



MOBİLYA SEKTÖRÜNDE SATIŞ TAHMİNİ: YİNELEMELİ SİNİR AĞI MODELLERİNİN KARŞILAŞTIRMALI ANALİZİ

Onur ŞAHİN^{1*}, Burakhan ÇUBUKÇU²

¹ Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Tezli Yüksek Lisans Öğrencisi, Bilecik, Türkiye

² Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Bilecik, Türkiye

Anahtar Kelimeler

*Yinelemeli Sinir Ağı,
Zaman Serisi Analizi,
Satış Tahmini,
Derin Öğrenme,
Makine Öğrenmesi,
LSTM.*

Öz

Günümüz iş dünyasında, şirketlerin başarılı bir şekilde faaliyet göstermeleri ve sürdürülebilir bir büyüme elde etmeleri, gelecekteki satışları doğru bir şekilde tahmin etmelerine bağlıdır. Bu bağlamda, stratejik planlama ve kaynak yönetimi süreçlerinde doğru ve güvenilir tahminlerin yapılması kritik bir öneme sahiptir. Bu çalışma, Yinelemeli Sinir Ağları (RNN) modellerini kullanarak bir mobilya firmasının gelecekteki satış tutarlarını tahmin etmeyi hedeflemektedir. Eğitim sürecinde Long Short-Term Memory (LSTM), Bidirectional LSTM (BiLSTM), Gated Recurrent Unit (GRU), Bidirectional GRU (BiGRU) gelişmiş yinelemeli sinir ağı modelleri kullanılmıştır. Çalışma, veri hazırlama süreçlerinden model eğitime kadar olan adımları detaylı bir şekilde açıklamaktadır. Her bir modelin performansı, R-kare, Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi ölçütler kullanılarak kapsamlı bir değerlendirmeye tabi tutulmuştur. Analiz sonuçlarına göre, BiGRU yöntemi tekrarlayan işlemlerde 0.94 R-kare skoru ile en yüksek doğruluğa sahip model olarak belirlenmiştir. Bu çalışma, yinelemeli sinir ağı modellerini kıyaslayarak şirketlerin satış tahmin süreçlerine nasıl entegre edilebileceği konusunda katkı sunmayı amaçlamaktadır.

SALES FORECASTING IN FURNITURE INDUSTRY: COMPARATIVE ANALYSIS OF RECURRENT NEURAL NETWORK MODELS

Keywords

*Recurrent Neural Network,
Time Series Analysis,
Sales Forecasting,
Deep Learning,
Machine Learning,
LSTM.*

Abstract

In today's business world, companies' successful operation and sustainable growth depend on accurately predicting future sales. In this context, making accurate and reliable predictions is of critical importance in strategic planning and resource management processes. This study aims to predict the future sales amounts of a furniture company using Recurrent Neural Networks (RNN) models. Long Short-Term Memory (LSTM), Bidirectional LSTM (BiLSTM), Gated Recurrent Unit (GRU), Bidirectional GRU (BiGRU) advanced recurrent neural network models were used in the training process. The study explains the steps from data preparation processes to model training in detail. The performance of each model was subjected to a comprehensive evaluation using metrics such as R-squared, Mean Absolute Error (MAE), Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). According to the analysis results, the BiGRU method was determined as the model with the highest accuracy with an R-squared score of 0.94 in repetitive operations. This study aims to contribute to how companies can integrate recurrent neural network models into their sales forecasting processes by comparing them.

Alıntı / Cite

Şahin, O., Çubukçu, B., (2024). Mobilya Sektöründe Satış Tahmini: Yinelemeli Sinir Ağı Modellerinin Karşılaştırmalı Analizi, Mühendislik Bilimleri ve Tasarım Dergisi, 12(4), 686-706.

Yazar Kimliği / Author ID (ORCID Number)

O. Şahin, 0009-0000-8955-658X
B. Çubukçu, 0000-0003-0480-1254

Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	07.02.2024
Revizyon Tarihi / Revision Date	08.09.2024
Kabul Tarihi / Accepted Date	22.10.2024
Yayın Tarihi / Published Date	25.12.2024

* İlgili yazar / Corresponding author: onur2000sahin@outlook.com, +90-507-355-3623

SALES FORECASTING IN FURNITURE INDUSTRY: COMPARATIVE ANALYSIS OF RECURRENT NEURAL NETWORK MODELS

Onur SAHİN^{1†}, Burakhan CUBUKCU²

¹ Bilecik Seyh Edebali University, Institute of Graduate Education, Graduate Student, Bilecik, Türkiye

² Bilecik Seyh Edebali University, Faculty of Engineering, Department of Computer Engineering, Bilecik, Türkiye

Highlights

- 2023 sales forecasts were made with LSTM, BiLSTM, GRU and BiGRU models.
- Error values were recorded throughout the training processes of the models.
- Predictions were compared with actual sales data and model performances were evaluated.
- Result of R-squared metrics are as follows: LSTM 90.7%, BiLSTM 93.2%, GRU 89.9%, BiGRU 94.0%.

