



Demand forecasting for e-retail sector using machine learning and deep learning methods

Mehmet Acı*^{ID}, Gamze Ayyıldız Doğansoy^{ID}

Mersin University, Engineering Faculty, Department of Computer Engineering, 33343, Mersin, Turkey

Highlights:

- Demand forecasting models for local supermarkets were developed and compared.
- A dataset obtained from internet sales and mobile sales was used.
- The best prediction result was obtained using Long and Short Term Memory Networks

Keywords:

- demand forecasting
- e-retail
- e-commerce
- machine learning
- deep learning

Article Info:

Research Article
Received: 07.06.2021
Accepted: 25.09.2021

DOI:

10.17341/gazimmfd.944081

Acknowledgement:

This study was supported by Mersin University Scientific Research Projects Unit (Project Code: 2019-3-TP2-3745).

Correspondence:

Author: Mehmet Acı
e-mail: maci@mersin.edu.tr
phone: +90 324 361 0033 / 17045

Graphical/Tabular Abstract

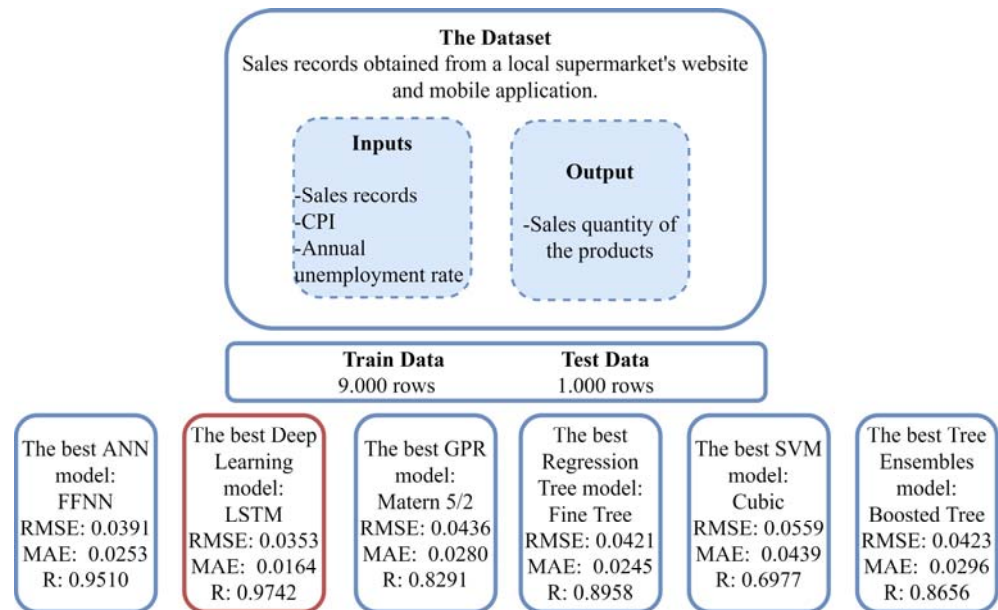


Figure A. 10-fold cross-validation results

Purpose: The demand for a certain category of products is estimated by taking into account the e-commerce data (website and mobile application) of a local supermarket for the last two years and the factors affecting product sales (CPI and unemployment data).

Theory and Methods:

Twenty-four different methods of six different artificial intelligence algorithms (i.e. Deep Learning, Artificial Neural Networks, Gaussian Process Regression, Regression Tree, Support Vector Regression and Ensemble Learning) have been trained and tested for the demand forecasting model.

Results:

The obtained results were evaluated using correlation coefficient (R), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE) criteria. The best result was obtained using Long Short-Term Memory Networks (RMSE= 0.0353; MAE= 0.0164; R = 0.9742).

Conclusion:

The results obtained can increase the success of e-retail sales by using the correct number of product orders, sales campaigns, and marketing strategies.



Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini

Mehmet Acı*^{ID}, Gamze Ayyıldız Doğansoy^{ID}

Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 33343 Yenişehir, Mersin, Türkiye

Ö N E Ç İ K A N L A R

- Yerel süpermarketlere yönelik talep tahmin modelleri geliştirilerek karşılaştırılmıştır
- İnternet satışları ve mobil satışlardan elde edilerek oluşturulan bir veri kümesi kullanılmıştır
- En iyi tahmin sonucu Uzun/Kısa Süreli Bellek Ağları kullanılarak elde edilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 07.06.2021

Kabul: 25.09.2021

DOI:

10.17341/gazimmfd.944081

Anahtar Kelimeler:

Talep tahmini,
e-perakende,
e-ticaret,
makine öğrenmesi,
derin öğrenme

ÖZ

Elektronik perakendecilik (e-perakende), perakendeci ile müşterilerin web ve mobil uygulamalar aracılığıyla iletişimde bulunduğu bir perakendecilik çeşididir. E-perakende işletmelerinin artan rekabet ortamında büyümeye devam edebilmesi ve rakip işletmelerden farklılaşarak ön plana çıkabilmesi için değişen tüketici taleplerine zamanında ve doğru bir şekilde cevap verebilmesi gerekmektedir. Türkiye'deki yerel süpermarket verileri ile e-perakende sektörüne yönelik Makine Öğrenmesi ve Derin Öğrenme algoritmalarını kullanan bir talep tahmin çalışması (bildiğimiz kadarıyla) henüz yapılmamıştır. Bu çalışmada yerel bir süpermarketin 2019-2020 yıllarına ait iki yıllık e-ticaret verileri (web sitesi ve mobil uygulama) ve ürün satışını etkileyen faktörler (tatil günleri, TÜFE değeri ve işsizlik oranı) göz önüne alınarak belirli kategorideki ürünlere yönelik talep tahmin edilmiştir. En iyi talep tahmin modelini elde edebilmek için altı farklı yapay zekâ algoritmasına ait (Derin Öğrenme, Yapay Sinir Ağları, Gauss Süreç Regresyonu, Regresyon Ağacı, Destek Vektör Regresyonu ve Topluluk Öğrenme) yirmi dört farklı yöntem kullanılmıştır. Sonuçlar, korelasyon katsayısı (R), Kök Ortalama Kare Hata (KOKH) ve Ortalama Mutlak Hata (OMH) kriterleri ile değerlendirilmiştir. En iyi sonuç Uzun/Kısa Süreli Bellek Ağları kullanılarak alınmıştır (KOKH=0,0353; OMH=0,0164; R=0,9742). Elde edilen sonuçlar ürün tedarikinin doğru miktarlarda yapılmasında, satış kampanyalarında ve pazarlama stratejilerinde kullanılarak e-perakende satışının başarısını artırabilecektir.

Demand forecasting for e-retail sector using machine learning and deep learning methods

H I G H L I G H T S

- Demand forecasting models for local supermarkets were developed and compared
- A dataset obtained from internet sales and mobile sales was used
- The best prediction result was obtained using Long Short-Term Memory Networks

Article Info

Research Article

Received: 07.06.2021

Accepted: 25.09.2021

DOI:

10.17341/gazimmfd.944081

Keywords:

Demand forecasting,
e-retail; e-commerce,
machine learning,
deep learning

ABSTRACT

Electronic retailing (e-retail) is a type of retailing where the retailer and customers communicate via web and mobile applications. In order for e-retail businesses to continue to grow in an increasingly competitive environment and to stand out from competing businesses, they need to be able to respond to changing consumer demands in a timely and accurate manner. A demand forecasting study using Machine Learning and Deep Learning algorithms for the e-retail sector with local supermarkets' data in Turkey (as far as we know) has not been carried out yet. In this study, the demand for a certain category of products was estimated by considering the two-year e-commerce data (website and mobile application) of a local supermarket for the years 2019-2020 and the factors affecting product sales (holidays, CPI value and unemployment rate). Twenty-four different methods of six different artificial intelligence algorithms (Deep Learning, Artificial Neural Networks, Gaussian Process Regression, Regression Tree, Support Vector Regression and Ensemble Learning) were used to obtain the best demand forecasting model. The obtained results were evaluated using correlation coefficient (R), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE) criteria. The best result was obtained using Long Short-Term Memory Networks (RMSE= 0.0353; MAE= 0.0164; R = 0.9742). The results obtained will be able to increase the success of e-retail sales by using the product supply in the right quantities, in sales campaigns, and in marketing strategies.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *maci@mersin.edu.tr, gamzeayyildizdogansoy@gmail.com /

Tel: +90 324 361 0033 / 17045

1326

1. GİRİŞ (INTRODUCTION)

Perakendecilik, üretici/sağlayıcı ile son tüketici arasında köprü görevi gören ve mal ile hizmetlerin son tüketiciye sunulmasına ilişkin her türlü faaliyet olarak tanımlanmaktadır [1]. Elektronik perakendecilik (e-perakende) ise klasik anlamdaki perakendecilik faaliyetlerinin sanal ortama ve çevrimiçi platformlara taşınması sonucunda ortaya çıkan bir kavramdır [2]. 2020 yılında başlayan COVID-19 salgını ise tüketicilerin e-perakendeye olan yönelimini daha çok artırmış ve hızlandırmıştır. E-perakende sektörünün büyümesi ve özellikle son yıllarda market sayılarının artması ile birlikte rekabet yoğunlaşmıştır. E-perakende sektöründeki işletmelerin temel amacı, müşteri taleplerini minimum zaman ve minimum maliyetle karşılayabilmektir. Bu nedenle etkin bir ürün talep tahmini sistemine ihtiyaç duyulur. Talep tahmini karar vericilerin başarılı olmalarında önemli bir rol oynamaktadır. Müşterilerin talep edeceği ürün adedinin doğru bilinmemesi halinde, stok fazlası ve imha gibi durumların oluşmasının yanı sıra ürünün mağaza stokunda bulunamaması, müşteri memnuniyetsizliğine sebep olarak müşteri kaybı yaşatabilmektedir.

