tahmine dayalı analitik işlemler ve büyük veri ile yapılmaktadır. Yapay Zekâ ve Makine Öğrenmesi tedarik zincirinin ticari anlamda güçlenmesine yardımcı olur. Tedarik zinciri optimize edilir, büyük veriler, müşteri istekleri, işletme eğilimleri bu çözüm içerisinde. Geleneksel tedarik sistemleri manuel operasyon gerektirdiğinden kusurludur. Fakat akıllı tedarik sistemleri dijital olduğundan kusursuz hale gelmiştir. Akıllı Tedarik Sistemlerinde perakende şirketleri artık tedarik sisteminin bağımsız bir zinciri değildir. Akıllı tedarik sistemi ile bütün faaliyet alanları veri ağları ve bağlı ağlar kullanılarak sistem optimize ve entegre edilir. Bu faaliyet alanları, karar vermeyi, verimliliği, maliyet kontrolünü ve tahminleri kapsamaktadır.

Bu çalışmada Türkiye'deki belirli illerde mevcut bulunan Kafe & Restoran bazlı işletmelerin 2015-2016 yılları arasındaki satış yaptıkları ürünlerin satış miktarları üzerine etki eden başta hava durumu olmak üzere farklı parametrelerin etkilerini ölçüp satış miktarının tahmin edilmesi için Makine Öğrenmesi Sınıflandırma algoritmaları ve derin öğrenme sınıflandırma algoritmaları kullanarak satış miktarlarının sınıflandırılmış ve bir akıllı tedarik sistemi tasarlanmıştır.

Bu çalışmanın literatüre katkıları aşağıdaki şekildedir.

- Bu çalışma için elde edilen veri seti ilk defa kullanılmıştır.
- Literatürde Akıllı Tedarik Sistemi üzerine sınırlı çalışmalar vardır bu çalışma sınırlı çalışmalardan farklı olarak Kafe & Restoran bazlı işletmelere akıllı tedarik sistemi ilk kez yapılmıştır.

Tez çalışması sırasında yapılan kaynak araştırmaları aşağıdaki gibidir.

Atieh *et.al* (2016), bir depo yönetim sisteminin tedarik zinciri performansı üzerindeki etkisini araştırmıştır. Veriler, Ürdün'deki önemli bir telekomünikasyon hizmet sağlayıcısının mevcut deposundan toplanmıştır. Depoda gerçekleştirilen tedarik zinciri prosedürleri gözden geçirilerek toplanan veriler ile gerekli işlemleri yapabilecek bir yazılım oluşturulmuş ve bu yazılım ile manuel sistemi karşılaştırmada bu çalışma bir kılavuz olmuştur.

Tejesh & Neeraja (2018), yapılan çalışmada ürünlere ait bilgilerin ayrıntılı bir şekilde tutulduğu, ürünlerin hangi depolarda, hangi miktarlarda bulunduğunu manuel olarak arama yapmanın fazla bir iş yükü olduğunu ve bu sorunu çözmek için bir depo envanter yönetim sistemi tasarlamıştır. Bu sistem ile mevcut depo envanter yönetim sistemi kıyaslanarak geliştirilen yöntemin daha dinamik çalıştığı sonucunu elde etmişlerdir.

Pietro De Giovanni (2021), Tedarik Zincirinde AI sistemi uygulayarak zincirin karar verme sürecine yardımcı olmuştur. Zincirdeki bütün halkalar ile etkileşim içine girerek SC içindeki problemlerin nasıl çözüleceğini öğrenmiştir.

Bager *et. al* (2022), tarımsal gıda tedarik zincirinde artan izlenebilirlik ile sürdürülebilirliğe teşvik etmek için bir Blockchain teknolojisinin ele alarak gerçek dünyadaki potansiyelini değerlendirmiştir.

Boute *et. al* (2021), envanter kontrolü için mevcut en gelişmiş DRL uygulamalarını yükseltebilecek ve envanter araştırmasındaki yapısal politika iç görülerinden yararlanarak ve bunları geliştirerek kapsamalarını genişletebilecek bir çalışma sunmuştur. Envanter kontrolünde uygulamalarını kolaylaştırmak için Derin Takviyeli Öğrenme algoritmalarının temel tasarım seçeneklerini açıklamaktadır. Kullanılan yol haritası operasyonlar içerisindeki farklı alanlara ve gelecekteki araştırmalara yol gösterebilir.

Kourentzes *et. al* (2020), İngiliz hızlı tüketim malları üreticisinden alınan verilerle gerçek bir vaka üzerinde çalışmışlardır. Uygun envanter metriklerini ve mevcut envanter politikasını dikkate alarak tahmin modellerini parametreleştirmeye yönelik bir yaklaşım ele almış ve aşırı stoğu ortadan kaldırırken talebi karşılamak ve optimum stok parametrelerini belirlemek için bir yol önermişlerdir.

Tyagi & Bolia (2022), restoran işletmeleri için gelir yönetiminin literatürünü kapsamlı bir şekilde ele almışlardır. Gelir yönetimi, doğru ürünün doğru zamanda ve miktarda, doğru tüketiciye doğru fiyatta satmaktır. Araştırma sonucunda restoran işletmelerinde gelir yönetiminin önündeki engeller ve sorunlar tespit edilmiştir.

Posch *et. al* (2022), personel kantinlerinde ve restoranlarda verilen menü öğelerinin günlük satış miktarlarını ele almışlar ve bu satış miktarlarının gelecekteki değerini tahmin etmeye çalışmışlardır. Yalnızca satış noktalarından alınan verilere dayanarak basit bir insan yorumuna izin veren bir tahmin yaklaşımı önerdiler ve gelecekteki satışları tahmin etmek için iki farklı genelleştirilmiş yöntem önermişlerdir. Önerilen modellerinin restoran verilerine uygun olduğunu gösterdiler ve yöntemdeki tahmin performans değerlerinin diğer yerleşik tahmin performans değerleri ile karşılaştırmışlardır.

Ntakolia *et. al* (2021), çalışmada tedarik zincirinin etkinliğini artırmayı amaçlamışlardır. Bu etkinliğe bağlı olarak işletmenin performansını artırmak amacıyla envanter sisteminde karşılanamayan sipariş oranını en etkin şekilde tahmin edecek modeller geliştirmişlerdir. Bu çalışmada geri sipariş tahmin problemi ele alınmıştır. Spesifik olarak, geri sipariş tahminlerinin ikili sınıflandırma problemini için çeşitli makine öğrenimi modelleri çalıştırılarak sonuçlar karşılaştırılmıştır.

Van Steenbergen & Mes (2020), makine öğrenmesine dayalı yaklaşım ile DemandForest tarafından yeni bir talep tahmini yöntemi sunmuşlardır. Önerilen yöntem mevcut ve yeni ürün özellikleri ile geçmiş ürün satış verileri birleştirilerek envanter yönetimi yaklaşımını doğrulamıştır.

Viriyasitavat *et. al* (2022), Geleneksel tedarik zinciri sistemleri ürün ve hizmetlerin toplam maliyetlerini düşürürken ve lojistik süreçleri optimize ederken zorluklarla karşılaşmışlardır. Çalışmada akıllı tedarik zincirlerindeki iş süreçlerinin sağlamlığı, uygulanabilirliğini ve ölçeklendirilebilirliğini geliştirme noktasındaki etkinliği gösterilmiştir.

Liu *et. al* (2022), Tarımsal tedarik zincirine dayalı bir çalışma ve tarımsal hassas yönetimdeki sorunları bulacak bir araştırma da yapmıştır. Temellendirilmiş teori yöntemini benimseyen bu makale 24 farklı işletmeci ile görüşme sağlayıp fikirleri karşılaştırmışlardır. Yaptığı bu karşılaştırmalar sonucunda sürekli teorileri geliştirerek tedarik zincirine dayalı bir tarımsal hassas yönetim tanımlama modeli önermişlerdir.

Kara & Dogan (2018), bozulabilir ürünler için bir stok yönetim sistemini ele almışlardır. Bir perakendecinin müşteri talebi ve teslim süresi altında toplam maliyetini minimize etmek

amacıyla envanter yönetiminin performansını değerlendirmişlerdir. Kısa ömürlü (bozulabilir) ürünlerin yüksek talep ile daha iyi sonuçlar gösterdiğini elde etmişlerdir.

Deng & Liu (2021), envanter yönetiminin birden çok faktörünü detaylı bir şekilde ele alan tedarik zinciri ve envanter yönetimi problemini için yeni birçok amaçlı optimizasyon modeline formüle etmişlerdir.

Merrad *et al.* (2020) güvenilir ve verimli bir nesne algılama ile depolardaki stok seviyelerinin tespit edilmesi ve oluşan stok eksikliği sorununun çözümü için bir envanter yönetim sistemi önermiştir.

Priore *et al.* (2019) tedarik zincirindeki stokları yönetmek için makine öğrenmesi algoritmalarını uygulamışlardır. Tümevarımsal bir öğrenme kullanarak dinamik bir çerçeve geliştirmişlerdir.

Demir *et al.* (2022) yapılan çalışmanın amacı Endüstri 4.0'a firmaların hazırlık ve olgunluk seviyelerinin daha iyi belirlenip ölçülebilmesi için, dijital tedarik zincirlerinin sürdürülebilir ve akıllı boyutta olgunluk seviyelerinin eş zamanlı ölçülmesine imkân sağlayan bir model önermişlerdir.

Wu *et al.* (2016) akıllı tedarik sisteminin mevcut durumunun ve sorunlarının keşfedilmesi ve incelenmesi üzerine bir araştırma yapmışlardır.

Lambourdiere *et al.* (2022) çok yönlü tedarik zinciri performanslarının oluşturmak için bu performanslara sahip olması gerektiğini belirtmiş ve dijital bir tedarik zinciri tasarlama sürecinde esneklik, görünürlük ve çeviklik ile birlikte dinamik tedarik zinciri performanslarının önemini anlatan kavramsal bir yapı sunmuşlardır.

Nozari *et al.* (2022) alanında uzman kişilerle görüşmeler sağlayarak “Nesnelerin Yapay Zekâsı” destekli tedarik zinciri sistemlerinin önüne çıkan zorluklar tespit etmişlerdir. Bu zorlukların önemleri ve neden ortaya çıktıkları belirlenmiştir.

KURAMSAL TEMELLER

Satış Miktarı Tahmini

Kafe & Restoran bazlı hizmet sektöründe amaç müşteri isteğine göre ürün tedarik edilip bu üründen kar amacı güderek belirli bir miktarda satış yapılmaktadır. Satış miktarı bütün işletmelerde belirli parametrelere bağlı olarak değişkenlik gösterir. Satış miktarını etkileyen parametreler oldukça önemlidir. İşletmeler kar amacı ile kurulur ve kar elde etmek için çeşitli araştırmalar ve çalışmalar yaparlar. Bu çalışmada için Türkiye geneli belirli illere ait Kafe & Restoranlardan satış verileri tedarik edildi. Bu satış verileri üzerine araştırmalar, çalışmalar ve analizler yapıldı veriler üzerinde düşünüldü.

Olsen & Jose (1982) 'de yiyecek-hizmet sektörü üzerinde çekici bir zaman serisi analizi kullanmışlardır.

Bujisiç, Bogicevic & Parsa (2016) tarafından yapılan çalışmada 17 farklı hava faktörünün restoran menülerine olan talebe etkisini araştırılmıştır. Menüleri hafif, sıcak, orta, soğuk, ağır diye sınıflara ayırmış ve hava faktörünün bu kategorilere olan etkilerini incelenmiştir. Sonuç olarak hava faktörlerinin restorandaki farklı menüler üzerinde farklı etkiler oluşturduğu görülmüştür. Ek olarak hava faktörlerinden bazı menüler çok etkilenmiş fakat bazı menüler üzerinde hava faktörlerinin etkili olmadığı satışlarını etkilemediği tespit edilmiştir.

Ma & Fildes (2021) perakende satış tahmini üzerine çalışmışlar yapmış ve yeni geliştirilen derin evrişimli sinir ağlarına dayalı bir meta-öğrenme çerçevesi sunmuşlardır.

Kafe & Restoran bazlı işletmelerin akıllı tedarik zincirinde geleceğe dönük satış tahminler yapmak en önemli noktadır. Satış tahminlerin tahmin performans değeri ne kadar doğru olursa tedarik zinciri o kadar etkin ve verimli olur.

Bu çalışma için Türkiye geneli 154 farklı işletmenin 2015-2016 yılları arasındaki satış verileri elde edilmiştir. Elde edilen veriler ham veriler olup daha önce herhangi bir çalışmada kullanılmamıştır. Bu veriler ilk kez akıllı bir tedarik sistemi tasarlamak için bu çalışmada geleceğe dönük satış tahminleri yapmak için kullanılmıştır.

Çalışmada kullanılan veri seti 818959 satırdan oluşmaktadır. 1267 tür ürünün satış değerlerini içeren bu veri setinde il ve işletme bazlı satış miktarları detayları ile mevcuttur.

1267 tür ürünlere ait detaylarını içeren bir veri seti araştırma sırasında elde edilmiş fakat bu çalışmanın ilerleyen noktalarında bahsedilen veri setine çalışma sırasında ihtiyaç

duyulmayacağına karar verilmiş ve ürünlerin detaylarını içeren bu veri seti bu çalışmada kullanılmamıştır.