Graphical Abstract

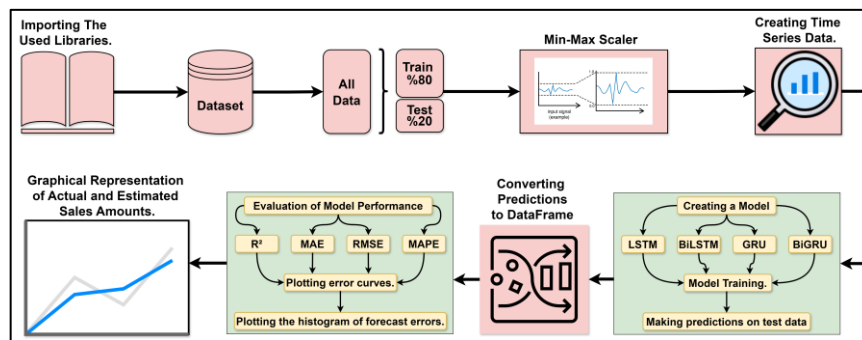


Figure. Diagram with Working Step

Purpose and Scope

The aim of this study is to evaluate the performance of deep learning models on time series data. The dataset contains daily order data of a furniture company. The scope of the work includes the use of different recurrent neural network architectures such as LSTM, BiLSTM, GRU and BiGRU)

Design/Methodology/Approach

In this study, a methodology was developed using deep learning models such as LSTM, BiLSTM, GRU and BiGRU to make sales forecasts with time series data.

Findings

When the average of repeated operations is taken, the performances of deep learning methods according to the R-squared metrics are as follows: LSTM 90.7%, BiLSTM 93.2%, GRU 89.9%, BiGRU 94.0%.

Research Limitations/Implications

It may be possible to increase the performance rate with hybrid versions of deep learning methods in further studies.

Practical Implications

In this study, real sales data of a furniture company between 2022-2023 were used. The outputs of the implemented deep learning models show the practical results of the study. The results of these models can help the company predict future sales demands and significantly improve planning processes.

Social Implications

It helps corporate companies anticipate future sales demands and optimize their operational strategies.

Originality

The originality of this work is that it is based on detailed comparisons that will help choose the most suitable model for a specific business problem. In addition, the data set used consists of sales data provided by a company operating in the furniture industry, and this data set has not been used in the literature before.

[†] Corresponding author: onur2000sahin@outlook.com, +90-507-355-3623

1. Giriş (Introduction)

Yapay zekâ, insan zekâsını taklit eden ve karmaşık problemleri çözmek için algoritmalar ve matematiksel modeller kullanan bir bilgisayar bilim dalıdır (Fetzer, 1990). Özellikle son yıllarda, yapay zeka alanındaki hızlı gelişmeler, gerçek dünya problemlerine yenilikçi çözümler sunma potansiyeliyle dikkat çekmektedir (Öztürk ve Şahin, 2018). Bu gelişmelerin merkezinde ise, derin öğrenme (deep learning) olarak bilinen bir makine öğrenmesi alt alanı yer almaktadır. Derin öğrenme, insan beynindeki sinir ağlarından ilham alan ve büyük veri kümeleri üzerinde eğitilen yapay sinir ağları (YSA) kullanarak karmaşık örüntüleri öğrenmeyi amaçlar (Lecun, Bengio ve Hinton, 2015).

Derin öğrenme, görüntü tanıma (Khasim, Ghosh, Rahat, Shaik ve Yesubabu, 2024; Şermet ve Pacal, 2024), doğal dil işleme (ChenShijie, ZhangYu ve YangQiang, 2024), sağlık hizmetleri (Öztatlıcı, Eroğlu, Öztatlıcı ve Göl, 2024; Pacal, 2024) gibi çeşitli alanlarda önemli sonuçlar elde etmiştir. Örneğin, derin öğrenme modelleri, tıbbi görüntülerdeki tümörleri tespit etmede bazı durumlarda radyologlardan daha başarılı olabilirken, doğal dil işleme alanında ise, çeviri, metin üretimi ve soru cevaplama gibi görevlerde insan benzeri performans sergileyebilmektedir. Derin öğrenmenin bu başarısı, farklı sektörleri de etkisi altına almış ve şirketlere operasyonlarını optimize etmeleri, verimliliklerini artırmaları ve daha iyi kararlar almaları için yeni yollar sunmuştur.