Talep, tüketicilerin bir ürün ya da hizmeti belirli bir fiyat düzeyinde almaya hazır oldukları miktara denir. Talep tahmini ise üretilen mal ve hizmetlerin piyasadaki aktif tüketiciler tarafından ne kadar talep edileceğinin önceden ön görülmesini ifade eder. Talep tahmini ile elde edilen veriler işletmelerde üretim planlama, depolama, kontrol sistemleri ve pazarlama stratejileri için temel kaynağı oluşturmaktadır [3]. Talep tahmini konusunda 1960'lı yıllardan beri çalışmalar yapılmakta olsa da son yıllarda yapılan çalışmaların hemen hepsi Yapay Zekâ tabanlı Makine Öğrenmesi ve Derin Öğrenme algoritmaları kullanılarak

gerçekleştirilmiştir [4]. Literatürdeki talep tahmini çalışmaları enerji [5-7], gıda [8-10], tekstil [11, 12], otomobil [13], temel ihtiyaçlar [3, 14], turizm [15, 16] ve çeşitli hizmetlerin [17-19] talebi gibi farklı perakende sektörlerindeki ürün ve hizmetler üzerine yapılmıştır. Bununla birlikte artan kentli nüfus ve teknolojik gelişmeler gıda ve temel ihtiyaç maddeleri temininin süpermarketlerin çevrimiçi hizmetleri (web sitesi, mobil uygulama) aracılığı ile yapılmasına ve bu alandaki talep tahmini probleminin önemine dikkat çekmektedir. Süpermarket verileri ile yapılacak talep tahmini çalışmalarının ekonomik getirisinin yanı sıra gıda israfının önlenmesi, halkın tüketim eğilimlerinin incelenmesi ve yerel üreticilerin korunması gibi yaygın etkileri de mevcuttur.

Süpermarket verileri ve Makine Öğrenmesi yöntemleri kullanılarak yapılan önceki talep tahmini çalışmaları incelenecek olursa (Tablo 1), Du vd. [20] dayanıksız çiftlik ürünlerine yönelik talebi tahmin etmek için Destek Vektör Makineleri'ni (DVM) kullanmışlardır. Çalışmalarında üç farklı süpermarketten alınan elma ve muz verileri ile haftanın 7 gününe dağılmış talep tahmin modeli geliştirmişlerdir. Slimani vd. [21] oyun teorisi ve Yapay Sinir Ağı (YSA) kullanarak Fas'taki bir süpermarket için ürün talep tahmin modeli geliştirmişlerdir. Qu vd. [22] 45 farklı bölgedeki önde gelen perakende mağazasının 2015-2017 yılları arasındaki satış verilerini ve Rastgele Orman algoritmasını kullanarak mağazaların haftalık talep tahminini yapmışlardır. Neelakantam vd. [23] Pekıştirmeli Öğrenme ve Sis Bilişim (Fog Computing) [24] algoritmalarını kullanarak bir süpermarketin üç ayrı şubesinden toplanmış verileri [25] düşük, orta ve yüksek talep kümelerine ayırmışlardır. Wolters ve Huchzermeier [26] Almanya genelinde 300 mağazası olan bir süpermarket zincirindeki 14 ürün için sezon içi ve sezon dışı promosyon talep tahmini

Tablo 1. Süpermarket verisi kullanılarak yapılan önceki çalışmaların başarımlarını karşılaştırması
(Performance comparison of previous studies using supermarket data)

Yazar	Yıl	Veri	Yöntem	En İyi Başarım
Du vd. [20]	2013	3 farklı süpermarketten toplanan 2 adet ürünün (elma ve muz) günlük satış verisi.	Destek Vektör Makinesi	Kök Ortalama Kare Hata =0,869
Slimani vd. [21]	2016	Bir süpermarketten alınan bir günlük satış verisi.	Oyun Teorisi ve Çok Katmanlı Algılayıcı	Ortalama Kare Hata=0,098
Qu vd. [22]	2017	Haftalık süpermarket satış verileri, hava sıcaklığı, yakıt fiyatları ve işsizlik verisi.	Rastgele Orman	Ortalama Mutlak Yüzde Hata=%23,6
Neelakantam vd. [23]	2021	3 farklı süpermarketten toplanan 3 aylık satış verisi [25]	Sis Bilişim	Silhouette skoru \geq %60
Wolters ve Huchzermeier [26]	2021	Bir süpermarket zincirindeki 14 ürüne ait satış verisi	Harmonik Regresyon	Ortalama Mutlak Yüzde Hata=%11,4 (1 haftalık tahmin)
Punam vd. [31]	2018	BigMart veri kümesi	İstatistiksel model (kübik)	Ortalama Mutlak Hata=0,391
Sekban [29]	2019		Rastgele Orman	Kök Ortalama Kare Hata =1,879
Malik ve Singh [28]	2020		Rastgele Orman	$R^2=0,563$

yapmışlardır. Bu alanda bilinen veri kümeleri arasında BigMart veri kümesi [27] literatürdeki çalışmalarda öne çıkmaktadır. Bu veri kümesindeki veriler dünya çapında birçok ülkede şubeleri bulunan ve 2007 yılında kurulmuş olan uluslararası bir market perakende şirketi olan BigMart süpermarket zincirine aittir. Veri kümesinde farklı şehirlerdeki on mağazaya dağıtılan 1559 ürünün 8523 satırlık satış bilgisi bulunmaktadır. BigMart veri kümesi ve Makine Öğrenmesi tabanlı tahmin modelleri kullanılarak birçok talep ve satış tahmini çalışması yapılmıştır [28-30].

Tablo 1'deki çalışmalar incelendiğinde, çalışmalarda kullanılan satış verilerinin servis noktası (Point of Service (POS)) bilgileri olduğu, kullanılan talep tahmini algoritmalarının kısıtlı olduğu görülmüştür. Bununla birlikte, sadece bir çalışmada [22] talebe etki eden diğer faktörler kullanılmış olup bu çalışmada geliştirilen modelin başarımı oldukça düşüktür (Ortalama Mutlak Yüzde Hata=%23,6). Diğer çalışmalarda ise sadece satış verisi kullanılmıştır. Tüketici Fiyatları Endeksi (TÜFE) gibi Türkiye'ye ait parametrelerin yurtdışı kaynaklı çalışmalarda bulunmaması doğal olmakla birlikte incelenen makalelerde çalışmanın yapıldığı ülkeye ait TÜFE değeri benzeri değişkenlere de rastlanmamıştır. Türkiye'deki yerel süpermarket verileri ile e-perakende sektörüne yönelik, Makine Öğrenmesi ve Derin Öğrenme algoritmalarını kullanan bir talep tahmin çalışması (bildiğimiz kadarıyla) henüz yapılmamıştır. Yapılan çalışma, toplanan verinin niteliği, yaygın etki, yöntem ve başarımlarından dolayı bu alanda gerçekleştirilen önceki çalışmalardan daha ileri bir noktadadır.

Bu çalışmada, müşterilerin elektronik alışveriş kayıtları analiz edilerek bir ürün talep tahmin modeli geliştirilmiştir. Çalışmada, yerel bir süpermarket zincirinden temin edilen internet alışveriş satış verilerinin yanı sıra Türkiye İstatistik Kurumu'ndan (TÜİK) temin edilen TÜFE, işsizlik oranı ve alışveriş yapılan tarihin tatil günü olup olmadığını gösteren veriler de kullanılmıştır.

Ürün talep tahmini için YSA, Derin Öğrenme, Gauss Süreç Regresyonu (GSR), Regresyon Ağacı, DVM ve Topluluk Öğrenme (Ensemble Learning) yöntemleri kullanılmış ve elde edilen sonuçlar karşılaştırılmıştır. YSA modellerinden İleri Beslemeli Sinir Ağları (İBSA) (Feed Forward Neural Networks), Fonksiyon Uydurma Sinir Ağları (FUYSA) (Function Fitting Neural Networks), Kademeli İleri Sinir Ağları (KİSA) (Cascade Forward Neural Networks), Çok Katmanlı Algılayıcılar (ÇKA) (Multi Layer Perceptrons) modelleri geliştirilmiştir. Derin Öğrenme yöntemlerinden ise Konvolüsyonel Sinir Ağları (KSA) (Convolutional Neural Networks), Tekrarlayan Sinir Ağları (TSA) (Recurrent Neural Networks), Uzun/Kısa Süreli Bellek Ağları (UKSBA) (Long Short-Term Memory Networks), Çift Yönlü Uzun/Kısa Süreli Bellek Ağları (ÇYUKSBA) (Bidirectional Long Short-Term Memory Networks), Derin Oto Kodlayıcılar (DOK) (Deep Auto Encoders) yöntemleri kullanılmıştır. Topluluk Öğrenme algoritmalarından Güçlendirilmiş Karar Ağaçları (Boosted Decision Trees) ve

Torbalama Karar Ağaçları (Bagged Decision Trees) kullanılmıştır. Sonuçlar korelasyon katsayısı (R), Kök Ortalama Kare Hata (KOKH) (Root Mean Square Error) ve Ortalama Mutlak Hata (OMH) (Mean Absolute Error) kriterleri ile değerlendirilmiştir.

Bu çalışmada yukarıda ifade edilen yöntemlerin seçilme nedeni; literatürdeki tahmin çalışmalarında kullanılan ve yüksek doğruluk oranına sahip algoritmalar olmalarıdır. Bununla birlikte alınan sonuçlar, iyi bilinen ve uzun zamandır kullanılan algoritmaların yanı sıra nispeten daha kısa süredir tahmin çalışmalarında kullanılan algoritmaları kıyaslama imkânı sunmuştur. Çalışmada kullanılan tüm yöntemler ürün talep tahmini için uygun yöntemler olup yöntemler arasında en başarılı sonuç Derin Öğrenme metodlarından UKSBA ile elde edilmiştir.