Hava Durumu Parametreleri

Hava durumu sadece yiyecek-içecek tercihlerini değil hayatımızın pek çok noktasında kararlarımızı etkilemektedir. Havanın sıcak veya yağışlı olması yemek tercihlerini değiştirebilir. Hatta sadece tercihlerini değil yemek yiyip yememe konusunda kararlarına bile etki edebilir. Pikniğe gideceğiniz günü planlarken o günün mutlaka hava durumuna bakarız. Bu bize tercihlerimiz noktasında yol gösterir. Aynı durum Kafe & Restoranlardaki satış miktarlarında da geçerlidir. Havanın sıcak olduğu bir günde müşteri grupları daha çok soğuk içecek grupları, dondurma grupları tercih ederken havanın sert ve soğuk olduğu bir günde daha çok çay ve türevleri, sıcak içecekler tercih ederler. Çalışma sırasında hava durumu parametrelerinin Kafe & Restoran satışları üzerine etkilerini inceleyeceğiz.

Bu çalışmada Meteoroloji genel Müdürlüğünden alınan 2014-2019 yıllarına ait Hava Durumu verileri kullanılmıştır.

Hava durumu verilerini detayları aşağıdaki gibidir.

2014-2019 yıllarına ait Saatlik Sıcaklık Değerleri (476688 veri)

2014-2019 yıllarına ait Saatlik Toplam Yağış Miktarı (442931 veri)

2014-2019 yıllarına ait Saatlik Nispi Nem (474380 veri)

2014-2019 yıllarına ait Saatlik Rüzgâr Yönü Ve Hızı (467793 veri)

Hava durumu verileri saat 07:00, saat 11:00 ve saat 16:00 olmak üzere bir gün içerisinde 3 kez ölçülmüş değerlerden oluşmaktadır.

Bu çalışmada Hava Durumu verilerinin gün içerisindeki ölçülen değerlerinin ortalaması alınmış ve ortalama hava durumu değeri kullanılmıştır. Hava durumunun 4 farklı parametresi olan yukarıdaki listede belirtilen parametreler ayrı ayrı veri tablosu halinde tedarik edilmiştir

Ürünler

Müşteri isteğinin kaliteli bir şekilde karşılanması noktasında ürünler çok önemlidir. Müşteri memnuniyetleri satışın ön planda olduğu hizmet sektörlerinde büyük önem taşır. Müşteriye doğru ürünü tam zamanında temin edip siparişinin karşılanması bu çalışmanın temel amacıdır. Buna ek olarak ürünlerin doğru miktarda ve doğru zamanda işletmenin deposunda bulunması gerekmektedir. İşletmelerin hangi üründen hangi tarihlerde ne kadar elinde bulunması gerektiği noktasında akıllı tedarik sistemi baz alınarak bu çalışma sağlanmıştır.

Çalışma için elde edilen veri setinde 1267 tür gıda (yiyecek-içecek) mevcuttur. Her ürün farklı günlerde farklı işletmelerde farklı adetlerde satılmıştır. Bazı ürünlerdeki satış miktarları hava durumu ile alakalı olmayabilir. Hatta bütün Kafe & Restoranların hava durumuna bağlı olmayabileceğini tahmin edebilmeliyiz.

Veri setimizdeki ürünler kendi içerisinde tedarik türüne göre gruplara ayrılmıştır. Elimizdeki veri setinde gruplama yapıldığında bu çalışma için 39 adet ürün grubu elde edilmiştir. Gruplama işlemi esnasında tedarik türü baz alınmış ve gruplama işlemi için 1267 tür ürün tek tek araştırılmış ve hangi gruba girmesi gerektiği belirlenmiştir. Bazı ürünler bu veri setindeki süre zarfında 1 veya 2 adet çok seyrek bazı ürünler ise az satılan ürünlere nazaran çok yüksek adetlerde satışlarını gerçekleştirmiştir.

Bu ürünlere ait detaylarının belirtildiği 53347 adetlik bir veri seti bu çalışma için incelemiş ve akıllı tedarik sistemine etki edecek parametrelerin bilgileri bu veri setinden alınmıştır.

Müşteri

Müşteri her işletmede karın en önemli noktasıdır. İşletmeler kar elde etmek için müşterilerin ihtiyaçlarını en doğru şekilde karşılamalı ve müşteri kaybetmemelidirler. Satış yapan ve dolayısıyla müşteri kitlesinin en yüksek olduğu Kafe & Restoran işletmeleri için bu durum daha fazla önem arz etmektedir. Bu işletmelerin amacı ellerindeki ürünleri planladıkları doğrultuda satışlarını yapmaktır. Bu satışı yaparken hem elinde fazladan ürün kalıp stok maliyetleri artırmamak hem de müşterinin isteğini kesinlikle karşılamak çok önemlidir. Akıllı tedarik sistemleri, sistemdeki bütün halkaların birbirleri ile olan iletişimlerini sıkı tutar ve elde ettikleri veriler ile gelecek satış tahminlerini doğru yaparlar. Bu durumda müşteriye doğru ürünü doğru zamanda ve miktarda satması noktasında işletmelere büyük destek olmaktadır.

Çalışma için elde edilen veri setlerinden biri de müşteri bilgilerini içeren veri tablolarıdır. 154 adet müşteri grubunun oluşturduğu bu veri setinde müşterilere ait detaylı bilgiler yer almaktadır. Veri setindeki her veri ihtiyaç duyulmadığından kullanılmamıştır. Sadece çalışma için uygun görülen parametreler veri setinden alınmıştır.

MATERYAL VE YÖNTEM

Yapay zekâ alanında yapılan çalışmalar giderek artmaktadır. Makine öğrenmesi ve derin öğrenme kavramları genel olarak yapay zekâ olarak adlandırılrsa da bu üç terim birbirlerinden farklıdır. İlerleyen bölümlerde makine öğrenmesi, derin öğrenme Yapay zekâ, hakkında ayrıntılı bilgi verilmiştir.

Yapay Zekâ

Zekâ terimi insanlar için kullanılır. İnsanın düşünme, karar verme, hareket etme, algılama ve etrafındaki olayları analiz edip sonuç çıkararak bir yetenek olarak adlandırılabilir. Bu özelliklerin makineler tarafından yapılmasına ise Yapay Zekâ denir. Başka bir deyiş ile insanların yapabildiği bazı işlemleri makineler tarafından insanlar kadar yetenekli bir şekilde yapılabilmesi olarak belirtilmiştir. (Endüstri 4.0).

John McCarthy yapay zekânın en önemli kurucularından biridir. Yapay Zekâ ile alakalı düzenlemiş olduğu bir konferansın sonrasında konferansa katılım sağlayan kişiler yapay zekânın ileri seviyelere taşınması gerektiğini düşünmüşlerdir (Endüstri 4.0). Yapay zekâ ile alakalı Turing Testini oluşturan Alan Turing bu alanın önemli kurucularından biridir. Oluşturduğu bu testin amacı mantıksal olarak makinelerin düşündüğünü söylemesinin doğru olup olmadığı üstünedir.

Marvin, Allen, Nathaniel Rochester, Minsky, -Claude E. Shannon, Newell, Herbert A. Simon. McCarthy, yapay zekânın icadına yardımcı olan diğer kişiler arasında gösterilmektedirler (Wikipedia 2001).

Yapay zekâ ikiye ayrılır.

- İnsanların yaptıklarını harfiyen yapabilen taklit eden zayıf yapay zekâ
- Yapılan hatalardan öğrenebilen ve bu hatalarla gelişebilen kuvvetli yapay zekâ

Yapay zekânın bu ayrılma noktaları zaman geçtikçe büyük verilerin ortaya çıkmasına sebebiyet vermiştir ve büyük verilerde yerini makine öğrenmesine bırakmıştır. Makine öğrenmesinden geliştikçe yerini derin öğrenmeye bırakmıştır. Bu yüzden derin öğrenme makine öğrenmesinden daha karmaşık hale gelmiş ve makine öğrenmesi de aynı şekilde yapay zekâdan daha karmaşık ve ileri seviyelerdir.

Makine Öğrenmesi

Makineler, insanların işlerini kolaylaştırmak ve iş yaparken kullandıkları süresi azaltmak için yapılmış basit araçlardır. En basit örneği olan kaldıraçlar herhangi bir bilimsel yasa bilinmeden yapılmıştır. Tekerleğin icadı ile birlikte mekanik yasalar bilinse de tekerlekte yine aynı mantıkla insanların işini kolaylaştırmak için geliştirilmiştir. Fakat zaman ilerledikçe bu basit icatlar geliştirilmiş ve zekâ kavramı ile bütünleştirilmiştir. Bu durum da otomatik makinaların keşfedilmesine öncülük etmiştir. Görüldüğü gibi gündelik hayatta kullanılan basit araçlar basit makinelere, daha sonra basit makineler ise akıllı makinelere dönüşmüştür. İnsanlığın bu gelişim ve değişim süreci beraberinde yapay zekânın önemli bir alt dalı olan makine öğrenmesi de hayatımıza getirmiş oldu ve hemen hemen bütün alanlarda kullanılmaya başlanmıştır (Bonaccorso 2017).

Öğrenme kelimesi, dışarıdan gelen uyaranlara göre değişen ya da önceki tecrübelerinin birçoğunu hatırlama olarak tanımlanabilir. Dolayısıyla makine öğrenmesine değişme eğilim gösteren veya geliştiren her yönteme en çok önem veren mühendislik yaklaşımıdır denilebilir (Bonaccorso 2017). Örneğin, insan eliyle geliştirilmiş en muhteşem eserlerden biri olan mekanik bir saat düşünüldüğünde bu saat yapısı gereği mekanik olarak ayarlanır ve herhangi bir değişim durumunda bu muhteşem eser işe yaramaz hale gelmektedir. İnsanlar ve hayvanlar yaşanan değişimleri fark edebilir bu durum sadece onlara özgüdür.

Makine öğrenmesinde amaç, elde edilen verilerle eğitilebilen matematiksel modeller kurmak ve incelemek bu matematiksel modellere mühendislik uygulamaları geliştirmek, geleceğe dönük çıkarımlar yapmak ve bunların sonucu olarak eksiksiz ve doğru kararlar alabilmektir. Diğer bir deyişle elde edilen bilgi ile bir amaca ulaşmak için bir eylem seçen ve seçtiği eylemin sonuçlarını takip edebilen bir yazılımın varlığıdır (Bonaccorso 2017).

Özellikle son yıllarda Makine öğrenmesi yapay zekânın dalları içerisinde en önemli noktaya gelmiştir. Makine öğrenmesi her farklı iş alanlarında uygulamalar geliştirerek kendisini göstermesi örnek verilebilir (Bonaccorso 2017).

Makine öğrenmesinin kullanıldığı uygulama alanlarında bazıları aşağıda verilmiştir. (Wikipedia 2001).

- Bilgisayarlı Görme
- Makine Algılaması
- Doğal Dil İşleme
- Bilgisayarlı Görmede Nesne Tanıma
- Kredi Kartı Dolandırıcılığı Denetimi

- Uyarlamalı Web Siteleri
- DNA Dizilerinin Sınıflandırılması
- Arama Motorları
- Borsa Çözümlemesi
- Sözdizimsel Örüntü Tanıma
- Tıbbi Tanı
- Oyun Oynama
- Robot Gezisi
- Beyin-Makine Ara yüzleri ve Kiminformatik
- Biyoinformatik
- Yazılım Mühendisliği
- Konuşma ve Elyazısı Tanıma

Arthur Samuel bir bilgisayar bilimcisidir. Arthur Samuel 1959 ‘da makine öğrenmesinde en temel noktanın “bilgisayarın açıkça programlanmadan öğrenme yeteneği” olduğunu belirtmiştir. Bilgisayarlar bu öğrenme yöntemini girdi verilerini eden algoritmalar ile çıktı sonuçlarını sınıflandırır ve tahmin yapar (Prowmes).

Makine öğrenme algoritmaları çalışmalardan çıkan sonuçları hedef parametrelere değerlerine göre birçok sınıfa ayırmaktadır (Batı 2020).

Giriş verileri ve çıkış verileri bilinen makine öğrenmesi algoritmaları denetimli/gözetimli öğrenme, sadece başlangıç verileri ve belirli bir sonuca ulaşmaya çalışan makine öğrenmesi algoritmaları denetimsiz/gözetimsiz öğrenme, bu algoritmaların yanında birbirine bağımlı ve peş peşe meydana gelen olayların çıktılarını bulmaya çalışan makine öğrenmesi algoritmalarına ise takviyeli/pekiştirmeli öğrenme algoritmaları denir ve makine öğrenmesi algoritmaları bu şekilde 3’ e ayrılır (Batı 2020).