Mobilya sektörü, tüketici ihtiyaçlarına yanıt veren ve yaşam tarzı değişiklikleriyle doğrudan ilişkili olan bir sektördür. Bu sektördeki satış rakamlarını tahmin etmek, pazar trendlerini anlamak ve gelecekteki talebi öngörmek açısından oldukça önemlidir. Bu tahminler, tüketici davranışlarının değişimini anlamak, pazar rekabetini yönetmek, stok seviyelerini optimize etmek ve üretim süreçlerini planlamak için temel bir yol haritası sağlar. Bu yol haritasını oluşturabilmek için zaman içerisindeki satış rakamlarını analiz etmek gerekmektedir.

Zaman serisi analizi, veri bilimi disiplini içinde özellikle satış tahminleri gibi uygulamalarda sıklıkla kullanılan bir metodoloji olarak kabul edilmektedir. Zaman serisi verileri, genellikle belirli bir zaman aralığındaki bir değişkenin sürekli ölçümlerini içerir (Parmezan, Souza ve Batista, 2019). Bu verilerin analizi, işletmelerin geçmiş performanslarını objektif bir şekilde değerlendirmelerine, gelecekteki talepleri öngörmelerine ve operasyonel stratejilerini optimize etmelerine yardımcı olur. Bu analitik yaklaşım, zaman içindeki trendleri, mevsimsel etkileri ve diğer önemli desenleri tespit ederek, karar vericilere bilgi sağlama ve verimliliklerini artırma konusunda değerli bir araç sunar.

Karar vericilere bilgi sağlayabilen zaman serisi analizi, özellikle satış tahminleri gibi uygulamalarda popüler bir metodoloji haline gelmiştir. Bu alanda yapay zekâ teknikleri, geleneksel istatistiksel yöntemlere ek olarak kullanılarak daha etkili ve hassas sonuçlar elde edilmesine katkı sağlamaktadır. Yapay zekâ modelleri, zaman içindeki karmaşık desenleri tanımlayabilme ve öğrenebilme yetenekleri ile öne çıkar. RNN, zaman serisi verilerini işlemek için özel olarak tasarlanmış yapay zekâ modelleridir. RNN'ler, önceki zaman adımlarından gelen bilgileri hafızalarında saklayarak gelecekteki değerleri tahmin etme yeteneğine sahiptir. Ancak, basit RNN yapıları, uzun vadeli bağımlılıkları başarılı bir şekilde öğrenme konusunda sınırlı kalabilir. (Agarwal, Mahajan, Shrotriya ve Shekhawat, 2024) Bu sınırlamaları aşmak için Gelişmiş RNN yapıları kullanılmaktadır. Bunlar arasında LSTM (Hochreiter ve Schmidhuber, 1997), BiLSTM (Graves ve Schmidhuber, 2005), GRU (Chung, Gulcehre, Cho ve Bengio, 2014) ve BiGRU (Wang vd., 2017) gibi modeller bulunmaktadır. LSTM ve GRU gibi yapılar, özellikle uzun vadeli bağımlılıkları daha iyi öğrenebilme yetenekleri ile dikkat çeker (Zhang, Zeng ve Starly, 2021).

LSTM, önceki bilgileri hafızasında saklayabilme ve unutabilme yetenekleri ile uzun vadeli bağımlılıkları modellendirir. BiLSTM, hem geçmiş hem de gelecek bilgileri kullanarak daha kapsamlı bir bağlam sağlar. GRU, LSTM'ye benzer bir yapıya sahiptir ancak daha az parametre kullanarak daha hızlı eğitim ve daha az bellek tüketimi sağlar. BiGRU ise hem geçmiş hem de gelecek bilgileri içeren bir bağlamı değerlendirir. Bu gelişmiş yapay zekâ modelleri, zaman serisi verilerinin karmaşıklığına daha iyi uyum sağlayarak daha doğru tahminler yapabilir. Dolayısıyla, işletmeler, satış tahminleri gibi kritik uygulamalarda bu modelleri kullanarak analizlerini daha verimli hale getirebilirler.