Makalenin bundan sonraki bölümleri şu şekilde organize edilmiştir: ikinci bölümde süpermarket verilerinden elde edilen veri kümesi ve talep tahmininde kullanılan yöntemler irdelenmiştir. Üçüncü bölümde farklı algoritmalar kullanılarak geliştirilen talep tahmin modellerinin detayları ve seçilen kriterler üzerinden başarımları verilmiştir. Dördüncü ve son bölümde ise çalışma sonuçları tartışılmış ve gelecek çalışma önerileri sunulmuştur.

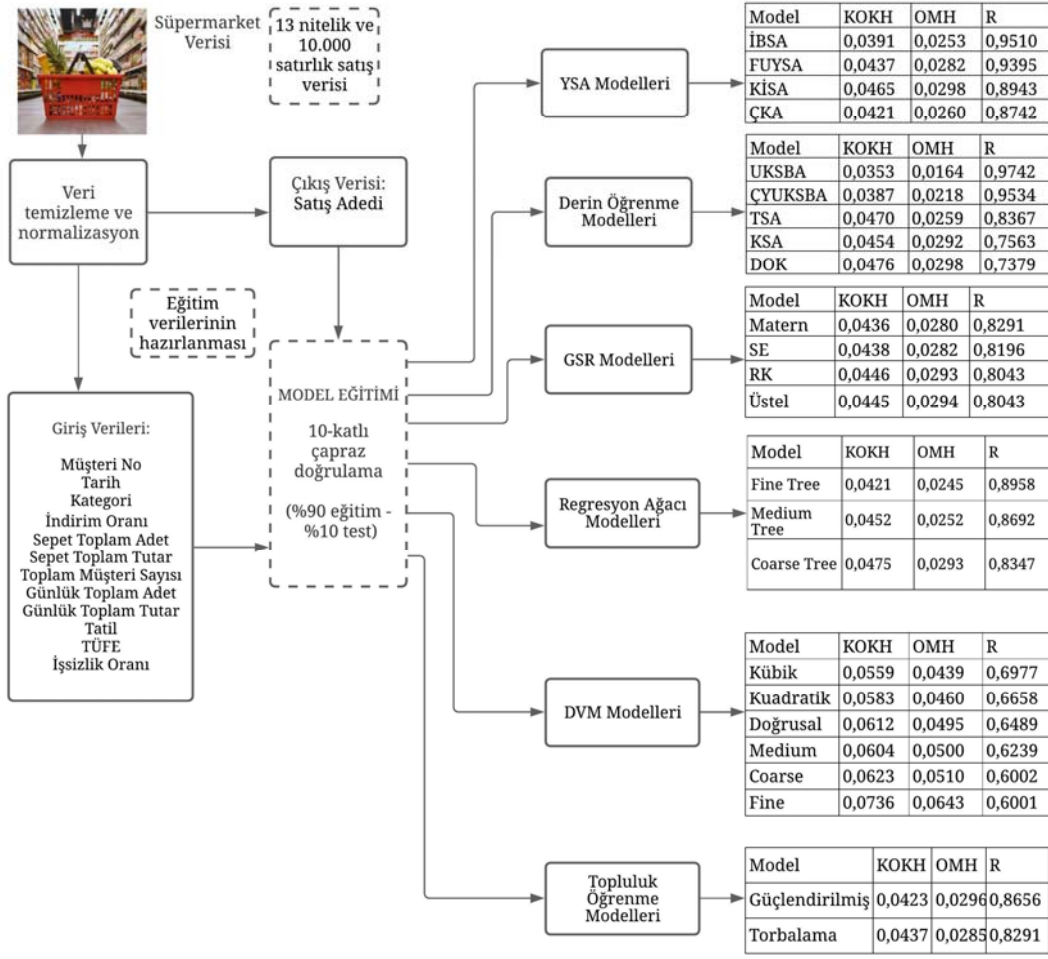
2. DENEYSEL METOT (EXPERIMENTAL METHOD)

Bu bölümde, çalışmada kullanılan veri kümesi ve talep tahmin modellerinin geliştirilmesinde kullanılan yöntemler ele alınacaktır. Geliştirilen modeller ve alınan sonuçlar blok diyagram olarak Şekil 1'de ifade edilmiş olup detaylar alt başlıklarda verilmiştir.

2.1. Veri Kümesi (The Dataset)

Çalışmada kullanılan veri kümesi yerel bir süpermarket zincirinin 2019-2020 yıllarına ait internet alışveriş satış verileri, TÜFE, işsizlik oranı ve tatil günleri verilerini içermektedir. TÜFE ve işsizlik oranı bilgileri, satış verilerinin tarih bilgisi baz alınarak TÜİK otomasyonundan çekilmiştir. Oluşturulan veri kümesinde toplam 13 nitelik ve 10.000 satırlık satış verisi bulunmaktadır. Veri kümesi niteliklerinin detayları Tablo 2'de sunulmuştur.

Tablo 2'de görülen müşteri no, tarih, kategori, adet, tutar, indirim oranı, sepet toplam adet ve sepet toplam tutar bilgileri müşterinin yapmış olduğu alışverişe ait olan satış bazı verilerdir. Ürüne ait kategori bilgisi tahmin sonuçlarının hangi ürün kategorisine ait olduğunu belirlemede kullanılacak olan verilerdir. Tutar ve indirim oranı bilgileri bir ürünün satış adedini en fazla etkileyen faktörlerdendir. Ürün tutarı bilgisi ürün birim fiyatı ile adet bilgisinin çarpılması ile elde edilen bilgidir. Ürün birim fiyatının düşük olması ürün tutarının da düşük olmasını sağlayacaktır. Bu durum ürüne olan talebi artırarak satış adedi sayısını yükseltecektir. İndirim oranı ürünlere brüt birim fiyat üzerinden uygulanan yüzdelik oran olarak ifade edilen iskonto miktarıdır. Ürünlere uygulanan indirim



Şekil 1. Talep tahmin sisteminin genel tasarımı (The overall design of the demand prediction system)

oranının artması satışı arttıran temel faktörlerden bir diğeridir. Sepet toplam adet ve sepet toplam tutar verileri müşterinin bir alışverişte satın alacağı tüm ürünlerin adet ve tutar olarak toplamlarını ifade eden veriler olup ürün talebini etkileyen faktörlerdendir. Sanal mağazaya gelen müşteri sayısının yoğunluğu ve tüm ürünlerin toplam satış adet/tutar bilgileri bir ürüne talep miktarını dolaylı olarak etkileyen faktörlerdir.

Firmadan alınan satış ve müşteri bilgilerini içeren veriler dışında ürün satışına etki ettiği düşünülen TÜFE ve işsizlik oranları ile ilgili tarihin tatil olup olmadığı bilgileri de veri kümesine eklenmiştir. TÜFE oranı gıda, sağlık, ulaşım, konaklama gibi mal ve hizmetleri içeren bir tüketici sepetindeki ortalama fiyat değişimini ölçen endekstir [32]. TÜFE'nin temel amacı tüketime konu olan önceden belirlenen mal ve hizmetlerin fiyatlarındaki değişimi ölçerek enflasyonu hesaplamaktır. TÜFE'deki değişiklikler yaşama maliyetiyle ilişkili fiyat değişikliklerini değerlendirmek için kullanılır. Fiyat değişikliklerini doğrudan etkileyen TÜFE oranı dolaylı olarak bir ürüne ait talep miktarını da etkileyen faktörlerdendir. İşsizlik oranı iş arayan, iş bekleyen ya da işe dönmeye hazır bireylerin, ülke nüfusu iş gücüne oranını

ifade eden kavramdır [33]. İşsizlik oranı ekonominin bütünü hakkında bilgi veren bir değerdir. İşsizlik oranının düşmesi ekonomideki toplam talebi artırarak tüketicilerin alım gücünü olumlu yönde etkilemektedir. Bu durum tüketicilerin ürün talebini artırmaktadır. Ürünün satışının yapıldığı tarihin özel ya da resmi tatil gününe denk gelmesi de satış adedini artıracak etmenlerden birisidir. Tatil günleri tüketicilerin ihtiyaçlarına daha fazla zaman ayırdığı günlerdir. Bu günlerde mağaza müşteri sayısı, toplam mağaza cirosu ve ürün satış adedi daha yüksek olmaktadır.

2.2. Yöntemler (Methods)

Bu bölümde çalışmada kullanılan Makine Öğrenmesi ve Derin Öğrenme tabanlı algoritmalar sunulacaktır. Sunulan algoritmalar literatürde sıkça kullanılan ve iyi bilinen yöntemler olmaları sebebiyle özetlenecek ve bu alanda son yıllarda yapılmış önemli çalışmalara referans verilecektir.

2.2.1. Yapay Sinir Ağı (YSA) (Artificial Neural Network)

YSA'lar, beyni oluşturan sinir hücrelerini (nöron) matematiksel olarak taklit eden Yapay Zekâ yöntemidir.



Tablo 2. Veri kümesi (The dataset)

Nitelik	Açıklama
Müşteri No	Her müşteri için benzersiz olan numara bilgisi.
Tarih	Satışın yapıldığı tarih bilgisi.
Kategori	Satın alınan ürünün kategori bilgisinin nümerik karşılığı. Temizlik/Kağıt/Kozmetik=1, Gıda/Atıştırmalık=2, Süt/Kahvaltılık=3, Diğer Kategoriler=4, İçecekler=5, Et/Balık=6
Adet	Satın alınan ürünün adet bilgisi.
Tutar	Satın alınan ürünün toplam tutar bilgisi.
İndirim Oranı	Ürüne uygulanan indirim oranı (%).
Sepet Toplam Adet	Müşterinin yapmış olduğu alışverişteki ürünlerin toplam adedi.
Sepet Toplam Tutar	Müşterinin yapmış olduğu alışverişin toplam tutarı.
Toplam Müşteri Sayısı	Satışın yapıldığı tarihte alışveriş yapan toplam müşteri sayısı.
Günlük Toplam Adet	Satışın yapıldığı tarihteki toplam ürün satış adedi.
Günlük Toplam Tutar	Satışın yapıldığı tarihteki toplam ürün satış tutar bilgisi.
Tatil	Satışın yapıldığı tarihin tatil olup olmadığı bilgisi.
TÜFE	Satışın yapıldığı tarihteki TÜFE oranı.
İşsizlik Oranı	Satışın yapıldığı tarihteki işsizlik oranı.