Denetimli/Gözetimli Makine Öğrenmesi Algoritmaları

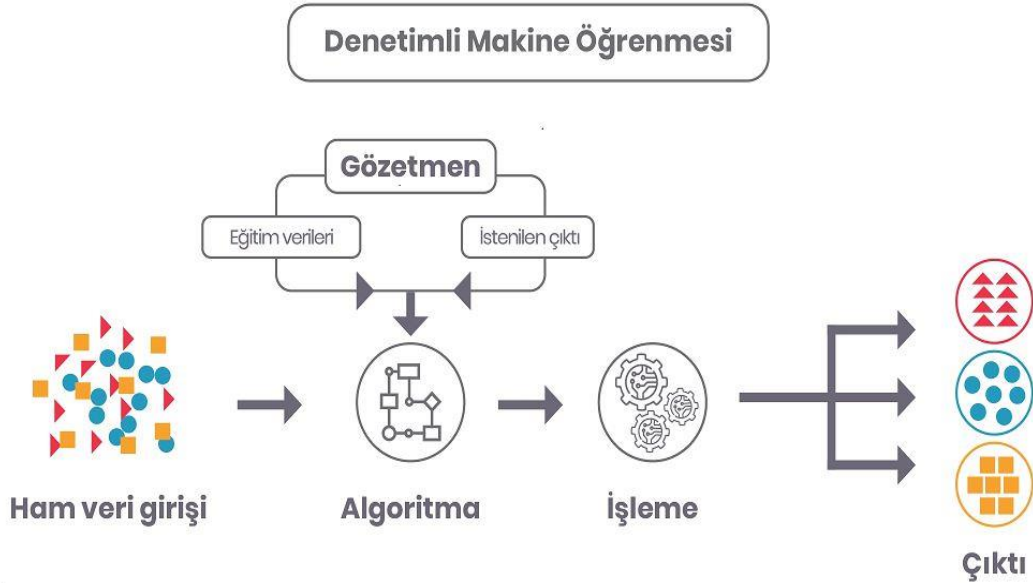
Bu makine öğrenmesi algoritmalarında denetlenen bir senaryo mevcuttur. Yani algoritmalarda girdi verileri ile çıktı verileri birlikte bulunurken programlanmış algoritmalar tarafından makinenin eğitilme söz konusudur (Bonaccorso 2017). Makinenin eğitilmesi için kullanılan girdi ve çıktılarının bilindiği bir veri seti üzerinden eğitim yapılır. Girdi ve çıktı verileri arasında bir bağlantı kurmak ve bu bağlantılardan sonuçlar elde etmek amacıyla bazı fonksiyonlar kullanılır. Bu fonksiyon denklem 1’de gösterildiği gibi girdi değişkeni olarak x , çıktı değişkeni olarak y şeklinde ifade edilebilir.

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

Regresyon ve sınıflandırma algoritmaları fonksiyonları belirlemek için kullanılır. Regresyon algoritmalarının kullanılması için çıktı(bağımlı değişken) verilerinin sürekli değerler alması yani sayısal değerler olması gerekmektedir. Kategorik veriler olduğunda regresyon modeline o şekilde giremez kategorik veriler sayısallaştırılarak modele girmesi sağlanır. Sınıflandırma algoritmalarının çıktı verilerinde ise belirli sayıda olası sonucunun olması yani verilerin kategorik bir alana girmesi gerekmektedir. (Bonaccorso 2017). Bazı algoritmalar ise sınıflandırmada da regresyonda da kullanılmaktadır (Elektrikport).

Regresyon ve sınıflandırma algoritmalarının kullanıldığı denetimli öğrenme uygulamalarının en yaygın olanları aşağıda verilmiştir (Bonaccorso 2017):

- Duygu analizi
- Doğal dil işleme
- Örüntü algılama
- Spam (istenmeyen posta) algılama
- Otomatik sıra işleme (müzik, konuşma vb.)
- Otomatik görüntü sınıflandırma



Şekil 1. Denetimli/gözetimli öğrenme

A. Sınıflandırma algoritmaları

Örüntü tanımda ve veri analitiğinde sınıflandırma gereklidir. Ön bilgilerden aktarılan verileri kategorize ettiği için sınıflandırma bir denetimli öğrenme tekniğidir. Sınıflandırma işlemi yapılacak olan veri seti eğitim veri seti ve test veri seti olmak üzere ikiye ayrılır. Test veri setinin analizinin yapılabilmesi için eğitim veri setindeki her sınıf değeri için ortak olan özellikler çıkarılır. Bu veri setinin test ve eğitim seti olarak ayrılmasından sonrasında sınıflandırma iki aşamadan oluşur.

İlk aşama eğitim veri setlerine uygulanır ve bir sınıflandırma modeli çıkarılır. İkinci aşamada ise çıkarılan sınıflandırma modeli etiketli bir test veri setinde doğrulanır (Singh *et al.* 2016).

Sınıflandırma algoritmaları içerisinde en yaygın kullanılanlar aşağıdaki gibidir:

- Lojistik Regresyon (Logistic Regression/LR)
- Karar Ağaçları (Decision Trees/DT)
- Rasgele Orman (Random Forest /RF)
- Gradyan Artırma (Gradient Boosting/GB)
- K-En Yakın Komşu (K-Nearest Neighbor/KNN)
- Sinir Ağları (Neural Networks/NN)
- Destek Vektör Makinası (Support Vector Machine/SVM)
- Naif Bayes (Naive Bayes/NB)
- Diskriminant Analizi (Discriminant Analysis/DA)

B. Regresyon algoritmaları

Regresyon algoritmalarının iki kullanım amacı vardır. İlki tahminler yapmaktır, ikincisi ise gerek duyulan bazı alanlarda bağımlı değişken ve bağımsız değişkenler arasındaki ilişkileri belirlemek için kullanılır. En önemlisi ise regresyon algoritmaları yalnızca tek bir bağımlı değişken ile farklı bağımsız değişkenlerden oluşan bir veri setindeki bağımsız değişkenlerin bağımlı değişken ile aralarındaki ilişkiyi gösterir (Maulud and Abdulazeez 2020).

Yaygın kullanılan regresyon algoritmaları aşağıdaki gibidir (Elektrikport, Maulud and Abdulazeez, 2020):

- Basit Doğrusal Regresyon (Simple Linear Regression/SLR)
- Çok Değişkenli Doğrusal Regresyon (Multivariate Linear Regression/MLR)
- Polinom Regresyon (Polynomial Regression/PR)

- Karar Ağaçları (Decision Trees/DT)
- K-En Yakın Komşu (K-Nearest Neighbor/KNN)
- Destek Vektör Makinası (Support Vector Machine/SVM)

Yukarıda belirtildiği gibi,

- Karar Ağaçları (Decision Trees/DT)
- K-En Yakın Komşu (K-Nearest Neighbor/KNN)
- Destek Vektör Makinası (Support Vector Machine/SVM)

Bu 3 algoritma hem sınıflandırma hem de regresyon analizlerinde kullanılır.

Denetimsiz/Gözetimsiz Makine Öğrenmesi Algoritmaları

Bu yaklaşım, modeli denetlemeye gerek duymadığından mutlak hata ölçütlerine dayanır. Modelin bilgileri keşfetmesi için bir denetleme ihtiyaç duymadığı bu algoritmalar için modelin tek başına çalışmasına izin verilmesi gerekir. Denetimsiz öğrenme algoritmaları ile daha karmaşık görevler yapılabilir. Bir dizi verinin benzer noktalarına ve uzaklık ölçütlerine göre nasıl toplanacağını (kümeleneceğini) öğrenmek için kullanılır (Bonaccorso 2017). Diğer bir deyişle denetimli öğrenme algoritmalarında verilerin etiketlenmesi söz konusudur. Fakat denetimsiz öğrenmede veri etiketleri yoktur ve algoritmalar kendi etiketlerini bulabilir ve kendi kendine öğrenebilirler. Kümeleme ve ilişkilendirme olmak üzere denetimsiz makine öğrenme algoritmaları ikiye ayrılır(Türkmen, 2021).

Denetimsiz öğrenme algoritmalarının kullanıldığı yaygın alanlar aşağıdaki gibidir. (Bonaccorso 2017):

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

A. Kümeleme

Basitçe veri setindeki elemanları gruplamaya çalışır ve bu gruplama işlemini sınıf etiketlerini bilmeden gerçekleştirerek sınıfları tanımlamakla uğraşır. Kümeleme algoritmalarının amacı, diğer kümelerden daha çok birbirine benzeyen nesne gruplarını veya kümeleri belirlemektir. Yani mevcut veri kümesinin belirli yönleri üzerinde basit özellikler kümesi oluşturmak ister. Genellikle kümeleme yöntemleri denetimli makine öğrenmesi algoritmalarından çok daha fazla özelliğe ihtiyaç duyar (Rodriguez at al 2019).

B. İlişkilendirme Kuralı

İlişkilendirme tabanlı makine öğrenmesi algoritmasında veriler etiketsiz geldiğinden bu algoritma verilerin çoğunu açıklar ve veriler için kurallar geliştirir. Mesela bir veri setinde satın alma yapan insanların olduğunu veya başka insanların da bu satın alma işlemi içinde olup olmadığını belirlemek için kullanılır. Yani bir ürünü satın alan kişiler başka bir ürünü de satın almak için eğilimlidir denebilir (Akoğlu 2018).

Takviyeli/Pekiştirmeli Öğrenme

Takviyeli öğrenme algoritmaları sayısal bir ödül-ceza yöntemini kullanarak öğrenmeye çalışır. Amaç ödül sinyalini maksimum noktaya çıkarmaktır. Diğer bir ifade ile bu algoritma durumları eylemlerle nasıl eşleştireceğinizi açıklayan bir makine öğrenmesi alanıdır. Takviyeli öğrenme algoritmaları, denetimli öğrenme algoritmalarından farklı olarak makine öğrenimi alanındaki en yeni konularla incelenir. Denetimli öğrenmede bir eğitim veri seti mevcuttur ve bu veri seti içerisinde etiketler denetimci tarafından sağlanmıştır. Öğrenme bu etiketleri denetimci tarafından sağlanan eğitim veri setinde gerçekleştirilir. Her bir veride sistem etiketlenmiş olana gider. Özetle veriler kategorik hale getirilmiştir. Denetimsiz öğrenmesi ise etiketleri belli olmayan veri setlerinde gizlenmiş yapıyı bulmakla ilgilenir. Takviyeli öğrenme algoritmaları her iki öğrenmeden de farklı çalışır (Sutton and Barto 2018). Örneğin bir satranç oyununa bakacak olursak oyundaki her hamle bir girdidir ve her hamle kendinden bir önceki ve bir sonraki hamleler ile bağımlıdır. Oyun bittiğinde oyunun kazanıp kaybetme durumu ise çıktı verilerini oluşturmaktadır. Takviyeli öğrenme algoritmalarında girdi ve çıktı değişkenleri birbirlerine bağımlıdır ve bu yönüyle denetimli ve denetimsiz makine öğrenmesi algoritmalarından ayrılır.

Bu çalışma için elde edilen verilerin sınıflandırma işlemleri denetimli makine öğrenmesi algoritmalarıyla yapılmıştır. Denetimli makine öğrenmesi algoritmaları bir sonraki bölümde daha ayrıntılı bir şekilde anlatılacaktır.

Çalışmada Kullanılan Denetimli/Gözetimli Makine Öğrenme Algoritmaları

Bu çalışmada denetimli/ gözetimli makine öğrenmesi algoritmaları içerisinde rasgele orman, karar ağaçları, gradyan artırma, K-NN ve destek vektör makinası (SVM) sınıflandırma algoritmaları kullanılmıştır.

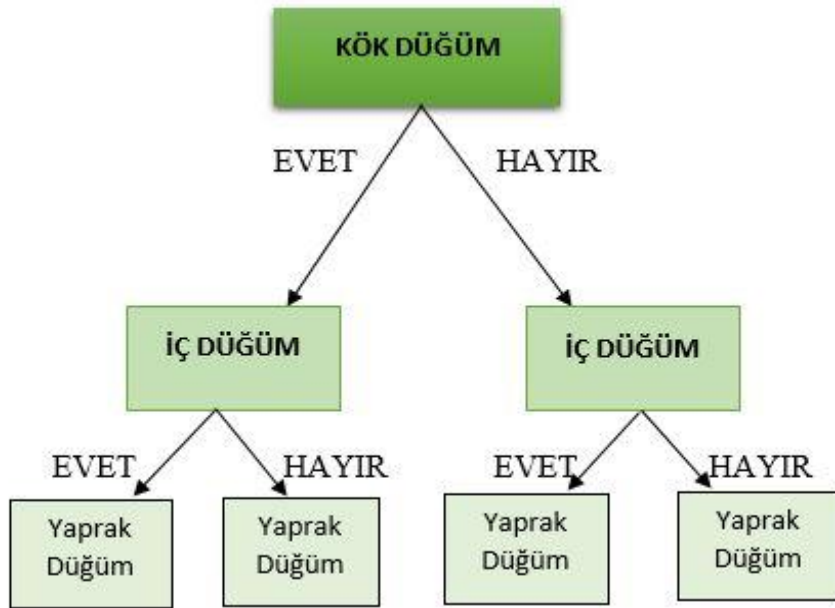
Karar ağaçları

Sınıflandırma ve regresyon modellerinin her ikisinde de kullanılır. Denetimli öğrenme algoritmasıdır. Sınıflandırma yapılacak veri seti hem sınıfsal hem de sayısal olarak belirtilebildiğinden bu sınıflandırma yöntemi çok sık kullanılmaktadır.

Karar Ağaçları, verileri nitelik değerlerine göre sıralayarak sınıflandıran algoritmadır. Karar ağaçları önceden tanımlanmış bir sınıf değişkenine sahiptir.

Karar ağacındaki her düğüm bir özelliği temsil eder. Ağaçtaki dallar ise düğümün yapabileceği değerleri gösterir. Veriler sınıflandırmaya kök düğümden başlar ve nitelik değerlerine göre sıralanır. (Osisanwo *et al.* 2017).

Şekilde karar ağaçlarının genel yapısı basitçe gösterilmiştir (Türkmen 2021).



Şekil 2. Karar ağaçlarının genel yapısı

Destek vektör makinaları


Regresyon ve sınıflandırma modellerinin her ikisinde de kullanılan bir diğer algoritma destek vektör makinalarıdır. Genel olarak destek vektör makinaları istatistiksel öğrenme ve yapısal risk minimizasyonu prensiplerine dayanır. Destek vektör makinaları sınıfların optimal ayrılmasını sağlayan hiper düzlem olarak da ifade edilen karar sınırlarının yerini belirleme amacıyla çalışan denetimli makine öğrenmesi algoritması olarak bilinir (Bhavsar and Ganatra 2012).

Destek vektör makinaları algoritması iki veri sınıfını birbirinden ayıran bir hiper düzlem vardır. Bu düzlemin her iki tarafı da “marj” adı verilen kavramın etrafında döner (Osisanwo *et al.* 2017).

Doğrusal (Lineer) destek vektör makinaları veri setinin (iki sınıflı) lineer olarak ayrıldığı durumlar için kullanılır.

Veri setinin (iki sınıflı) doğrusal olarak ayrıldığı durumlar için doğrusal (lineer) destek vektör makinaları kullanılır. SVM' ler sesten etkilenen algoritmalarıdır. Gürültü ne kadar yüksek olursa veriler birbirine o kadar çok çakışır ve algoritma gruplar arası sınırı çizirken zorlanacağından model başarı oranı düşer

Aşağıdaki şekilde destek vektör makinasının genel çalışma biçimi gösterilmiştir (Türkmen 2021).




Şekil 3. Destek vektör makinaları genel yapısı

K-En yakın komşu

Regresyon ve sınıflandırma da kullanılan denetimli makine öğrenmesi algoritmalarının en basitlerinden biridir. Birbirine benzeyen verilerin birbirine yakın olduğu prensibine dayanır. Etiketlenmiş bir veri sınıflandırıcıya verildiğinde kendisine en yakın k-nesneleri için desen uzayında arama yapar ve en sık görülen etiketi belirleyerek sınıfa atar (Bhavsar and Ganatra 2012). K-en yakın komşu algoritmaları, bir model oluşturmak için benzerlik ölçüsü kullanır. Eğitim verilerinden k-en yakın komşu açıkça bir model oluşturamaz, bunun yerine test veri setinde benzerlik ölçüsü kullanarak en yakın komşuları hesaplar (Burkart and Huber 2021).

Şekilde bu algoritmanın genel görünümü verilmiştir (Türkmen 2021).



Şekil 4. K-en yakın komşu algoritmasının çalışma biçimi

Rasgele orman modeli

Rastgele orman modeli rastgele eğitilmiş karar ağaçları topluluğundan oluşur. Rastgele orman modelinin en önemli kavramı, rastgele eğitilen her kararın diğer karardan rastgele farklı olma durumudur. Rastgele karar ağaçlarındaki rasgelelik parametresinin aksine rastgele orman modelinde rasgelelik parametresi sadece her ağacın rasgeleliğine değil aynı zamanda orman modelindeki her ağacın korelasyonlarını kontrol eder (Holmberg and Hallden 2018).

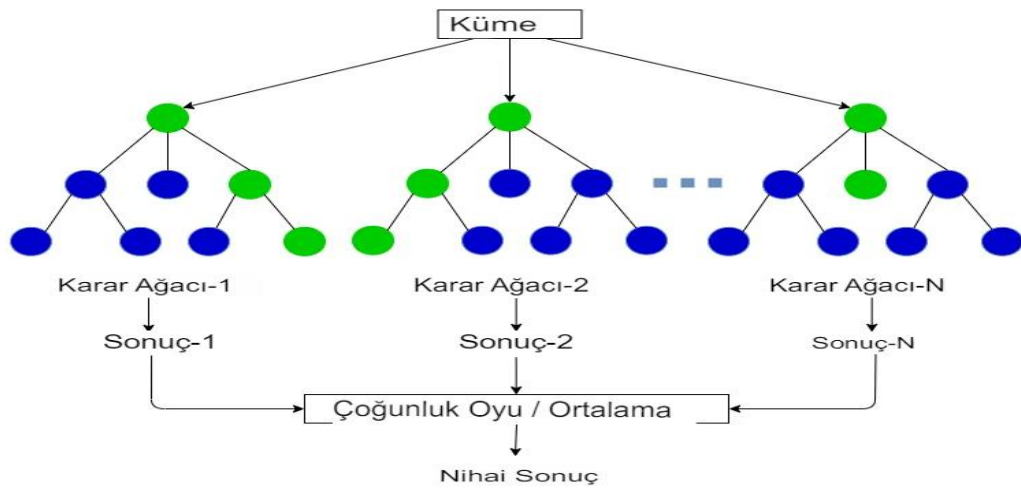
Rastgele orman algoritması, hem girdi değişkenlerinin çok fazla olduğu büyük veri setlerinde hem de eksik verilerde iyi performans göstererek yüksek tahminler yapması bakımından çok büyük kolaylıklar sağlamaktadır (Başer *et al.* 2021).

Tüm ağaçlar rastgele orman modelinde ayrı ayrı eğitilir ve test aşamasına geldiğinde her test verisi, tüm test verisi ağaçların içinden geçerek yapraklara ulaşır. Tüm farklı ağaç tahminlerini modelde tek bir tahminde birleştirmek için ortalama alma işlemi uygulanır (Holmberg and Hallden 2018).

Rastgele orman modelindeki en önemli parametreler aşağıdaki gibidir.

- Kullanılan Özelliklerin Seçimi
- Ormanın Büyüklüğü
- İzin Verilen Maksimum Orman Derinliği
- Bölünmüş Dğümlerin Ne Tür Zayıf Öğrenen/Test İşlevi
- Eğitim Hedefi İşlevi

Aşağıdaki şekilde rastgele orman algoritmasının genel yapısı belirtilmiştir(Türkmen 2021).



Şekil 5. Rastgele orman algoritması

Gradyan artırma modeli

Sınıflandırma ve regresyon problemlerinde kullanılan bir makine öğrenmesi algoritmasıdır. Bu algoritma zayıf tahmin modellerini bir araya gelmesini sağlar ve karar ağaçlarından oluşan bir model geliştirir(Türkmen 2021). Modeller temel öğrenici kullanılarak veya zayıf öğrenici kullanılarak eğitilir. Bu modeller rastgele bir tahminden daha yüksek bir performans gösterme eğilimindedir. Fakat daha iyi bir performans göstermesi için dikkatli bir şekilde seçilmesi gerekir. Seçilen model için güçlendirme algoritması kullanılıp bir araya getirildiğinde model daha doğru bir model oluşturulmuş olur (Sobolewski *et al.* 2023).

Sınıflandırma Algoritmaları Performans Ölçütleri

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

Karmaşıklık matrisi (confusion matrix)

Karmaşıklık matrisi, önerilen sınıflandırma algoritmalarının gerçek değerlerini ve tahmin edilen değerlerini karşılaştıran performans ölçüm aracıdır. Sınıflandırma işlemi sonucunda algoritmaları test etmek için kullanılan bu matris, girilen verilerin kaç adetinin doğru tahmin edildiğini ve kaç adet yanlış tahmin edildiğini performans ölçümü için kullanılır. Örneğin; makine öğrenmesine girecek test veri setindeki veriler pozitif(doğru) ya da negatif(yanlış) olmak üzere iki sınıftan oluşur. Veriler bu sınıflardan birine girmesi gerekirken sınıflandırmanın ikili olarak yapıldığını düşünürsek karmaşıklık matrisi,

- Doğru Pozitif/DP(True Positive)
- Doğru Negatif/DN(True Negative)
- Yanlış Pozitif/YP(False Positive)
- Yanlış Negative/YN(False Negative)

Yukarıda belirtildiği gibi dört alana bölünür (Güneş, 2020).

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	Doğru Pozitif	Yanlış Negatif
	Negatif	Yanlış Pozitif	Doğru Negatif


$$Kesinlik = \frac{DP}{DP+YP}$$
$$Hassasiyet = \frac{DP}{DP+YN}$$
$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN}$$
$$F1-Skoru = 2 \times \frac{Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet}$$

Şekil 6. İkili sınıflandırma için karmaşıklık matrisi ve performans metrikleri

Yapay Sinir Ağı (ANN)

Yapay sinir ağları, insanların biyolojik sinir ağlarından esinlenerek geliştirilmiş modellerdir. Bu modellerde, biyolojik sinir ağlarında bulunan düğümler gibi birbirine bağlı ve birbirleriyle iletişim halindeki düğümler kullanılmaktadır. Bu düğümler iletişim kurmak için birbirlerine sinyaller gönderirler. Gönderilen sinyaller giriş katmanından başlayıp son çıkış katmanına doğru taşınır. Tasarlanan yapay sinir ağlarında, katmanların özellikleri ve katman

sayısı özelleştirilebilir. Katmanların kaç düğümden oluşacağı, olasılık ağırlıkları ve hangi fonksiyonlarla çözüleceği gibi nitelikler belirlenebilir (Türkmen 2021). Aşağıdaki şekil yapay sinir ağlarının genel yapısını gösterir (Bilimfili, 2015).

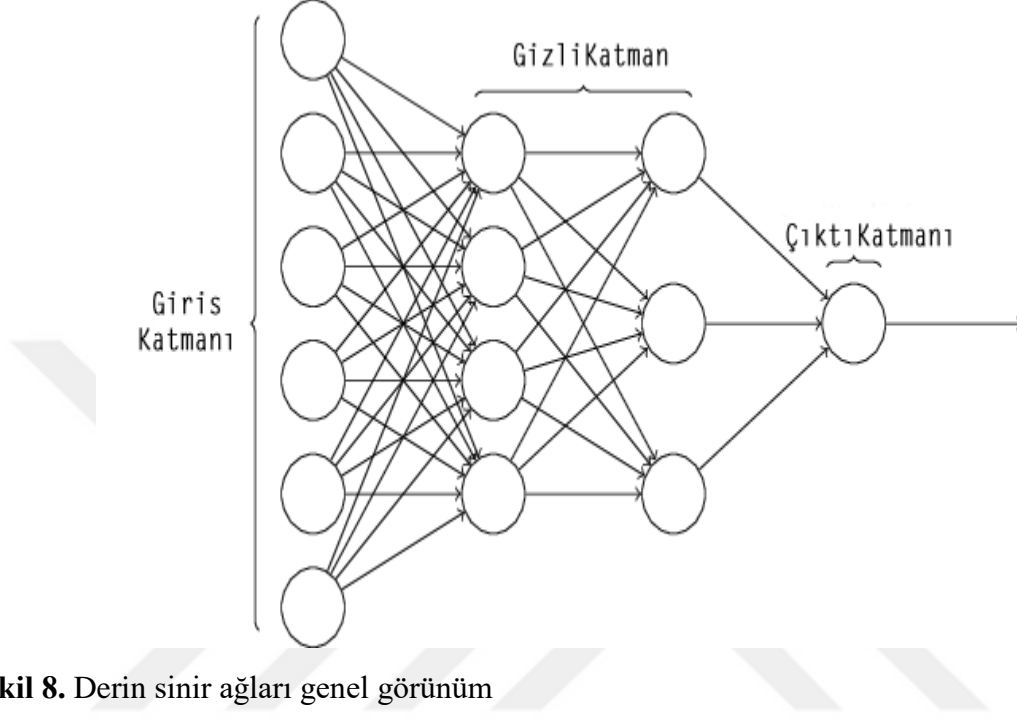


Şekil 7. Yapay sinir ağları genel yapısı

Derin öğrenme

Yapay sinir ağlarının daha çok katmandan oluşmuş haline derin öğrenme denir ve makine öğrenmesinin bir alt dalı olarak bilinir. Daha detaylı tanımlarsak; güçlü bir makine öğrenmesi algoritması olarak bilinir ve bilgisayarların konuşma ve görüntü tanıma gibi algısal sorunlarının çözülmesini sağlar. Yapay sinir ağları giriş katmanı (input layer), çıkış katmanı (ouput layer) ve bir adet gizli katmandan (hidden layer) oluşur. Yapay sinir ağlarının genel yapısını bu şekilde ifade edebiliriz (Medium). Özetle yapay sinir ağlarına taklit edilen insan beyni denilebilir (Bilimfili, 2015). Derin öğrenme mimarilerinde yapay sinir ağları, giriş ve çıkış katmanlarının arasında birden çok gizli katman mevcuttur. Derin yapay sinir ağlarında birden çok işleme katmanı bulunur ve bu katmanlar çok büyük veri setlerindeki kalıpları ve yapıyı keşfetmek için kullanılır. Her bir katman, kendisinden sonraki katmanların üzerine kurduğu verilerden bir kavram öğrenir; öğrenilen kavram seviye ne kadar yüksek ise o kadar soyut olur. Derin öğrenme, özellikleri otomatik olarak çıkarır ve önceki veri işlemeye bağlı olma durumu yoktur.

Derin öğrenme algoritmasını oluşturmak için kaç katman gerektiği konusunda kesin ve hızlı bir kural bulunmamaktadır. Fakat çoğu bu alanda uzman kişiler derin öğrenmeyi oluşturmak için ikiden fazla katman gerektiği konusunda hem fikirdir (Shrestha and Mahmood 2019). Derin sinir ağına (deep learning neural network) ait görsel verilmiştir (Medium).



Şekil 8. Derin sinir ağları genel görünüm

Derin öğrenme içerisinde bulunan mimariler aşağıdaki gibidir(Şeker vd. 2017, Ser ve Bati 2019):

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

Yapay sinir ağının yapısını ve sinir ağının nasıl eğitildiğini açıklayan parametrelere hiperparametre denir (Devhunter, 2018).

Sinir ağlarının yapısı ile alakalı olan Hiperparametre değerleri aşağıdaki gibidir (Medium, Kurt 2018):

- Veri setinin boyutu
- Öğrenme hızı
- Katman sayısı ve gizli katmandaki nöron sayısı
- Momentum katsayısı
- Eğitim/döngü tur (epoch) sayısı
- Başlangıç ağırlıkları belirleme
- Aktivasyon fonksiyonu
- Kernel boyut
- Havuzlama boyutu
- Seyreltme (dropout) değeri

Çalışmada Kullanılan Derin Öğrenme Yöntemleri

Bu çalışma içerisinde, derin sinir ağırları kullanılarak bir sınıflandırma çalışması yapılmıştır.