YSA hücre yapısı girişler, ağırlıklar, transfer fonksiyonu, aktivasyon fonksiyonu ve çıkışlar olmak üzere beş ana bileşenden oluşmaktadır [34]. Dış ortamdan alınan giriş verileri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Net giriş, giriş verileri ile bu verilerin ağırlıklarının çarpılması ile elde edilir. Aktivasyon fonksiyonu genelde doğrusal olmayan bir fonksiyondur ve işlem süresince net çıkışı hesaplar. Bu işlemin sonucu aynı zamanda nöron çıkışını da vermektedir.

Çalışmada, YSA yöntemlerinden İBSA, FUYYA, KİSA ve ÇKA kullanılarak talep tahmin modelleri oluşturulmuştur. Bu yöntemlerden İBSA'lar (Şekil 2) nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir. Bir katman sadece kendisinden sonraki katmana bağlıdır [35].


FUYYA ise iki katmanlı ileri beslemeli ağ yapısı kullanarak fonksiyon uyarlama sorununu çözme konusunda kullanılan YSA türüdür. Veri seçimi, eğitim, doğrulama ve test işlemleri FUYYA ağ modeli kullanılarak MATLAB uygulamasında yapılabilmektedir (Şekil 3) [36].

**Şekil 2.** İBSA mimarisi (FFNN architecture)**Şekil 3.** FUYYA mimarisi (FITNET architecture)

KİSA ileri beslemeli ağlara benzer ancak girdiden her katmana ve her katmandan sonraki katmanlara bir ağırlık bağlantısı içerir (Şekil 4) [37]. İki katmanlı ileri beslemeli ağlar potansiyel olarak herhangi bir girdi-çıkış ilişkisini öğrenebilirken, daha fazla katmana sahip ileri beslemeli ağlar karmaşık ilişkileri daha hızlı öğrenebilirler.

**Şekil 4.** KİSA mimarisi (CFNN architecture)

ÇKA YSA'ların girdi ve çıktıları arasında doğrusal olmayan ilişkiler bulunan olayları öğrenmesi için daha gelişmiş modellere ihtiyaç duyulması sonucu ortaya çıkan ve diğer YSA yöntemlerinin temelini oluşturan modeldir (Şekil 5). ÇKA ağı kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı oluşturur. Bu çözüm uzayı gösterilen benzer örnekler için sonuçlar ve çözümler üretir [38].

**Şekil 5.** ÇKA mimarisi (MLP architecture)

2.2.2. Derin Öğrenme (Deep Learning)

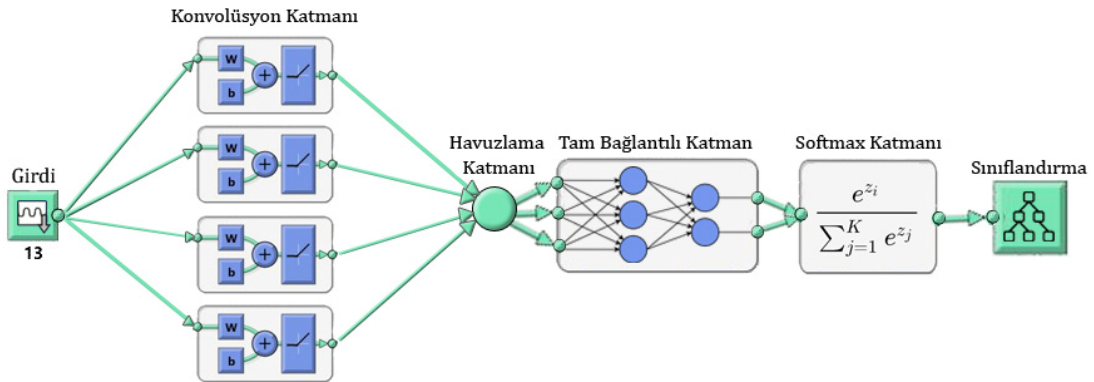
Derin Öğrenme YSA'ları temel alan makine öğrenmesinin bir alt kümesidir. Derin Öğrenme ile oluşturulan sinir

ağlarının klasik YSA'ların çok katmanlı ve çok nöronlu bir hali olduğu söylenilebilir. Bu çok katmanlı yapıda bilgiye ait özellik çıkarımları sinir ağı katmanları içerisinde oluşturulmaktadır. Katmanlı yapı öznelikleri gizli katmanda açığa çıkararak ağırlık değerlerini eğitim sürecinde belirlemektedir. Konvolüsyon işlemi ile veriye ait özellikler belirlenmekte ve ağıdaki diğer katmanlar bu özellikleri alarak bir alt katmana iletmektedir. Bu yönü ile özellik çıkarımını kendi başına karar vererek yapabilen sinir ağı, klasik yöntemlere göre daha başarılı sonuçlar üretmektedir [39].


Çalışmada Derin Öğrenme yöntemlerinden KSA, TSA, UKSBA, ÇYUKSBA, DOK yaklaşımları kullanılmıştır. KSA'lar görüntü tanıma, sinyal işleme, dil tanıma, duyu tanıma ve konuşma doğrulama çalışmalarında sıklıkla kullanılsa da regresyon çalışmalarında da oldukça iyi sonuçlar veren bir yöntemdir [40]. KSA'lar iki aşamalı çalışır: İlk aşamada birbiriyle ilişkili olan yerel özneliklerin çıkartılması işlemi yapılır. Sonraki aşamada ise ÇKA'lar ile elde edilmek istenen çıktı hesaplanır. Birçok gizli alt katmandan oluşan KSA mimarisindeki ilk katman konvolüsyonel katmandır. Bu katmanda küçük boyutlu filtreler girdinin tamamı üzerinde gezdirilerek konvolüsyon işlemi yapılır [41]. Konvolüsyon işlemi sonrası öznelik haritasının çıkışına aktivasyon fonksiyonu uygulanır. Böylece sonucu doğrusal olmayan bir özellik katılmış olunur. Uygulanan aktivasyon fonksiyonları ile sinir ağının, eğitim boyunca hızlı ve kararlı bir şekilde yakınsaması sağlanır. Şekil 6'da çalışmada kullanılan KSA'nın mimarisi görülmektedir. TSA'lar metin, ses ve zaman serisi verileri gibi ardışık sıralı verileri modellemek için kullanılır. Tekrarlayıcı olarak isimlendirilmelerinin sebebi, bir dizinin

her bir elemanı için aynı görevi tekrar tekrar gerçekleştirmesidir. Geleneksel bir sinir ağındaki tüm girdi ve çıktılar genellikle birbirinden bağımsızdır ancak TSA'lar birimleri arasında bağlantılar bulunan ve bu bağlantıların yönlendirilmiş bir döngü oluşturduğu ağlardır (Şekil 7) [42]. İleri beslemeli ağlardan farklı olarak TSA'ların girdileri işlemek için kullanabileceği kendi giriş bellekleri vardır. Verileri işlemek için kendi hafızalarından yararlanırlar. TSA'lar döngüsel yapısı ile geçmiş bilgilerin kullanılmasını da sağlayarak zaman serisi boyunca ilerleyen veriler arasında anlamlandırma yapabilmektedir.

UKSBA ve ÇYUKSBA kaybolan gradyan ve uzun süreli bağımlılık problemlerine çözüm üretmek için geliştirilen TSA'lardır. TSA'lara göre daha iyi performans sağlayan ve daha tutarlı olan özel iç kapılara sahiptirler [41]. UKSBA hücreleri girdi verilerini uzun süre hafızada tutma özelliğine sahiptir. Bu hücrelerin hafızaları önceki durum verileri ile o anki giriş verilerini sonraki durum girdisi için kullanılmaktadır [43]. Hafızalarında hangi verilerin tutulacağına karar verdikten sonra önceki durum verileri, o an hafızada bulunan veriler ile girdi verilerini birleştirerek daha etkin sonuçlar üreten bir ağ yapısı oluştururlar. ÇYUKSBA bir serinin hem geçmiş hem de gelecek zamanlardaki bilgilerini kullanabilmeyi sağlar. Bu yöntem ile TSA durum nöronları pozitif zaman ve negatif zaman olmak üzere birbiriyle bağlantısı olmayan iki duruma bölünmektedir. Böylelikle geleneksel TSA yapılarından farklı olarak iki katmandan gelen değerler hesaplanır. Çift yönlü özyinelemeli sinir ağlarında tekrar eden hücrelerde UKSBA hücresi kullanılırsa ÇYUKSBA mimarisi elde edilmektedir [41]. Şekil 8'de çalışmada kullanılan UKSBA ve ÇYUKSBA mimarileri görülmektedir.