ARAŞTIRMA BULGULARI

Bu bölümde yapılan çalışmadaki problem, çalışmanın amacı, çalışmanın kapsamı, kullanılan veri setleri, çalışmada kullanılan Makine öğrenmesi ve derin öğrenme algoritmaları bunların detayları hakkında bilgiler verilmiştir.

Veri Seti

Çalışmada kullanılan hava durumu verileri meteoroloji genel müdürlüğünden elde edilmiştir.

Veri setleri aşağıdaki gibidir.

- Ürün
- Müşteri
- Satış
- Hava Durumu (Sıcaklık)
- Hava Durumu (Nispi Nem)
- Hava Durumu (Toplam Yağış)
- Hava Durumu (Rüzgâr Hızı)

1. Ürün

Türkiye’ de bazı şehirlerde farklı Kafe & Restoranlarda satışı gerçekleştirilen yiyecek- içeceklere ait detayları içeren veri setidir. Ürün ismi, ürünün satış fiyatı, kalorisi, pişirme zamanı, satış yapılan şehir, şube sayısı, ürüne ait detaylı bilgi vs. bilgilerinin içerir. Ürünlere ait veri setinden alınan bir örnek aşağıdaki gibidir.

ProductID	CustomerID	Name	Code	Price	Tax	Tax2	CookingTime	Calorie	Index	Description	LingoName	LingoDescription
0	10138	Göğün Orbası	10138	6.00	8.00	8.00	10.0	386.0	NaN	NaN	{TR:"Göğün Orbası"}	{TR:""}
1	10139	Börek	10139	16.00	8.00	8.00	10.0	421.0	NaN	NaN	{TR:"Börek"}	{TR:""}
2	10140	Etili Ekmek	10140	17.00	8.00	8.00	10.0	513.0	NaN	Konya yöresinde yapılan, kıyma şeklindeki dana...	{TR:"Etili Ekmek"}	{TR:"Konya yöresinde yapılan, kıyma şeklinde..."}
3	10141	Mevlana	10141	17.00	8.00	8.00	10.0	573.0	NaN	Peynir, kusbasi et, yeşil biber, maydanöz özel...	{TR:"Mevlana"}	{TR:"Peynir, kusbasi et, yeşil biber, maydanöz..."}
4	10142	Bıçak Arası	10142	19.00	8.00	8.00	10.0	520.0	NaN	Bıçak arası döve etinin bifteklik kısmından, l...	{TR:"Bıçak Arası"}	{TR:"Bıçak arası döve etinin bifteklik kısmından..."}
5	10143	Kuzu Tandir	10143	24.00	8.00	8.00	10.0	560.0	NaN	Yere kazılarak yapılan tandirlerin içine kuzu ...	{TR:"Kuzu Tandir"}	{TR:"Yere kazılarak yapılan tandirlerin içine..."}
6	10144	Izgara Köfte	10144	19.00	8.00	8.00	10.0	200.0	NaN	NaN	{TR:"Izgara Köfte"}	{TR:""}
7	10145	Tavuk Izgara	10145	15.00	8.00	8.00	10.0	426.0	NaN	NaN	{TR:"Tavuk Izgara"}	{TR:""}
8	10146	Kuzu Sis	10146	30.00	8.00	8.00	10.0	531.0	NaN	Baharatlı sirkenin içinde bekletilerek koyun e...	{TR:"Kuzu Sis"}	{TR:"Baharatlı sirkenin içinde bekletilerek ..."

Şekil 10. Ürün veri setinden alınan 8 örnek

2. Müşteri

Türkiye geneli rasgele illerden alınan 154 işletme ve bilgilerini içeren veri setidir. Veri setinde müşteri gruplarına ait sektör, adres, şehir, başlama tarihi vs. detaylı bilgilerini içerir. Aşağıdaki şekilde veri setinden örnek verilmiştir.

Customer Reseller/ParentID	SectorID	Title	Code	Sector	RegisterTime	Address	City/Town	District	Country	Lat/Lng	Language	WorkDays	WorkHou	Type	Status	ViewInde	Rank	Branches		
1	1	NULL	235	Unvan	1	RESTAUR	21.11.2017 09:32	Kocaeli Ü	Kocaeli	Bağsöle	Türkiye	40.703522;29.884414	TR	Pazartesi	10:00-21:0	0	2	30	1000	1
10049	1	NULL	NULL	Unvan	10049	Restaurai	21.04.2014 07:40	Karaköprü	Kocaeli	Gölcük	Türkiye	40.705750;29.859792	TR	Pazartesi	09:00-21:0	0	2	26	1000	1
10060	34	NULL	237	Unvan	10060	CAFE & RE	22.07.2014 17:09	Mürsel U	Ankara	Çankaya	Türkiye	39.919916;32.855100	TR	Pazartesi	10:00-22:0	0	2	81	1000	1
10062	1	NULL	NULL	Unvan	10062	Otel & Ko	27.08.2014 07:01	Kozluk M	Kocaeli	İzmit	Türkiye	40.761082;29.881023	TR	NULL	NULL	0	2	36	1000	1
10065	82	NULL	412	Unvan	10065	RESTAUR	5.09.2014 12:49	Merkez M	Kocaeli	Gölcük	Türkiye	40.718864;29.822854	TR	Pazartesi	09:00-21:0	0	2	17	1000	1
10066	34	NULL	412	Unvan	10066	RESTAUR	20.09.2014 09:26	Şenlikköy	İstanbul	Bakırköy	Türkiye	40.981017;28.799216	TR	Açılış Gün-		0	2	113	1000	1
10080	34	NULL	414	Unvan	10080	CAFE & RE	23.02.2015 09:10	Meclis m	İstanbul	Sancaktepe	Türkiye	41.013419;29.192630	TR	Açılış Gün	09:00-18:0	0	2	4	1000	1
10082	1	NULL	414	Unvan	10082	CAFE & RE	6.03.2015 11:23	Kütayha İ	Kütayha		Türkiye	39.419955;29.985732	TR	Açılış Gün-		0	2	34	1000	1
10085	1	10415	238	Unvan	10085	PASTAHAN	6.04.2015 12:06	M. Ali Paş	Kocaeli	İzmit	Türkiye	40.772275;29.955959	TR	Pazartesi	07:00-21:0	1	2	8	1000	1
10086	34	NULL	NULL	Unvan	10086	Restaurai	17.04.2015 13:21	Caferağa	İstanbul	Kadıköy	Türkiye	40.988893;29.024755	TR	NULL	NULL	0	2	37	1000	1
10091	1	NULL	414	Unvan	10091	CAFE & RE	28.05.2015 09:22	22.Ada Şi	Kocaeli	Gölcük	Türkiye	40.702026;29.806694	TR	Açılış Gün-		0	2	33	1000	1
10092	1	10415	238	Unvan	10092	PASTAHAN	3.06.2015 22:33	Yeşilova	Kocaeli	İzmit	Türkiye	40.786577;29.971218	TR	Açılış Gün-		1	2	9	1000	1
10096	1	10415	238	Unvan	10096	PASTAHAN	2015-07-16 10:31:54.077	Köseköy	Kocaeli	İzmit	Türkiye	40.740446;29.976623	TR	Açılış Gün-		1	2	7	1000	1
10097	1	NULL	412	Unvan	10097	RESTAUR	20.07.2015 10:09	Uncubozuk	Manisa	Yunusem	Türkiye	38.609955;27.385374	TR	Açılış Gün-		0	2	11	NULL	1
10103	34	NULL	NULL	Unvan	10103	Restaurai	30.08.2015 19:12	Caferağa	İstanbul	Kadıköy	Türkiye	40.989445;29.028400	TR	Pazartesi	09:00-02:0	0	2	165	1000	1
10104	1	NULL	NULL	Unvan	10104	Restaurai	8.09.2015 07:56	Kurtuluş 1	Uşak		Türkiye	38.674229;29.405882	TR	NULL	NULL	0	2	14	1000	1
10105	1	NULL	NULL	Unvan	10105	Kahve Dü	6.10.2015 11:01	İnönü ca	Artvin		Türkiye	41.180525;41.820206	TR	NULL	NULL	0	2	24	1000	1
10107	34	NULL	NULL	Unvan	10107	Restaurai	10.11.2015 06:58	Kadıköy	İstanbul	Kadıköy	Türkiye	40.989917;29.065503	TR	Pazartesi	09:00-02:0	0	2	89	1000	1
10109	1	NULL	NULL	Unvan	10109	Restaurai	16.11.2015 12:18	Salamah	Jedda		Suudi Ara	21.294527;39.223124	TR	NULL	NULL	0	2	25	1000	1
10114	1	NULL	NULL	Unvan	10114	Restaurai	28.12.2015 08:29	Kardelen	Ankara	Yenimahşi	Türkiye	39.928342;32.866086	TR	NULL	NULL	0	2	3	1000	1
10116	1	NULL	NULL	Unvan	10116	Restaurai	31.12.2015 10:56	Kentkoop	Ankara	Yenimahşi	Türkiye	39.936766;32.855100	TR	NULL	NULL	0	2	16	1000	1
10178	1	NULL	NULL	Unvan	10178	Restaurai	16.01.2016 13:39	Muhsin Y	Sakarya	Serdivan	Türkiye	40.765795;30.372146	TR	NULL	NULL	0	2	35	1000	1
10191	1	NULL	NULL	Unvan	10191	Restaurai	2016-02-22 15:09:20.060	Marina İ	Kocaeli	İzmit	Türkiye	40.759160;29.919986	TR	NULL	NULL	0	2	38	1000	1
10193	1	NULL	NULL	Unvan	10193	Cafe & Ba	24.02.2016 17:17	Istasyon I	Manisa	Alaşehir	Türkiye	38.361657;28.513933	TR	NULL	NULL	0	2	27	1000	1
10194	34	NULL	414	Unvan	10194	CAFE & RE	7.03.2016 18:59	Mehmet İ	İstanbul	Kadıköy	Türkiye	41.009723;29.041427	TR	Açılış Gün-		0	2	150	1000	1

Şekil 11. Müşteri gruplarına ait veri setinden örnek

3. Satış

Bu veri setinde 818959 satır bulunur ve yukarıda bahsi geçen 154 işletme ve 1267 tür ürünlere ait yapılan satışların tutulduğu veri setidir. Hangi gün, hangi üründen, ne kadar miktarda, hangi tarihte ve kaç adet satıldığının detaylarını içeren veri setidir. Şekilde yukarıda bahsedilen veri setinden rasgele örnekler verilmiştir.

CustomerID	Name	Price	StartTime	EndTime	OrderPrice	Quantity	OrderTime
0	10092	Limonata	28522.00	2015-08-06 10:46:00.000	2015-08-06 10:46:00.000	15.50	2.0 2015-08-06 10:45:00.000
1	10096	Kıymalı Börek	23102.00	2015-08-06 10:48:00.000	2015-08-06 10:48:00.000	6.00	1.0 2015-08-06 10:48:00.000
2	10096	Ayran	0.93	2015-08-06 10:48:00.000	2015-08-06 10:48:00.000	6.00	1.0 2015-08-06 10:48:00.000
3	10096	Kıymalı Börek	23102.00	2015-08-06 10:50:00.000	2015-08-06 10:50:00.000	6.00	1.0 2015-08-06 10:50:00.000
4	10096	Çay	0.93	2015-08-06 10:50:00.000	2015-08-06 10:50:00.000	6.00	1.0 2015-08-06 10:50:00.000
5	10096	Küt Böreği	46266.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	2.0 2015-08-06 10:51:00.000
6	10096	Karisik Börek	23102.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
7	10096	Kıymalı Börek	23102.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
8	10096	Peynirli Börek	23102.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
9	10096	Su Böreği	23102.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
10	10096	Ayran	0.93	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
11	10096	Çay	28522.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	3.0 2015-08-06 10:51:00.000
12	10096	Sade Pogaça	0.69	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	1.0 2015-08-06 10:51:00.000
13	10096	Kıymalı Pide	17685.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	4.0 2015-08-06 10:51:00.000
14	10096	Limonata	20576.00	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	4.0 2015-08-06 10:51:00.000
15	10096	Su	0.93	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	2.0 2015-08-06 11:12:00.000
16	10096	Su	0.93	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	51.25	2.0 2015-08-06 10:57:00.000
17	10096	Su	0.93	2015-08-06 10:51:00.000	2015-08-06 11:14:00.000	10.00	2.0 2015-08-06 10:58:00.000

Şekil 12. Satış veri seti

Hava Durumu Verileri

Hava durumu verileri (Sıcaklık, yağış miktarı, nispi nem, rüzgâr hızı) 4 ayrı veri seti olarak elde edilmiş olup gerekli ön işlemler yapıp tek tabloda birleştirilmiştir. Veri ön işleme başlığı altında hava durumu veri setlerinin detaylarından bahsedilecektir.

Veri Ön İşleme (Data Preprocessing)

Veri setleri akıllı bir tedarik sistemi tasarımı yapılırken etki eden parametreler şekilde ayıklanmıştır. Müşteri ID' si ile satış ve müşteri veri setleri arasında bağlantı kurulup tek veri seti haline getirildi. Bu veri setini ise ürün ID' leri aracılığıyla bağlayıp bu üç seti birleştirip satış adı verilen son tabloda toplandı. Ek olarak bu veri bağlantı kurma işlemi yapılırken veri tablolarından problemde kullanılacak sütunları belirlenip bu sütunlar alınarak satış tablosu oluşturulmuştur. Son tablo olarak belirttiğimiz satış veri setine ait rastgele alınan veri örneklerini içeren şekil aşağıdaki gibidir. Satış veri seti 818959 satırdan oluşmaktadır.

	Name	ProductID	StartTime	EndTime	OrderPrice	OrderPrice	Branches	CookingTime	CityTown	CityTown
0	Limonata	72408	2015-08-06 10:46:00.000	2015-08-06 10:46:00	15.50	15.50	1.0	0.0	Kocaeli	Kocaeli
1	Kıymalı Börek	73051	2015-08-06 10:48:00.000	2015-08-06 10:48:00	6.00	6.00	1.0	0.0	Kocaeli	Kocaeli
2	Ayran	73065	2015-08-06 10:48:00.000	2015-08-06 10:48:00	6.00	6.00	1.0	0.0	Kocaeli	Kocaeli
3	Kıymalı Börek	73051	2015-08-06 10:50:00.000	2015-08-06 10:58:00	6.00	6.00	1.0	0.0	Kocaeli	Kocaeli
4	Çay	73063	2015-08-06 10:50:00.000	2015-08-06 10:58:00	6.00	6.00	1.0	0.0	Kocaeli	Kocaeli
5	Küt Böreği	73077	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
6	Karisik Börek	73076	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
7	Kıymalı Börek	73051	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
8	Peynirli Börek	73052	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
9	Su Böreği	73078	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
10	Ayran	73065	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
11	Çay	73063	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
12	Sade Pogaça	73073	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
13	Kıymalı Pide	73053	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
14	Limonata	73062	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
15	Su	73064	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
16	Su	73064	2015-08-06 10:51:00.000	2015-08-06 11:14:00	51.25	51.25	1.0	0.0	Kocaeli	Kocaeli
17	Su	73064	2015-08-06 10:51:00.000	2015-08-06 11:14:00	10.00	10.00	1.0	0.0	Kocaeli	Kocaeli

Şekil 13. Birleştirilmiş son tablo

Hava durumu parametrelerine ait 4 ayrı veri seti mevcuttu. Hava durumu değerleri her veri setinde gün içerisinde saat 07:00'da, saat 11:00'da ve saat 16:00'da ölçülmüş bir güne ait üç farklı değer mevcuttu. Bu çalışma için hava durumu parametreleri için günlük ortalama değer alınıp, hava durumu değerleri üç değerden tek değere dönüştürülmüştür. Son olarak dört farklı hava durumu parametresini içeren veri setleri *Istasyon_Adi*, *TARİH*, *SAAT* sütunları arasında bağlantı kurularak ortalama hava durumu adı verilen 442930 satırlık bir veri setine dönüştürülmüştür. Hava durumu verilerine ait son tablodan bir örnek aşağıdaki şekilde verilmiştir.

	Istasyon_Adi	TARİH	RUZGAR_HIZI	SICAKLIK	NISPI_NEM	TOPLAM_YAGIS_OMGI_mm
0	?ANAKKALE	2014-01-01	3.433333	7.866667	83.333333	0.000000
1	?ANAKKALE	2014-01-02	3.733333	8.766667	83.666667	0.066667
2	?ANAKKALE	2014-01-03	2.766667	9.133333	85.000000	0.000000
3	?ANAKKALE	2014-01-04	2.500000	7.833333	83.333333	0.000000
4	?ANAKKALE	2014-01-05	1.200000	8.066667	86.000000	0.000000
5	?ANAKKALE	2014-01-06	1.733333	9.633333	84.333333	0.000000
6	?ANAKKALE	2014-01-07	1.750000	9.500000	83.000000	0.000000
7	?ANAKKALE	2014-01-08	5.433333	8.600000	83.000000	0.000000
8	?ANAKKALE	2014-01-09	2.633333	7.666667	81.333333	0.000000
9	?ANAKKALE	2014-01-10	2.700000	8.600000	84.666667	0.000000
10	?ANAKKALE	2014-01-11	1.933333	10.400000	81.000000	0.000000
11	?ANAKKALE	2014-01-12	1.466667	9.333333	90.333333	0.066667
12	?ANAKKALE	2014-01-13	1.400000	9.100000	89.666667	0.000000
13	?ANAKKALE	2014-01-14	1.800000	8.633333	88.000000	0.000000
14	?ANAKKALE	2014-01-15	2.300000	11.766667	80.000000	0.000000
15	?ANAKKALE	2014-01-16	5.366667	13.066667	84.333333	0.000000
16	?ANAKKALE	2014-01-17	3.300000	12.166667	90.333333	0.000000
17	?ANAKKALE	2014-01-18	8.366667	13.433333	78.666667	0.000000

Şekil 14. Ortalama hava durumu veri setinden örnek

Veri ön işleme evresinde, yukarıda belirtildiği gibi 7 ayrı veri seti birleştirilerek 2 veri seti haline getirilmiştir. 2 ayrı veri seti olan satış ve ortalama hava durumu verileri tarih ve şehire göre bağlanmış ve tek veri seti haline gelmiştir. Proje kısmında satış_hava_durumu diye adlandırılan bu veri setine 2015-2016 yıllarına ait kur detayları Türkiye Cumhuriyeti Merkez Bankası sayfasından alınmış ve tarih ile bağlantı kurulup son veri setine eklenmiştir.

Ürün Grublama İşlemi

Son veri setimiz olan satış hava durumu kur tablosunda 818959 satırlık veri mevcuttur. Bu veri setinde 1267 tür yiyecek-içecek(ürün) bulunmaktadır. Python programlama dili aracılığıyla bu sayı ve detayları elde edilmiştir. Hangi üründen bu veri setinde toplamda kaç adet satıldığını çıkardığımız bu veri seti için, 1267 tür ürün tedarik türüne göre gruplara ayrılmıştır. Her ürün için tek tek araştırma yapıp ürüne ait detaylı bilgiler çıkarılmıştır ve bu bilgiler doğrultusunda ürünün hangi gruba girmesi gerektiği belirlenerek bir *ürün_grup* tablosu oluşturulmuştur. *ürün_grup* tablosuna ait örnek şekil 15’ de verilmiştir.

	Name	Grup
1214	Malibu	Alkollü İçecekler Grubu
1215	Red Label	Alkollü İçecekler Grubu
1216	Açma Tahinli	Pogaca Grubu
1217	Jameson	Alkollü İçecekler Grubu
1218	DONDURMALI FRAPPE	Dondurma Grubu
1219	Cevizli Özel Dürüm KG	Tatlı Grubu
1220	835 - Steak Diavolo	Et Yemeği Grubu
1221	12'LI FINDIK VOTKA	Alkollü İçecekler Grubu
1222	Jose Cuervo	Alkollü İçecekler Grubu
1223	Samuel Adam's	?
1224	SALATA LIBERTA	Salata Grubu
1225	Grolsch	Bira Grubu
1226	Fistikli Özel Dürüm KG	Tatlı Grubu
1227	BEE'S KISS	Kola ve Diğer İçecekler
1228	051 - Red Bull	Kola ve Diğer İçecekler

Şekil 15. Ürün grup örnek tablo

Son veri ön işleme, bu grup tablosunun *Name* sütünü aracılığıyla hava durumu satış kur tablosu ile birleştirme işlemidir.

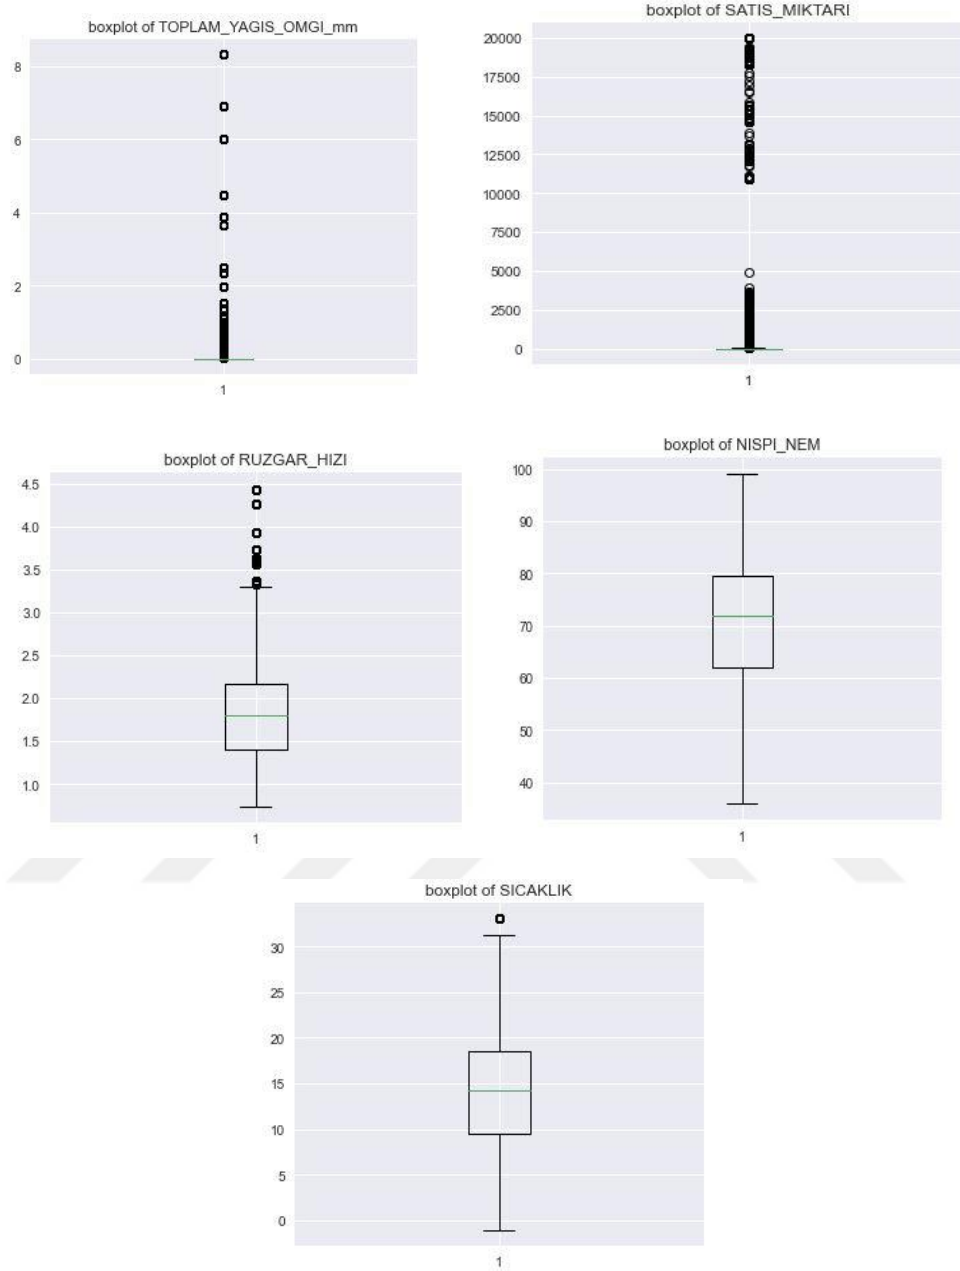
Ön işleme yapıp tablolar arası bağlantı kurulurken tablolarda kullanılmayacak sütunlar çıkarılmış, her veri seti için python aracılığıyla eksik veri, eksik verileri tamamlama işlemleri yapılmış ve veri seti kullanılabilir hale getirilmiştir.

Veri ön işleme makine öğrenmesi modellerinin kurumasını noktasında çok büyük öneme sahiptir. Biz bu çalışma için yukarıda özetle bahsettiğim ön işleme adımları ile veriyi makine öğrenmesi ve derin öğrenme sınıflandırma modelleri için hazır hale getirdik. Veri ön işleme, veri temizleme, normalleştirme, dönüştürme, boyut indirgeme, eksik veri tamamlama, aykırı veri işlemleri ile yapıp veriyi kullanılabilir hale getirmektir.

Aykırı (outlier) veriler, python da boxplot-IQR (kutu grafiği) yöntemi kullanılarak tespit edildi.

Aykırı değerler barındıran sayısal öznitelikler alt ve üst değerine eşitlenir bu çalışma kapsamında sadece üst değer için bir sınır belirlenmiş ve aykırı üst verilere üst değere eşitlemeler yapılmıştır. Aşağıdaki şekilde python da aracılığıyla aykırı verileri için kullanılan kutu grafikleri verilmiştir.

Aykırı veri işlemleri ile Quantity (*SATIS_MIKTARI*) adlı sayısal öznitelik için üst sınır 20.000 adet olarak belirlendi ve aykırı üst değerler 20.000 olarak işleme alınmıştır.



Şekil 16. Aykırı veriler kutu grafiği gösterimi

Makine öğrenmesi model tasarımı için giriş ve çıkış değişkenlerinin sayısal olması gerekmektedir. Bu çalışma için makine öğrenmesi modellerinde bağımsız(çıktı) değişken olarak, Quantity(Satış Miktarı) ele alınmıştır.

Modele girecek olan bağımsız(girdi) değişkenler ise,

- Ürün Grup
- Tatil gün (Tarih)
- Sıcaklık

- Nispi nem
- Toplam yağış
- Rüzgâr Hızı

olarak belirlenmiştir.

Fakat elimizde bulunan veri setinde tarih bilgisi olup bunları hafta sonu veya hafta içi durumu hakkında bilgi olmadığından veri setindeki tarihleri baz alarak python dilinde günlerin tatil olup olmama durumu true-false olarak veri setine eklenmiştir. Eğer tarih hafta sonra ise tatil true eğer tarih hafta içi gününe denk geliyorsa false olarak atanmıştır. Son olarak quantity değeri ürün bazlı olup bir tarihte birden fazla tür ürün ve birden fazla farklı satışlar gerçekleşmiştir. Bu hali ile makine öğrenmesine veri setini sokmak doğru ve sağlıklı sonuç vermeyeceğinden *groupby* fonksiyonu ile satış miktarı, tarih ve ürün bazlı gruplanmıştır. Bu gruplama işlemi sonucunda veri seti 818959 satırdan 59626 satıra inmiştir.