Şekil 6. KSA mimarisi (CNN architecture)



Şekil 7. TSA mimarisi (RNN architecture)


Oto kodlayıcılar girdi veri kümesini sıkıştırarak, en az kayıpla girdiye en çok benzeyen çıktıyı üretecek olan, en iyi özelliklerin ve yapısal bilgilerin öğrenilmesini sağlayan çok katmanlı YSA mimarileridir. DOK ise her bir katmandaki çıktıların ardışık katmanın girişlerine bağlandığı oto kodlayıcı katmanlarından oluşan sinir ağıdır (Şekil 9). DOK'lar girdi, gizli ve çıktı olmak üzere üç katmandan oluşmaktadır. Girdi katmanındaki verinin oldukça benzeri bir çıktı amaçlandığı için girdi ve çıktı katmanındaki nöron sayıları eşit olmakla beraber gizli katmandaki nöron sayısı değişkenlik gösterebilir. Gizli katmandaki nöron sayısı ağıın başarımlını etkilemektedir. DOK'larda girdi ile çıktı arasındaki benzerlik oranının fazla olması algoritma fonksiyonunun başarılı olduğunu gösterir. Benzerlik oranı girdi veri kümesine en yüksek olana kadar ağırlıklar değiştirilerek algoritma çalışır [44].



Şekil 9. DOK mimarisi (DAE architecture)




2.2.3. Gauss süreç regresyonu (GSR) (Gauss process regression)

GSR Bayesian regresyon yaklaşımını kullanan ve doğrusal olmayan regresyon problemlerinin çözümüne uygun bir modeldir [45]. GSR modeli küçük veri kümeleri üzerinde iyi çalışan ve tahminler üzerinde belirsizlik ölçümleri yapma becerisine sahip bir yöntemdir. Doğrusal olmayan regresyon problemlerinin çözümüne uygundur. GSR'ler istatistiksel modellemede birden çok hedef değer tahmin edilmesinde ve haritalamayı daha yüksek boyutlarda analiz etmekte kullanılır [46]. Tahmin değerleri sistematik ya da rassal varyasyonlar ile olabilmektedir. Gauss süreci fonksiyonlar üzerine olasılık dağılımı tanımlar (Eş. 1).



Şekil 8. UKSBA ve ÇYUKSBA mimarileri (LSTM and BiLSTM network architectures)

Tablo 3. Regresyon ağacı yöntemlerinin karşılaştırılması (Comparison of the regression tree methods)

Ağaç Modeli	Model Esnekliği
Coarse Tree 	Düşük. Az sayıda yaprak kullanılır. Maksimum bölünme sayısı 4'tür.
Medium Tree 	Orta. Orta sayıda yaprak kullanılır. Maksimum bölünme sayısı 20'dir.
Fine Tree 	Yüksek. Çok yaprak kullanılır. Maksimum bölünme sayısı 100'dür.

$$f(x) \sim GP(m(x), K(x, x')) \quad (1)$$

$m(x)$ ortalama, $K(x, x')$ ise kovaryans fonksiyonları olup formülleri Eş. 2 ve Eş. 3'te verilmiştir. $x, x' \in X$ rastgele değişken olmak üzere:

$$m(x) = E[f(x)] \quad (2)$$

$$K(x, x') = E[(f(x) - m(x))(f(x') - m(x'))^T] \quad (3)$$

GSR modelleri küçük örneklem uzayları, yüksek boyutlar ve doğrusal olmayan karmaşık regresyon problemleriyle çalışmak için oldukça uygun olup güçlü genelleme yeteneğine sahiptirler. DVM ve YSA'lar ile karşılaştırıldığında kolay uygulama, hiper-parametrelerin kendinden uyarlamalı edinimi, parametrelerin esnek olmayan çıkarımı ve çıktısının olasılıksal dağılımı gibi birçok avantaja sahiptir [47]. GSR dağılımı için birçok kovaryans fonksiyon seçeneği vardır: Rasyonel Kuadratik (RK), Kare Üstel, Matern 5/2 ve Üstel model fonksiyonları bu çalışmada kullanılmıştır.

2.2.4. Regresyon ağacı (Regression tree)

Regresyon ağacı, bağımlı ve bağımsız değişkenlerin birbirleri arasındaki ilişkileri inceleyen ve sonuçları ağaç şeklinde diyagram ile özetleyen karar ağacı algoritmasıdır. Çalışmada regresyon ağacı yöntemlerinden Coarse Tree, Medium Tree ve Fine Tree modelleri kullanılmıştır. Tablo 3'te kullanılan ağaç modelleri model esnekliği özelliklerine göre karşılaştırılmıştır [48].

2.2.5. Destek vektör makinesi (DVM) (Support vector machine)

DVM'ler istatistiksel öğrenme teorisindeki gelişmelere dayanan, veri sınıflandırma ve regresyon için kullanılan güçlü bir Makine Öğrenmesi yöntemidir. Risk minimizasyonu ilkesi üzerine geliştirilmiş olan DVM'ler,

tahmin çalışmalarında bir fonksiyonu genelleştirme hatasının üst sınırını minimize ederler [49]. Bir veri kümesi $G = \{(X_i, d_i)\}_{i=1}^N$ için X_i giriş vektörü, d_i gerçek değer ve N toplam veri sayısı olduğunda DVM fonksiyonu Eş. 4'te gösterildiği gibidir.

$$y = f(x) = w\psi(x) + b \quad (4)$$

Bu formülde $w\psi(x)$ nonlineer giriş uzayı x 'ten haritalanan özelliği ifade eder. Bu yöntemde giriş uzayından özellik uzayına lineer olmayan çekirdek fonksiyonların ($w\psi(x)$) kullanılmasına izin verilir. w ve b risk fonksiyonunun minimize edilmesi ile tahmin edilen katsayılarıdır [50]. Çalışmada DVM yöntemlerinden Doğrusal, Kuadratik, Kübik, Fine Gaussian, Medium Gaussian ve Coarse Gaussian DVM modelleri kullanılmıştır [49].

2.2.6. Topluluk öğrenme algoritmaları (Ensemble learning algorithms)

Topluluk öğrenmesi metodu tahmin modeli çıktısının tek bir temel öğrenme algoritması yerine, birden fazla öğrenme algoritması sonucu elde edilen çıktıların birleştirilmesi ile elde edilmesini amaçlayan Makine Öğrenmesi yöntemidir [51]. Ağaç tabanlı topluluk öğrenme yöntemleri de birleştirilmiş bir tahmin vermek için çok sayıda farklı ağacın tahminlerini bir araya getirmektedir [52]. Topluluk öğrenme yöntemlerinin en bilinenleri Güçlendirilmiş Karar Ağaçları (Boosted Decision Trees) ve Torbalama Karar Ağaçları (Bagged Decision Trees) yöntemleridir [53].

3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Çalışmadaki tüm talep tahmin modelleri MATLAB [54] yazılımının ilgili araç ve kütüphaneleri kullanılarak geliştirilmiştir. Talep tahmin modelleri geliştirilmeden önce veri kümesindeki tüm veriler normalize edilerek ön işleme tabii tutulmuştur. Bu sayede çalışmanın güvenilirliği ve tekrar edilebilirliği sağlanmıştır. Her bir modele ait en iyi sonucu veren ve ampirik yöntemle elde edilmiş parametrelere ait detaylar Tablo 4'te verilmiştir. Geliştirilen talep tahmin modellerinin başarımlarının karşılaştırılması için KOKH (Eş. 5), OMH (Eş. 6) ve R (Eş. 7) metrikleri kullanılmıştır. KOKH, bir yapay zekâ modeli ile yapılan tahmin işlemleri sonucu, tahmin edilen değerler ile gerçek değerler arasındaki uzaklığın bulunmasında sıklıkla kullanılan ve hatanın büyüklüğünü ölçen kuadratik bir metriktir [55]. Regresyon hattının veri noktalarından ne kadar uzakta olduğunu ölçen KOKH tahmin hatalarının standart sapmasıdır. KOKH $[0, \infty]$ aralığında değer alabilir. KOKH değeri düşük olan tahminleyiciler daha iyi performans gösterirler. OMH iki sürekli değişken arasındaki farkın ölçüsünü ifade eden değerdir [55]. OMH her bir gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey ve yatay uzaklıktır. Yönlerini dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen OMH tüm tekil hataların ortalama eşit olarak ağırlıklandırıldığı doğrusal bir büyüklüktür. OMH $[0, \infty]$ aralığında değer alabilir. Negatif yönelimli OMH değerlerine sahip tahminleyiciler daha iyi performans gösterir. R değeri bir

bağımsız değişken veya bir regresyon modelindeki değişkenler tarafından açıklanan bir bağımlı değişken için varyansın oranını temsil eden istatistiksel bir ölçüttür [56, 57]. Tahmin sistemlerinde gerçek veriler ile tahmin edilen veriler arasındaki doğruluk ilişkisini ölçer. R $[0, 1]$ aralığında değer alabilir. Korelasyon katsayısının 0'a yaklaşması değişkenler arasında zayıf ilişkinin, 1'e yaklaşması ise güçlü ilişkinin mevcut olduğunu gösterir.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (5)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (6)$$

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - O_m)^2}} \quad (7)$$

Formüllerde bulunan n değeri test için kullanılan veri noktalarının sayısı iken P_i tahmin değerini ifade etmektedir. O_i gözlenen değer, O_m ise gözlenen değerlerin ortalamasıdır.