Satış miktarı değişkeni bir sınıf olarak belirtilmiş ve sınıf değerleri,


- $0 < \text{Satış miktarı} < 10$ ise satış miktarı 'az' sınıfına
- $10 < \text{Satış miktarı} < 70$ ise satış miktarı 'orta' sınıfına
- $70 < \text{Satış miktarı} < 20.00$ ise satış miktarı 'çok' sınıfına

girmektedir. Ek olarak veri setleri arasında bağlantı kurma işlemleri sonucunda şehir İstanbul ve Kocaeli olmak üzere ikiye düşmüştür. Makine öğrenmesi için yukarıdaki işlemlerin yapılar hazırlanan son veri setinden pythondan alınan örnek tablo aşağıdaki şekilde verilmiştir.

	URUN_ADI	GRUP	TARİH	TATIL	SEHIR	RUZGAR_HIZI	SICAKLIK	NISPI_NEM	TOPLAM_YAGIS_OMGI_mm	SATIS_MIKTARI
0	CHIMAY RED	Bira Grubu	2016-03-05	True	ISTANBUL	1.533333	11.266667	78.333333	0.000000	az
1	CHIMAY RED	Bira Grubu	2016-03-10	False	ISTANBUL	1.566667	12.566667	71.000000	0.000000	az
2	1 Litre içecek	Kola ve Diğer İçecekler	2016-01-09	True	KOCAELI	1.000000	8.933333	64.666667	0.000000	az
3	1 Litre içecek	Kola ve Diğer İçecekler	2016-01-14	False	KOCAELI	1.133333	7.633333	90.000000	0.733333	az
4	1 Litre içecek	Kola ve Diğer İçecekler	2016-03-02	False	KOCAELI	1.666667	16.000000	71.000000	0.066667	az
5	12'LI FINDIK VOTKA	Alkollü İçecekler Grubu	2015-09-22	False	ISTANBUL	2.333333	25.400000	63.666667	0.000000	az
6	12'LI JAGER	Alkollü İçecekler Grubu	2016-04-06	False	ISTANBUL	1.600000	17.666667	45.000000	0.000000	az
7	3 PEYNIRLI IZGARA TAVUK SALATASI	Salata Grubu	2015-09-20	True	ISTANBUL	1.833333	24.900000	67.333333	0.000000	az
8	3 PEYNIRLI IZGARA TAVUK SALATASI	Salata Grubu	2015-10-03	True	ISTANBUL	2.200000	21.066667	76.666667	0.000000	az
9	3 PEYNIRLI IZGARA TAVUK SALATASI	Salata Grubu	2015-10-05	False	ISTANBUL	1.833333	22.166667	74.666667	0.000000	az

Şekil 17. Makine öğrenmesine girecek veri seti

Veri setindeki deęişken arasındaki korelasyon(ilişki) python aracılığı ile bakıldı. Python da elde edilen korelasyon grafięi şekilde verilmiştir.




Şekil 18. Korelasyon grafięi

Aşğıdaki şekilde görüldüęü gibi veri seti için istatistiksel açıklamalar; ortalama, standart sapma, max, min. deęer vs. python *describe* fonksiyonu ile yapıldı ve incelendi.

	RUZGAR_HIZI	SICAKLIK	NISPI_NEM	TOPLAM_YAGIS_OMGI_mm	SATIS_MIKTARI
count	59626.000000	59626.000000	59626.000000	59626.000000	5.962600e+04
mean	1.827421	14.335200	70.761349	0.118803	6.343798e+03
std	0.596619	6.587034	12.773597	0.582067	6.708919e+04
min	0.733333	-1.100000	36.000000	0.000000	6.000000e-02
25%	1.400000	9.466667	62.000000	0.000000	1.000000e+00
50%	1.800000	14.200000	72.000000	0.000000	3.000000e+00
75%	2.166667	18.500000	79.666667	0.000000	9.000000e+00
max	4.433333	33.033333	99.000000	8.333333	2.629498e+06

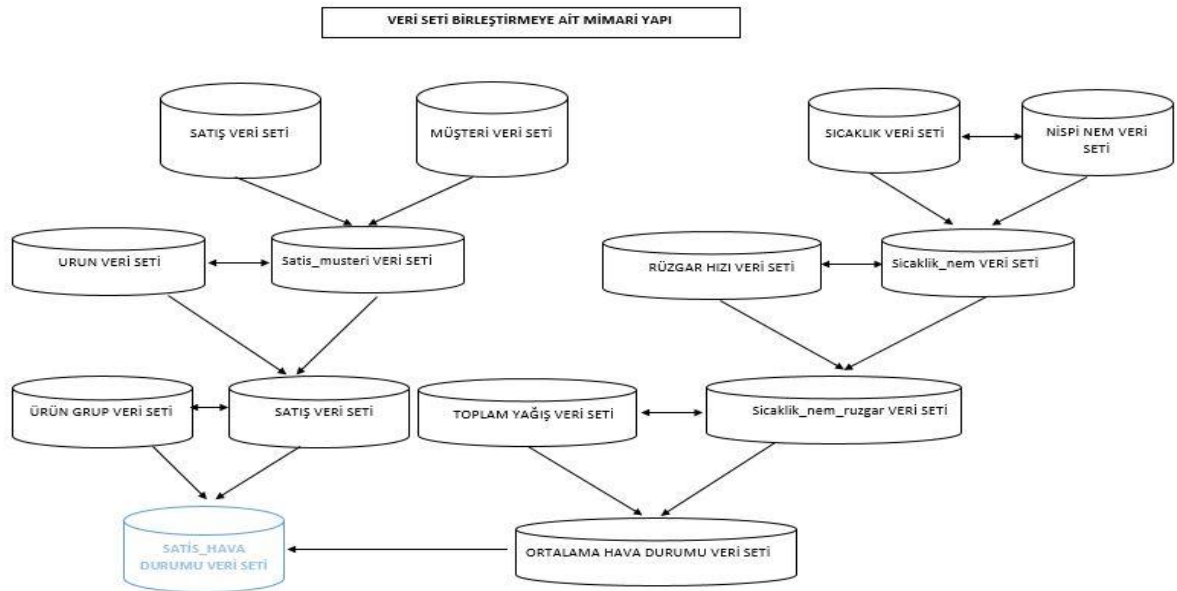
Şekil 19. Veri seti istatistiksel açıklama

data_set adı verilen veri setimiz makine öğrenmesi ve derin öğrenme modeline girmeye hazır hale geldi. Makine öğrenmesi ve derin öğrenme algoritmalarına girmeden önce değişkenlerin etkileri pythonda çizilerek gözlemler yapıldı. Aşağıda satış miktarı ile tatil günlerine ait veri setinden çizdirilmiş grafik bulunmaktadır.



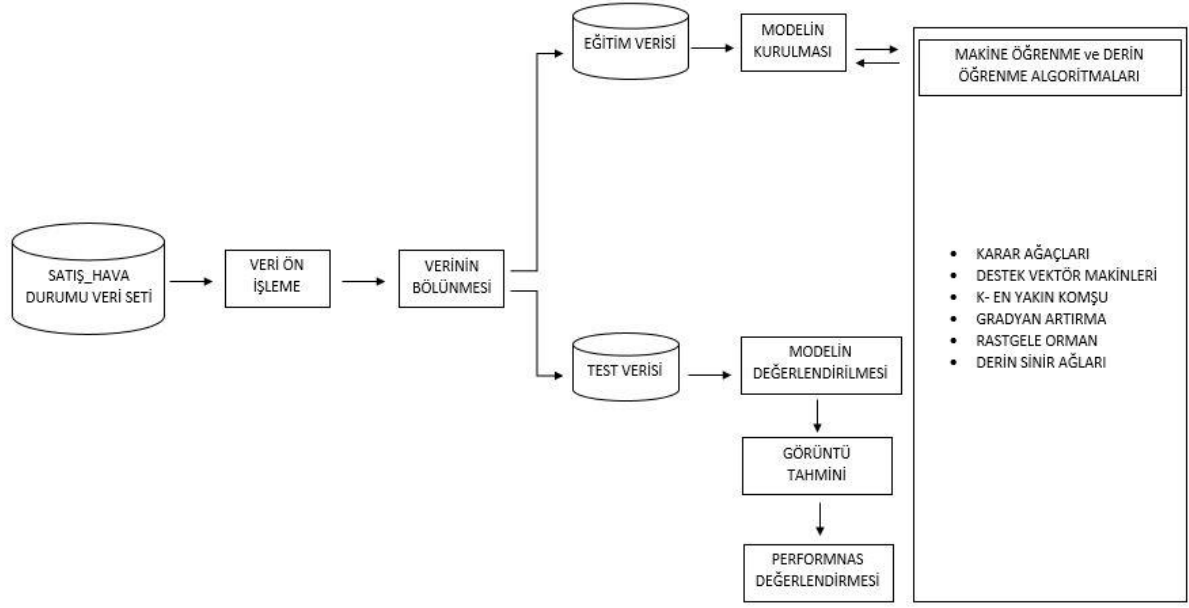
Şekil 20. Veri setinde satış miktarı ve tatil günlerine ait kutu grafiği

Makine öğrenmesi algoritmalarından 5 farklı teknik kullanılarak satış miktarları tahmin edilmiş ve bu tahminler doğrultusunda akıllı bir tedarik sistemi tasarlanmıştır. Aşağıdaki şekilde veri seti birleştirme işlemleri için oluşturulan mimari yapıda şekilde gösterilmiştir.



Şekil 21. Veri seti birleştirme için oluşturulan mimari yapı

Makine öğrenmesi ve derin öğrenme sınıflandırma algoritmalarının için önerilen modele ait mimari aşağıdaki gibidir.




Şekil 22. Akıl tedarik sistemi tasarımında farklı modellerin karşılaştırılmasında kullanılan mimari

Makine öğrenmesi algoritmaları ile sınıflandırma yapıldıktan sonra aynı veri seri için derin öğrenme algoritmalarından derin sinir ağları kullanılarak sınıflandırma yapılmıştır.

İlk olarak model yapay sinir ağı ile sınıflandırılmış ardından katman sayıları artırılarak bir derin sinir ağı oluşturulmuş ve sonuçları karşılaştırılarak en uygun model belirlenmiştir.


Sınıflandırma işlemi sonrasında modelin eğitim geçmişini gösteren grafik aşağıdaki gibidir.



Şekil 23. Derin sinir ağı eğitim geçmişi

Epoch sayısı artıkça model daha çok öğrenmeye başlar ve training skor değeri giderek artar.

Loss fonksiyonu, modelin yaptığı tahminin gerçek değerlerden farklılığını hesaplar. Derin sinir ağlarının son katmanını loss fonksiyonu oluşturur. Loss fonksiyonu ile modelin hata oranı ve aynı zamanda başarısını ölçen grafik şekilde verilmiştir.



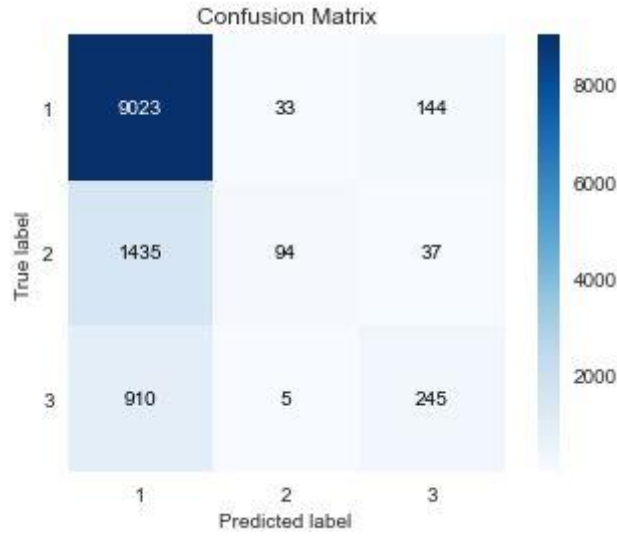
Şekil 24. Loss fonksiyonun grafiği

Sonuç: Veri ön işlemleri yapılan veri seti makine öğrenmesine %0,80 'i eğitim veri seti olarak ve %20'i test veri seti olarak ayrılıp sınıflandırma işlemi yapılmıştır. Veri seti normalize edildi. Gerekli kütüphaneler python a import edilerek veri seti için uygun olan sınıflandırma algoritmaları çalıştırıldı. Bu çalışmada,

- Rastgele orman modeli 0,7768 doğruluk oranı ile sonuç verdi
- Karar Ağaçları 0,7802 doğruluk oranı ile sonuç verdi
- Gradyan Artırma Sınıflandırıcısı 0,7860 doğruluk oranı ile sonuç verdi
- K- en Yakın Komşu algoritması 0,7834 doğruluk oranı ile sonuç verdi
- Destek Vektör Makineleri 0,7850 doğruluk oranı ile sonuç verdi
- Derin Sinir Ağları 0,7844 doğruluk oranı ile sonuç verdi

Bu modeller arasında karşılaştırma yapıldığında problem için en uygun makine öğrenmesi sınıflandırma algoritmasının 0,7860 doğruluk oranı ile gradyan artırma sınıflandırıcısı olduğu gözlemlendi.

Gradyan artırma sınıflandırıcısına ait çalışmadan alınan karmaşıklık matrisi şekilde verilmiştir.



Şekil 25. Gradyan artırma sınıflandırıcısı karmaşıklık matrisi

Makine Öğrenme Algoritmaları ve Derin Sinir Ağı Modeli Sonuçları

Tablo 1. Sınıflandırma Algoritmaları İçin Performans Değerlendirmesi

Model	Doğruluk(%)	Kesinlik(%)	F1-Score(%)	Recall(%)
Derin Sinir Ağları	78.52	-	-	-
Rastgele Orman Modeli	77,77	78	87	99
Karar Ağaçları	78.02	80	88	97
Gradyan Artırma	78.60	80	88	98
K-en Yakın Komşu	78.34	80	88	97
Destek Vektör Makineleri	78.50	79	88	98

SONUÇ

Akıllı tedarik sistemi tasarımı için makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak tahminler yapılmıştır. Makine öğrenmesi sınıflandırma algoritmaları akıllı tedarik sistemi tasarımında başarılı sonuçlar vermiş olup bu çalışmaya en uygun yöntemin gradyan artırıcı sınıflandırma algoritması olduğu söylenebilir. Derin sinir ağları kullanılarak sınıflandırma yapıldığında başarılı sonuçlar elde edilmiştir. Derin sinir ağlarında katman sayıları artırılarak modelin doğruluk değerinde artmalar ve kayıp fonksiyon değerinde (loss fonksiyonunda) azalmalar meydana gelmiştir. Çalışma sonucunda makine öğrenmesi ve derin öğrenme yöntemlerinin performans ölçütleri kıyaslanmıştır. Kullanılan yöntemler içinde en yüksek doğruluk değeri ile gradyan artırıcı sınıflandırma algoritması en başarılı sonuç vermiştir. Fakat kullanılan sınıflandırma algoritmalarının doğruluk değerleri birbirine çok yakındır. Bu da kullanılan yöntemlerinin hepsinin bu problem için uygunluğunun da doğruluğunu göstermektedir. Bir tedarik zinciri en küçük halkadan başlayıp ürünün müşteriye ulaşana kadar geçirdiği bütün süreçtir ve bu sürecin doğru tasarlanması üreticiden – distribütöre ve ondanda satıcıya kadar her bölümünü doğrudan etkiler Akıllı bir tedarik sisteminde, sistemdeki bütün bileşenlerini verileri alınarak sisteme olan etkileri üzerinde doğru kararlara vererek işletmelerin karlarında ve verimliliklerinde artış, maliyetlerinde ise azalmalar oluşturur. Bütün işletmeler kar amacı güderek çalışır ve kar elde etmek için değişiklikler ve iyileştirmeler yapar Akıllı bir tedarik sisteminde sistemin bütün bileşenlerinin davranışları gözlemlenerek sistemin performansını artırmak için sistemdeki bileşenlerinin davranışları biçimlendirilir. Literatürde akıllı bir tedarik sistemi konusunda çok fazla çalışma yapılmamıştır. Bu çalışma ile literatüre katkı sağlanıp teknolojinin gücünü ve verimliliğini gösterilebilir. Özetle akıllı bir tedarik sisteminde özellikle hizmet sektöründe firma sahibi ya da satış yapıp hizmet veren kişi hangi gün hangi tarihte elinde kaç tür malzemedan ne kadar bulundurmalıdır? Sorusunu cevaplayan bu çalışma ile gerçek veriler verilip gözlemler yapılmıştır. Veri setinden örnekler girilip sonuçların doğruluğu analiz edilerek akıllı tedarik sistemi tasarımı için makine öğrenmesi ve derin öğrenme tahminleme algoritmalarının başarılı sonuçlar verdiğini gözlemlenmiştir.

KAYNAKÇA

- Akoğlu, S., 2018. Makine öğrenmesi, <https://deepinsightr.com/> (15.07.2021).
- Atieh, A. M., Kaylani, H., Al-Abdallat, Y., Qaderi, A., Ghoul, L., Jaradat, L., & Hdairis, I. 2016. Performance improvement of inventory management system processes by an automated warehouse management system. *Procedia Cirp*, 41, 568-572.
- Bager, S., Singh, C., & Persson, U. 2022. Blockchain is not a silver wand for agri-food supply chain sustainability: Insights from a coffee case study. *Current Researches in Environmental Sustainability*, 4,100163.
- Başer, B., Yangın, M. & Sarıdaş, E. 2021. Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması. *Süleyman Demirel University Journal of Natural and Applied Sciences*. 25, 1, 112-120.
- Batı, F., 2020. Makine öğrenmesi sınıflandırma algoritmaları kullanılarak meme kanseri tahmini. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Aydın Üniversitesi, İstanbul.
- 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.
- Bilimfili, 2022. Yapay Sinir Ağları. <https://bilimfili.com/wp-content/uploads/2015/12/yapay-sinir-aglari1-bilimfilicom.jpg>.(17.01.2023).
- Boute, R. N., Gijbrecchts, J., van Jaarsveld, W., & Vanvuchelen, N. 2021. Deep reinforcement learning for inventory control: a roadmap. *European Journal of Operational Research*.
- Bonaccorso, G., 2017. Machine learning algorithms. Packt Publishing Ltd. Kantardzic, M., 2011. Data Mining: Concepts, Models, Methods, and Algorithms
- Liu, W., Wei, S., Wang, S., Lim, M., & Wang, Y. 2022. Problem identification model of agricultural precision management based on smart supply chains: an exploratory study from China. *Cleaner Production Magazine*. 352, 131622.
- Devhunter, 2018. Yapay Sinir Ağlarındaki Hiperparametreler. <https://devhunteryz.wordpress.com/2018/08/27/yapay-sinir-aglarindaki-hiperparametreler/#:~:text=Hiperparametreler%20Nedir%3F,ve%20sapmalar%C4%B1%20optimize%20etmeden%20%C3%B6nce>.(11.01.2023).
- Demir, S., Gündüz, M., & Paksoy T. 2022. A New Evaluation Model for the Readiness and Maturity Level of Intelligent and Sustainable Supply Chain Management Based on Geometric Mean. *Journal of Transportation and Logistics*.
- Deng, C. N., & Liu, Y. J. (2021). A Deep Learning-Based Inventory Management and Demand Prediction Optimization Method for Anomaly Detection. *Wireless Communications & Mobile Computing*, 2021. doi:10.1155/2021/9969357
- Elektrikport. Regresyon algoritmaları, <https://www.elektrikport.com/> (15.07.2021). Endüstri 4.0., Yapay zekâ, <https://www.endustri40.com/> (15.07.2021).
- Geest, M., Tekinerdoğan, B., & Çatal, Ç. 2020. A reference architecture for developing smart warehouses in Industry 4.0. *Computers in Industry*, 124, 103343.

- Gedik, Y. 2021. Endüstri 4.0 Teknolojilerinin ve Endüstri 4.0'ın Üretim ve Tedarik Zinciri Kapsamındaki Etkileri: Teorik Bir Çerçeve. *JOEEP*, 6(1), 248-264.
- Giovanni, P. 2021. Intelligent Supply Chains with vendor-managed inventory, coordination and environmental performance. *European Journal of Operations Research*, 292, 2.
- Güneş, O.M., 2020. Makine öğrenmesi yöntemleri kullanılarak karaciğer sirozu hastalığını etkileyen faktörlerin sınıflandırılması. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü İstatistik Anabilim Dalı, On dokuz Mayıs Üniversitesi, Samsun.
- Holmberg, M. & Hallden, P. 2018. Machine Learning for Restaurant Sales Forecast. Department of Information Technology.
- Kara, A., & Dogan, I. (2018). Reinforcement learning approaches for specifying ordering policies of perishable inventory systems. *EXPERT SYSTEMS WITH APPLICATIONS*, 91, 150-158. <https://doi.org/10.1016/j.eswa.2017.08.046>
- Kourentzes, N., Trapero, J. R., & Barrow, D. K. 2020. Optimising forecasting models for inventory planning. *International Journal of Production Economics*, 225, 107597.
- Kurt, F., 2018. Evrişimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Hacettepe Üniversitesi, Ankara.
- Lambourdiere, E., Corbin, E., & Verny, J. 2022. Chapter 24 - Reconceptualizing supply chain strategy for the digital era: achieving digital ambidexterity through dynamic capabilities. *The Digital Supply Chain*. 419-434.
- Ma, S. & Fildes, R. 2021. Retail Sales Forecasting With Meta-Learning. *European Journal of Operational Research*. 288, 1, 111-128.
- 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.
- Meager, S., Kumar, V., Ekren, B., & Paddeu, D. 2021. Exploring the Drivers and Barriers to Green Supply Chain Management Implementation: A study of Independent UK Restaurants. *Procedia Manufacturing*, 51, 1642-1649.
- Medium (2021). <https://medium.com/> (20.07.2021).
- Merrad, Y., Habaebi, M. H., Islam, M. R., & Gunawan, T. S. (2020). A Real-time Mobile Notification System for Inventory Stock out Detection using SIFT and RANSAC. *International Journal of Interactive Mobile Technologies*, 14(5).
- Nozari, H., Jarosz, A., & Nahr, J. 2022. Analysis of the Challenges of Artificial Intelligence of Things (AIoT) for the Smart Supply Chain (Case Study: FMCG Industries). *Industry 4.0 Supply Chain: From Connectivity Provisioning, Data Management to Cyber Resilience*.
- Ntakolia, C., Kokkotis, C., Karlsson, P., & Moustakidis, S. 2021. An explainable machine learning model for material backorder prediction in inventory management [Article]. *Sensors*, 21(23), Article 7926. <https://doi.org/10.3390/s21237926>
- Olsen, M. & Jose, M. 1982. Time-Series Forecasting: A Testing Of Applications To The Food-Service Industry. *International Journal of Hospitality Management*. 1,3, 151-156.
- 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.

- Quantum, Python ile uzun kısa süreli bellek (LSTM). <https://www.alpha-quantum.com/blog/long-short-term-memory-lstm-with-python/long-short-term-memory-lstm-with-python/>.(20.01.2023)
- 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.
- Posch, K., Truden, H., Hungerlander, P. & Pilz, Z. 2022. A Bayesian Approach For Predicting Food And Beverage Sales In Staff Canteens And Restaurants. *International Journal of Forecasting*. 38,1, 321-338.
- 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.
- 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.
- Shao, X., Liu, W., Li, Y., Chaudhry, H., Yue, X. 2021. Multi-stage implementation framework for smart supply chain management under Industry 4.0. *Technological Forecasting and Social Change*, 162, 120354.
- Shrestha, A., & Mahmood, A., 2019. Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040-53065.
- Sobolewski, A., Tchakorom, M. & Couturier, R. 2023. Slope boost-based approach for short- and medium-term wind turbine output estimation. *Renewable Energy*. 203,142-160.
- Sutton, R. S., & Barto, A. G., 2018. Reinforcement learning: An introduction. MIT press.
- Tejesh, B. S. S., & Neeraja, S. 2018. Warehouse inventory management system using IoT and open source framework. *Alexandria engineering journal*, 57(4), 3817-3823.
- Turhost,2021. Makine Öğrenmesi(Machine Learning) Nedir?. <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir/>. (24.01.2023).
- Tirendaz Akademi, 2020. [https://tirendazakademi.medium.com/deri%CC%87n%C3%B6%C4%9Frenme-ve-yapay-si%CC%87ni%CC%87r-a%C4%9Fleri-a80b9bc716b3\(28.01.202](https://tirendazakademi.medium.com/deri%CC%87n%C3%B6%C4%9Frenme-ve-yapay-si%CC%87ni%CC%87r-a%C4%9Fleri-a80b9bc716b3(28.01.202)
- Türkmen, E., 2021. makine öğrenmesi yöntemleri ile banka pazarlama tahmini. Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Kültür Üniversitesi, İstanbul.
- Tyagi, M. & Bolia, N. 2022. Approaches For Restaurant Revenue Management. *Journal of Revenue and Pricing Management*. 21,17-35.
- Wikipedia, 2001. <https://tr.wikipedia.org/wiki/Anasayfa> (15.07.2021).
- Wu, L., Yue, X., Jin, A., & Yen, D. 2016. Akıllı tedarik zinciri yönetimi: gelecekteki araştırmalar için bir inceleme ve çıkarımlar. *Uluslararası Lojistik Yönetimi Dergisi*. 27,2.
- Van Steenbergen, R. M., & Mes, M. R. K. 2020. Forecasting demand profiles of new products. *DECISION SUPPORT SYSTEMS*, 139. <https://doi.org/10.1016/j.dss.2020.113401>
- Viriyasitavat, W., Bi, Z., & Hoonsopon, D. 2022. Blockchain technologies for interoperability of business processes in smart supply chains. *Journal of Industrial Information Integration*. 26, 100326.

Necmettin ., 2017. Derin ğrenme uygulamalarında temel kavramlar : perceptron, skor fonksiyonu ve hata hesaplaması(loss function), [https://tr.linkedin.com/pulse/derin%C3%B6%C4%9Frenmeuygulamalar%C4%B1nda-temel-kavramlar-skor-ve-%C3%A7arkac%C4%B1,\(28.01.2023\)](https://tr.linkedin.com/pulse/derin%C3%B6%C4%9Frenmeuygulamalar%C4%B1nda-temel-kavramlar-skor-ve-%C3%A7arkac%C4%B1,(28.01.2023))



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Zümrüt YILDIRIM
Eğitim	
Lise:	Nenehatun Kız Anadolu Lisesi
Lisans:	Atatürk Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
Yüksek lisans:	Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı(2019)
Yabancı Dil Bilgisi	
İngilizce:	Orta
Almanca:	Çok az