Yapılan testlerde satış adedi bilgisi haricindeki nitelikler model girdisi, satış adedi bilgisi ise model çıktısı olarak kullanılmıştır. Geliştirilen tahmin modelleri aynı veri kümesinin farklı oranlarda bölütlenmesi ile iki defa test edilmiştir. İlk test için %90 eğitim - %10 test verisi bölütlenmesi kullanılırken; ikinci test için %75 eğitim - %25 test verisi bölütlenmesi kullanılmıştır. Her iki test için de 10-katlı çapraz doğrulama yöntemi [58] kullanılmış olup Eş. 5, Eş. 6 ve Eş. 7'de verilen metrikler ayrı ayrı ölçülmüştür. Alınan sonuçların aritmetik ortalaması model başarımı olarak kabul edilmiş ve Tablo 5'te geliştirilen tüm talep tahmin modellerinin KOKH, OMH ve R değerleri verilmiştir. Tablo 5 incelendiğinde aşağıdaki çıkarımların yapılması mümkündür:

- Talep tahmin modelleri için kullanılan tüm yöntemler tahmin edici hata oranları ve R değerlerine sahiptir.
- Yöntemler birbirleri ile kıyaslandığında Derin Öğrenme yöntemlerinin diğer yöntemlere göre daha düşük hata oranları ve daha yüksek R değerlerine sahip oldukları gözlemlenmiştir. YSA'ların ise Derin Öğrenmeden sonra en iyi sonucu veren ikinci yöntem olduğu görülmüştür.
- Yöntemler kendi aralarında kıyaslandığında ise Derin Öğrenme yöntemlerinden UKSBA modelinin, YSA'lardan İBSA'nın, GSR yaklaşımlarından Matern 5/2'nin, Regresyon Ağaçlarından Fine Tree modelinin, DVM'ler arasında Kübik modelin ve Topluluk Öğrenme modellerinden Güçlendirilmiş Karar Ağacı modelinin kendi yöntemleri içinde başarımları en yüksek modeller olduğu gözlemlenmiştir. Alınan sonuçlardan anlaşıldığı üzere klasik Makine Öğrenmesi yöntemlerine kıyasla YSA tabanlı algoritmaların talep tahmini problemi için daha uygun yöntemler olduğu görülmüştür.
- Farklı bölütleme oranları ile alınan sonuçlar kıyaslandığında %90 eğitim - %10 test bölütlenmesi ile elde edilen sonuçlarla %75 eğitim - %25 test bölütlenmesinden elde edilen sonuçların birbirine yakın olduğu fakat %90 eğitim - %10 test bölütlenmesinin nispeten daha iyi sonuçlar ürettiği görülmüştür.

Tablo 4. Model parametreleri (Model parameters)

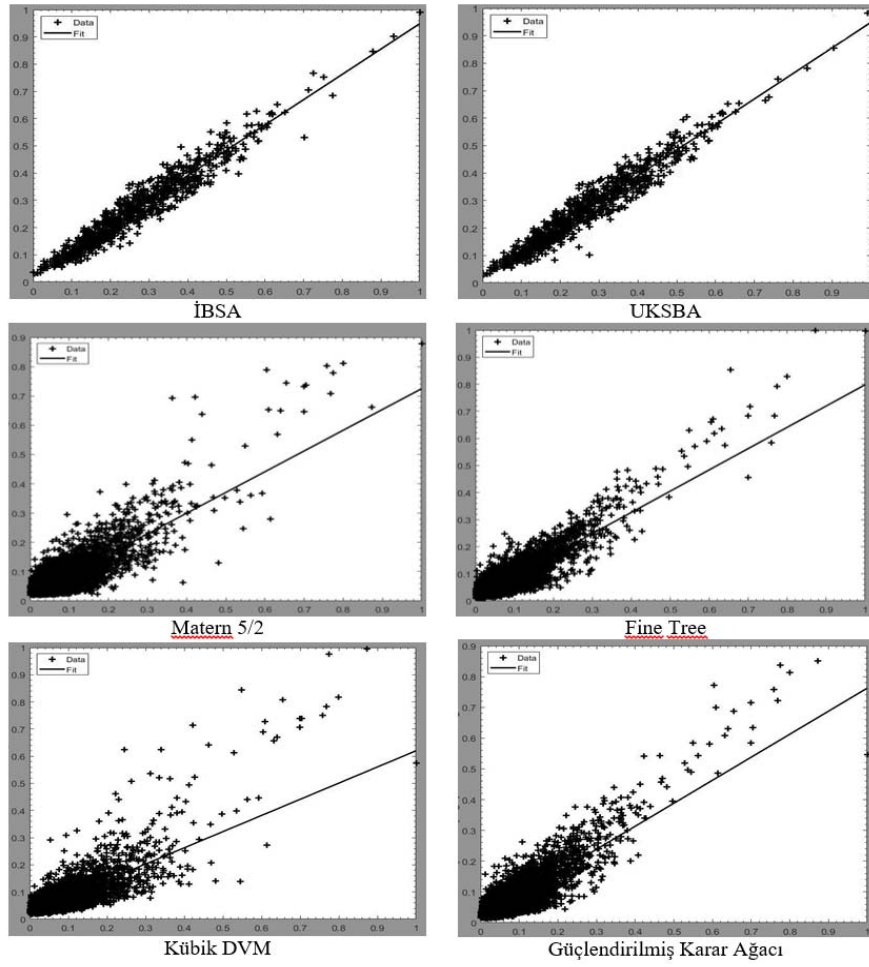
Yöntem	Model	Parametreler	
YSA	İBSA	Öğrenme Fonksiyonu: TrainSCG Uyarlama Öğrenme Fonksiyonu: LearnGDM	Transfer Fonksiyonu: Tansig Gizli Katman Sayısı: 2 / Nöron Sayısı: 10
	FUYSA	Öğrenme Fonksiyonu: Levenberg-Marquardt	Gizli Katman Sayısı: 1 Nöron Sayısı: 10
	KİSA	Öğrenme Fonksiyonu: TrainSCG Uyarlama Öğrenme Fonksiyonu: LearnGDM	Transfer Fonksiyonu: Tansig Gizli Katman Sayısı: 2 / Nöron Sayısı: 10
	ÇKA	Öğrenme Fonksiyonu: LearnPN Transfer Fonksiyonu: Hard-Limit	Gizli Katman Sayısı: 1 Nöron Sayısı: 10
	UKSBA	Öğrenme Fonksiyonu: Adam Aktivasyon Fonksiyonları: Sigmoid ve Tanh	Max Epochs: 250 / Gradyan Eşiği: 1 Başlangıç Öğrenme Oranı: 0,005 Öğrenme Oranını Düşürme Periyodu: 125
	ÇYUKSBA	Öğrenme Fonksiyonu: Adam Aktivasyon Fonksiyonları: Sigmoid ve Tanh	Gradyan Eşiği: 1 Başlangıç Öğrenme Oranı: 0,005 Öğrenme Oranını Düşürme Periyodu: 125
Derin Öğrenme	TSA	Gizli Nöron Sayısı: 200 Max Epochs: 250 Öğrenme Fonksiyonu: TrainGDM Öğrenme fonksiyonu uyarlaması: LearnGDM	Katman Sayısı: 4 Nöron Sayısı: 200
	KSA	Transfer fonksiyonu: Tansig Öğrenme Fonksiyonu: Adam Aktivasyon Fonksiyonu: Relu Konvolüsyon Katman Sayısı: 5	Uygulanan Konvolüsyonlu Filtre Sayısı: 200 Mini Yığın Büyüklüğü: 128 Max Epochs: 1000
	DOK	Öğrenme Fonksiyonu: TrainSCG Kayıp Fonksiyonu: Msesparse Transfer Fonksiyonu: Logsis Gizli Nöron Sayısı: 200	Ağırlık Düzenleme Katsayısı: 1,0000e-03 Seyreklik Düzenlemesi: 1 Seyreklik Oranı: 0,05
GSR	Matern 5/2	Kernel Fonksiyon: Matern 5/2 Kernel Ölçeği: 0,27	
	SE	Kernel Fonksiyon: Squared Exponential Kernel Ölçeği: 0,27	Temel Fonksiyon: Constant Standart Sapma: 0,19
	RK	Kernel Fonksiyon: Rational Quadratic Kernel Ölçeği: 0,27	Nümerik Parametre Optimizasyonu: True
	Üstel	Kernel Fonksiyon: Exponential Kernel Ölçeği: 0,27	
Regresyon Ağacı	Fine Tree	Min Yaprak Boyutu: 4	
	Medium Tree	Min. Yaprak Boyutu: 12	
	Coarse Tree	Min Yaprak Boyutu: 36	
	Kübik	Kernel Fonksiyon: Cubic	Kernel Ölçeği: 1 Veri Standardizasyon: True
DVM	Kuadratik	Kernel Fonksiyon: Quadratic	Epsilon: 0,021 Kutu Sınırlandırma: 0,208
	Doğrusal	Kernel Fonksiyon: Linear	
	Medium Gaussian	Kernel Fonksiyon: Gaussian Kutu Sınırlandırma: 0,208	Kernel Ölçeği: 2,20
	Coarse Gaussian	Epsilon: 0,021 Veri Standardizasyon: True	Kernel Ölçeği: 8,90 Kernel Ölçeği: 0,56
Topluluk Öğrenme	Güçlendirilmiş Karar Ağaçları Torbalama Karar Ağaçları	Minimum Yaprak Boyutu: 8 Öğrenen Sayısı: 30	

Tablo 5. 10-katlı çapraz doğrulama sonuçları (her yönteme ait en iyi model italik olarak vurgulanmıştır)
(10-fold cross-validation results (the best model for each method is highlighted in italic))

Yöntem	Model	%90 eğitim-%10 test			%75 eğitim-%25 test		
		KOKH	OMH	R	KOKH	OMH	R
YSA	<i>İBSA</i>	<i>0,0391</i>	<i>0,0253</i>	<i>0,9510</i>	<i>0,0498</i>	<i>0,0578</i>	<i>0,9145</i>
YSA	FUYSA	0,0437	0,0282	0,9395	0,0513	0,0584	0,8954
YSA	KİSA	0,0465	0,0298	0,8943	0,0546	0,0597	0,8618
YSA	ÇKA	0,0421	0,0260	0,8742	0,0521	0,0582	0,8575
Derin Öğrenme	<i>UKSBA</i>	<i>0,0353</i>	<i>0,0164</i>	<i>0,9742</i>	<i>0,0402</i>	<i>0,0387</i>	<i>0,9193</i>
Derin Öğrenme	ÇYUKSBA	0,0387	0,0218	0,9534	0,0445	0,0413	0,9054
Derin Öğrenme	TSA	0,0470	0,0259	0,8367	0,0522	0,0487	0,7965
Derin Öğrenme	KSA	0,0454	0,0292	0,7563	0,0523	0,0493	0,7106
Derin Öğrenme	DOK	0,0476	0,0298	0,7379	0,0618	0,0548	0,6794
GSR	<i>Matern 5/2</i>	<i>0,0436</i>	<i>0,0280</i>	<i>0,8291</i>	<i>0,0697</i>	<i>0,0590</i>	<i>0,7251</i>
GSR	SE	0,0438	0,0282	0,8196	0,0727	0,0596	0,7024
GSR	RK	0,0446	0,0293	0,8043	0,0759	0,0632	0,7089
GSR	Üstel	0,0445	0,0294	0,8043	0,0782	0,0647	0,6860
Regresyon Ağacı	<i>Fine Tree</i>	<i>0,0421</i>	<i>0,0245</i>	<i>0,8958</i>	<i>0,0660</i>	<i>0,0535</i>	<i>0,7890</i>
Regresyon Ağacı	Medium Tree	0,0452	0,0252	0,8692	0,0676	0,0562	0,7563
Regresyon Ağacı	Coarse Tree	0,0475	0,0293	0,8347	0,0699	0,0590	0,7387
DVM	<i>Kübik</i>	<i>0,0559</i>	<i>0,0439</i>	<i>0,6977</i>	<i>0,0691</i>	<i>0,0612</i>	<i>0,6143</i>
DVM	Kuadratik	0,0583	0,0460	0,6658	0,0686	0,0629	0,5734
DVM	Doğrusal	0,0612	0,0495	0,6489	0,0674	0,0640	0,5602
DVM	Medium Gaussian	0,0604	0,0500	0,6239	0,0710	0,0643	0,5328
DVM	Coarse Gaussian	0,0623	0,0510	0,6002	0,0721	0,0698	0,5130
DVM	Fine Gaussian	0,0736	0,0643	0,6001	0,0723	0,0705	0,5102
Topluluk Öğrenme	<i>Güçlendirilmiş Karar Ağaçları</i>	<i>0,0423</i>	<i>0,0296</i>	<i>0,8656</i>	<i>0,0542</i>	<i>0,0421</i>	<i>0,7956</i>
Topluluk Öğrenme	Torbalama Karar Ağaçları	0,0437	0,0285	0,8291	0,0543	0,0419	0,7593


Tablo 5'te verilen R ölçütü hedef değer ve model çıktıları arasındaki doğruluk ilişkisini ölçse de verilerin görselleştirilmesinin modellerin başarımını anlamakta önemli bir yeri bulunmaktadır. Şekil 10'da her yöntemin en iyi modeline ait dağılım grafikleri verilmiştir. Şekil 10'da da görüldüğü üzere, İBSA ve UKSBA modelleri birbirine çok yakın başarımlar göstermiş ve bu sayede çalışmadaki en iyi iki talep tahmin modeli olduğu sonucuna varılmıştır. Çalışmada kullanılan veri kümesinde bulunan tatil günleri, TÜFE değeri ve işsizlik oranı niteliklerinin sonuca olan etkisini incelemek amacıyla veri kümesinden bu girdiler çıkarılarak

çalışmadaki en başarılı modellerden olan UKSBA, ÇYUKSBA ve İBSA modelleri tekrar eğitilmiş ve test edilmiştir. Karşılaştırmalı sonuçlar Şekil 11'de sunulmuştur. Şekil 11'deki sonuçlar incelendiğinde tatil günleri, TÜFE değeri ve işsizlik oranı niteliklerinin model başarımını doğrudan etkilediği görülmüştür. Her üç modelde de bahsi geçen niteliklerin çıkarılmasının ardından hata oranları artmış, korelasyon katsayısı düşmüştür. Talep tahmininde alışveriş verisi dışındaki faktörleri ve TÜFE gibi Türkiye'ye özgü verileri kullanmanın tahmin modeli geliştirmedeki etkisi olumlu olarak gözlemlenmiştir.



Şekil 10. Her yönteme ait en iyi talep tahmin modelinin dağılım grafikleri (x eksenini hedef değerleri, y eksenini tahmin değerlerini göstermektedir)

(Scatter plots of the best demand forecasting model for each method (x axis shows target values, y axis shows predicted values))



Şekil 11. Tatil günleri, TÜFE değeri ve işsizlik oranı niteliklerinin UKSBA, ÇYUKSBA ve İBSA modellerinin başarımına etkisi (* ile işaretli olan satırlar niteliklerin veri kümesinden çıkarılmasından sonraki sonuçları göstermektedir) (Effects of holidays, CPI value and unemployment rate attributes on the LSTM, BLSTM and FFNN models' performance (the rows marked with * show the results after the attributes are removed from the dataset))

4. SONUÇLAR (CONCLUSIONS)

Talep tahmini günlük hayatta ve bilimsel çalışmalarda sıklıkla çalışılan bir konu olmakla birlikte e-perakende sektörünün hızlı gelişimi ile süpermarket alışverişlerinin çevrimiçi platformlardan yapılmasına bağlı olarak söz konusu alandaki talep tahmini uygulamaları son yıllarda önem kazanmıştır. Süpermarket verileri kullanılan önceki talep tahmin çalışmaları incelendiğinde geliştirilen modellerin hem veri hem de yöntem yönünden oldukça kısıtlı olduğu, başarımlarının tatmin edici düzeyde olmadığı ve alışveriş verisi dışında talebe etki eden faktörlerin çoğunlukla göz ardı edildiği görülmüştür.

Bu çalışmada yerel bir süpermarketin 2019-2020 tarihlerini kapsayan iki yıllık internet alışverişi satış verileri ile birlikte TÜFE, işsizlik oranı ve tatil günleri verileri kullanılarak oluşturulan veri kümesi üzerinde ürün satış adedini tahmin eden Makine Öğrenmesi ve Derin Öğrenme tabanlı modeller geliştirilmiştir. Çalışmada geliştirilen talep tahmin modelleri arasında Derin Öğrenme yöntemlerinden UKSBA ve ÇYUKSBA ile YSA yöntemlerinden İBSA modellerinin KOKH, OMH ve R ölçütleri açısından en iyi sonuçları verdiği gözlemlenmiştir. Geliştirilen talep tahmin modellerinde kullanılan alışveriş verisi dışındaki niteliklerin (tatil günleri, TÜFE değeri ve işsizlik oranı) model başarımı üzerindeki etkisi ölçülmüş ve tüm ölçütlerin başarısına yüksek oranlarda katkı sağladıkları gözlemlenmiştir.

Çalışmada geliştirilen talep tahmin modelleri, e-perakende sektöründe faaliyet gösteren web ve mobil uygulamalarda kullanılarak sektördeki açığı kapatma potansiyeline sahiptir. Gelecekteki çalışmalarda veri kümesinde bulunmayan fakat talebe etki ettiği öngörülen bağımsız değişkenleri saptayarak veri kümesini geliştirmek ve bu çalışmada geliştirilen yirmi dört modelin yanı sıra farklı modellerle tahmin doğruluğunun artırılması amaçlanmaktadır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma, Mersin Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir (Proje Kodu: 2019-3-TP2-3745). Çalışmada kullanılan veriler için Groseri Gıda ve İhtiyaç Maddeleri Tic. Ltd. Şti.'ne teşekkür ederiz.

KAYNAKLAR (REFERENCES)

- Öztürk, İ., Türkiye'de perakende sektörü, *Journal of Social Sciences*, 3 (1), 69-81, 2006.
- Tevetoğlu, M., Kel, H.A., COVID-19 pandemisi, dijital perakendecilik ve sözleşme hukukuna etkisi, *Yapay Zeka Çağında Hukuk*, 1 (1), 66-78, 2021.
- Yücesoy, M. Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini, *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul*, 2011.
- Torun H., Canbulut G., Analysis of two stage supply chain coordination under fuzzy demand, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1315-1328, 2019.
- Ünlü, R., Zaman serileri tahminlenmesinde makine öğrenimi ve derin öğrenme tekniklerinin kıyaslanması: Türkiye elektrik üretimi için en iyi tahmin modelinin seçilmesine yönelik bir vaka çalışması, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23 (2), 359-370, 2019.
- Rahman, S., Rabiul Alam, M.G., Mahbubur Rahman, M., Deep Learning Based Ensemble Method for Household Energy Demand Forecasting of Smart Home, *International Conference on Computer and Information Technology*, Dakka-Bangladeş, 18-20 Aralık, 19472446, 2019.
- Es H., Kalender Y.F., Hamzaçebi C., Forecasting the net energy demand of Turkey by artificial neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29 (3), 495-504, 2014.
- Sönmez, O., Zengin, K., Yiyecek ve içecek işletmelerinde talep tahmini: yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma, *European Journal of Science and Technology*, Özel Sayı, 302-308, 2019.
- Yergök, D., Acı, M., An alternative approach for daily demand prediction in mass meal production: Regression Learner, *European Journal of Science and Technology*, Özel Sayı, 64-73, 2019.
- Huber, J., Stuckenschmidt, H., Daily retail demand forecasting using machine learning with emphasis on calendric special days, *International Journal of Forecasting*, 36 (4), 1420-1438, 2020.
- Satoglu, S.I., Eren, U., Perakende Giyim Sektöründe Yapay Sinir Ağları ile Talep Tahmini, *Endüstri ve İşletme Mühendisliği Kurultayı, İstanbul-Türkiye*, 1-7, 17-18 Kasım, 2017.
- Arsılkaya, S., Bir Lojistik Firmasında Zaman Serileri Analizi ve Yapay Sinir Ağları ile Talep Tahminin Karşılaştırılması, *International Symposium on Innovative Approaches in Engineering and Natural Sciences*, 239-245, 22-24 Kasım, 2019.
- Kaya, K.S., Yıldırım, Ö., A prediction model for automobile sales in turkey using deep neural network, *Endüstri Mühendisliği*, 31 (1), 57-74, 2020.
- Türk, E., Kiani, F., Yapay sinir ağları ile talep tahmini yapma: Beyaz eşya üretim planlaması için YSA uygulaması, *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1 (1), 30-37, 2019.
- Law, R., Li, G., Fong, D.K.C., Han, X., Tourism demand forecasting: A deep learning approach, *Annals of Tourism Research*, 75, 410-423, 2019.
- Claveria, O., Monte, E., Torra, S., Regional tourism demand forecasting with machine learning models: Gaussian process regression vs. neural network models in a multiple-input multiple-output setting, *SSRN Electronic Journal*, 1 (1), 1-26, 2018.
- Xu, C., Ji, J., Liu, P., The station-free sharing bike demand forecasting with a deep learning approach and large-scale datasets, *Transportation Research Part C: Emerging Technologies*, 95, 47-60, 2018.
- Jiang, S., Chin, K.S., Wang, L., Qu, G., Tsui, K.L., Modified genetic algorithm-based feature selection

- combined with pre-trained deep neural network for demand forecasting in outpatient department, *Expert Systems with Applications*, 82, 216-230, 2017.
19. Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification, *Computer Methods and Programs in Biomedicine*, 171, 1-10, 2019.
 20. Du, X.F., Leung, S.C.H., Zhang, J.L., Lai, K.K., Demand forecasting of perishable farm products using support vector machine, *International Journal of Systems Science*, 44 (3), 556-567, 2013.
 21. Slimani, I., El Farissi, I., Achchab, S., Artificial Neural Networks for Demand Forecasting: Application Using Moroccan Supermarket Data, *International Conference on Intelligent Systems Design and Applications, Porto-Portekiz*, 266-271, 14-16 Kasım, 2016.
 22. Qu, T., Zhang, J.H., Chan, F.T.S., Srivastava, R.S., Tiwari, M.K., Park, W.Y., Demand prediction and price optimization for semi-luxury supermarket segment, *Computers and Industrial Engineering*, 113, 91-102, 2017.
 23. Neelakantam, G., Onthoni, D.D., Sahoo, P.K., Fog computing enabled locality based product demand prediction and decision making using reinforcement learning, *Electronics*, 10 (3), 1-16, 2021.
 24. Bellendorf, J., Mann, Z.Á., Classification of optimization problems in fog computing, *Future Generation Computer Systems*, 107, 158-176, 2020.
 25. Kaggle Supermarket sales, <https://www.kaggle.com/aungpyaeap/supermarket-sales>, Yayın tarihi Mayıs 27, 2019. Erişim tarihi Aralık 12, 2021.
 26. Wolters, J., Huchzermeier, A., Joint in-season and out-of-season promotion demand forecasting in a retail environment, *Journal of Retailing*, Baskıda, DOI: 10.1016/j.jretai.2021.01.003, 2022.
 27. BigMart Sales Data, <https://www.kaggle.com/brijbhushannanda1979/bigmart-sales-data>, Yayın tarihi Ocak 16, 2018. Erişim tarihi Aralık 12, 2021.
 28. Malik, N., Singh, K., Sales prediction model for Big Mart, *Parichay: Maharaja Surajmal Institute Journal of Applied Research*, 3 (1), 22-32, 2020.
 29. Sekban, J., Applying machine learning algorithms in sales prediction, *Yüksek Lisans Tezi, Kadir Has Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul*, 2019.
 30. Agbonlahor, O.V., A comparative study on machine learning and deep learning techniques for predicting big Mart item outlet sales, *Yüksek Lisans Tezi, Dublin Business School, Dublin*, 2020.
 31. Punam, K., Pamula, R., Jain, P.K., A Two-Level Statistical Model for Big Mart Sales Prediction, *International Conference on Computing, Power and Communication Technologies, Yeni Delhi-Hindistan*, 617-620, 28-29 Eylül, 2018.
 32. Çelik, Ş., Şengül, T., Şengül, Y.A., İnci, H., Tüketici fiyat indeksini etkileyen bitkisel ve hayvansal üretim değerlerinin çok değişkenli uyarlanabilir regresyon uzanımları ile incelenmesi: Türkiye örneği, *Journal of Awareness*, 3 (5), 399-408, 2018.
 33. Uysal, D., Erdoğan, S., Enflasyon ile İşsizlik Oranı Arasındaki İlişki ve Türkiye Örneği (1980-2002), *Sosyal Ekonomik Araştırmalar Dergisi*, 3 (6), 35-46, 2003.
 34. Graupe, D., Principles of Artificial Neural Networks, Editör: Chen, W.K., World Scientific Publishing, Hackensack, NJ, A.B.D., 3, 9-17, 2013.
 35. Razavi, S., Tolson, B.A., A new formulation for feedforward neural networks, *IEEE Transactions on Neural Networks*, 22 (10), 1588-1598, 2011.
 36. MATLAB Function fitting neural network, <https://www.mathworks.com/help/deeplearning/ref/fitnet.html>, Yayın tarihi Mart 13, 2021. Erişim tarihi Aralık 12, 2021.
 37. Alkhasawneh, M.S., Tay, L.T., A hybrid intelligent system integrating the cascade forward neural network with elman neural network, *Arabian Journal for Science and Engineering*, 43 (12), 6737-6749, 2018.
 38. Öztemel, E., Yapay Sinir Ağları, Papatya Bilim Yayınevi, İstanbul, Türkiye, 59-74, 2012.
 39. Şeker, A., Diri, B., Balık, H.H., A review about deep learning methods and applications, *Gazi Journal of Engineering Sciences*, 3 (3), 47-64, 2017.
 40. Babu, G.S., Zhao, P., Li, X.L., Deep convolutional neural network based regression approach for estimation of remaining useful life, *International Conference on Database Systems for Advanced Applications, Dallas-A.B.D.*, 214-228, 16-18 Nisan, 2016.
 41. Goodfellow, I., Bengio, Y., Courville, A., Deep Learning, Editör: Dietterich, T., The MIT Press, Massachusetts, A.B.D., 2016.
 42. Şişmanoğlu, G., Koçer, F., Önde, M.A., Şahingöz, O.K., Derin öğrenme yöntemleri ile borsada fiyat tahmini, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9 (1), 434-445, 2020.
 43. Sherratt, F., Plummer, A., Irvani, P., Understanding LSTM network behaviour of imu-based locomotion mode recognition for applications in prostheses and wearables, *Sensors*, 21 (4), 1-23, 2021.
 44. Şeker, A., Yüksek, A.G., Stacked autoencoder method for fabric defect detection, *Cumhuriyet Science Journal*, 38 (2), 342-342, 2017.
 45. Liu, K., Hu, X., Wei, Z., Li, Y., Jiang, Y., Modified gaussian process regression models for cyclic capacity prediction of lithium-ion batteries, *IEEE Transactions on Transportation Electrification*, 5 (4), 1225-1236, 2019.
 46. Fang, D., Zhang, X., Yu, Q., Jin, T.C., Tian, L., A novel method for carbon dioxide emission forecasting based on improved Gaussian processes regression, *Journal of Cleaner Production*, 173, 143-150, 2018.
 47. Zhao, J., Guo, H., Han, M., Tang, H., Li, X., Gaussian process regression for prediction of sulfate content in lakes of China, *Journal of Engineering and Technological Sciences*, 51 (2), 198-215, 2019.
 48. MATLAB, Choose Regression Model Options, <https://www.mathworks.com/help/stats/choose->

- regression-model-options.html, Yayın tarihi Mart 15, 2018. Erişim tarihi Aralık 12, 2021.
49. Pisner, D.A., Schnyer, D.M., Support Vector Machine, Machine Learning: Methods and Applications to Brain Disorders, Cilt 7, Editör: Mechelli, A., Academic Press, Londra, İngiltere, 101-121, 2019.
 50. Awad, M., Khanna, R., Awad, M., Khanna, R., Support Vector Regression, Efficient Learning Machines, Apress, 4, 67-80, 2015.
 51. Onan, A., A clustering based classifier ensemble approach to corporate bankruptcy prediction, Alphanumeric Journal, 6 (2), 365-376, 2018.
 52. Yılmaz, H., Random forests yönteminde kayıp veri probleminin incelenmesi ve sağlık alanında bir uygulama, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Sağlık Bilimleri Enstitüsü, Eskişehir, 2014.
 53. Mosavi, A., Sajedi Hosseini, F., Choubin, B., Goodarzi, M., Dineva, A.A., Rafiei Sardooi, E., Ensemble boosting and bagging based machine learning models for groundwater potential prediction, Water Resources Management, 35 (1), 23-37, 2021.
 54. Machine Learning with MATLAB, <https://www.mathworks.com/solutions/machine-learning.html>, Yayın tarihi Mart 15, 2018. Erişim tarihi Aralık 12, 2021.
 55. Chai, T., Draxler, R.R., Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature, Geoscientific Model Development, 7 (3), 1247-1250, 2014.
 56. Cleophas, T.J., Zwinderman, A.H., Bayesian Pearson Correlation Analysis, Modern Bayesian Statistics in Clinical Research, Cilt 11, Springer International Publishing, Cham, İsviçre, 111-118, 2018.
 57. Asuero, A.G., Sayago, A., González, A.G., The correlation coefficient: An overview, Critical Reviews in Analytical Chemistry, 36 (1), 41-59, 2007.
 58. Karayığıt, H., Acı, Ç.İ., Akdağlı, A., Detecting abusive Instagram comments in Turkish using convolutional neural network and machine learning methods, Expert Systems with Applications, 174 (1), 114802, 2021.