Bu çalışmada, RNN modelleri kullanılarak mobilya sektöründe bir firmaya ait toplam satış rakamlarının tahmin edilmesi ve kullanılan RNN yöntemlerinin başarımlarının kıyaslanması hedeflenmektedir. Çalışmanın ilk aşaması, satış veri setinin detaylı bir şekilde incelenmesi ve ön işleme sürecidir. Bu aşamada, tarih ve net fiyat gibi kritik değişkenlerin yanı sıra, veri setindeki gürültüyü azaltmak ve modele uygun hale getirmek adına çeşitli ön işleme adımları uygulanır. Bu adımlar, veri setinin içerdiği bilgilerin doğruluğunu artırmak, anlamlı desenleri ortaya çıkarmak ve model performansını optimize etmek amacıyla gerçekleştirilir. Ön işleme adımları arasında veri normalizasyonu, zaman serisi verisinin uygun bir şekilde bölünmesi (eğitim ve test olarak) ve ölçeklendirilmesi, gürültünün giderilmesi ve eksik veri değerlerinin ele alınması yer almaktadır.

Her bir modelin gerçek ve tahmini satış değerleri ve eğitim süreçlerine ait hata eğrileri hesaplanarak grafikler halinde incelenir. Bu grafikler, modellerin performansını anlamak, karşılaştırmak ve her bir modelin avantajlarını ile zorluklarını belirlemek için önemli bir araç sağlar. Görsel analiz, modelin zaman içindeki tahmin başarısını görmek, eğitim süreçlerindeki hata eğrilerini izlemek ve modelin genel performansını değerlendirmek için etkili bir yöntemdir. Bu grafikler, karmaşık veri ilişkilerini anlama, modelin doğruluğunu değerlendirme ve iyileştirme fırsatlarını belirleme konularında değerli bilgiler sunar. Bu kapsamda yapılan çalışma ile literatüre şu katkılar sağlanması hedeflenmektedir:

- Farklı RNN Modellerinin Karşılaştırılması: Çalışmada, LSTM, BiLSTM, GRU ve BiGRU gibi dört farklı RNN modeli kullanılarak mobilya sektöründe satış tahmini gerçekleştirilmiştir. Bu modellerin performansları R-kare, MAE, RMSE ve MAPE gibi farklı metrikler kullanılarak karşılaştırılmış ve her bir modelin güçlü ve zayıf yönleri ortaya konmuştur.
- Mobilya Sektörüne Özgü Uygulama: Çalışmada kullanılan veri seti, mobilya sektöründe faaliyet gösteren bir firmaya ait gerçek satış verilerinden oluşmaktadır. Bu sayede, çalışma sonuçları mobilya sektörü için daha gerçekçi ve uygulanabilir bilgiler sunmaktadır.
- Gelecek Satış Tahminlerinde Yol Gösterici: Çalışma sonuçları, mobilya sektöründe faaliyet gösteren firmaların gelecekteki satışlarını tahmin etmelerinde kullanabilecekleri en uygun RNN modelini belirlemelerine yardımcı olacaktır. Özellikle Bidirectional yapıya sahip modellerin daha başarılı sonuçlar verdiği gözlemlenmiştir.
- Literatürdeki Eksikliği Giderme: Mobilya sektöründe RNN modelleri kullanılarak yapılan satış tahmini çalışmaları sınırlıdır. Bu çalışma, literatürdeki bu eksikliği gidererek gelecek çalışmalara ışık tutmayı hedeflemektedir.

Bu katkılar, çalışmanın hem akademik alana hem de mobilya sektörüne katkılar sağlayacağını göstermektedir. Çalışmanın ilerleyen bölümlerinde sırasıyla kaynak araştırması, materyal ve yöntem, deneysel sonuçlar, sonuç ve tartışma bölümleri sunulmaktadır.

2. Kaynak Araştırması (Literature Survey)

Mobilya sektörü, dünya genelinde önemli bir ekonomik sektör olarak öne çıkmaktadır (Gürpınar ve Barca, 2007). Küresel rekabet nedeniyle, mobilya şirketleri sadece fiyat rekabetiyle değil, aynı zamanda tasarım yenilikleri, sürdürülebilirlik ve müşteri hizmeti gibi faktörlere odaklanarak stratejik kararlar almak zorundadırlar. Satış tahmini, mobilya sektöründe faaliyet gösteren işletmelerin rekabet avantajını artırmak, stok yönetimini optimize etmek ve operasyonel süreçlerini daha etkili bir şekilde planlamak adına kritik bir öneme sahiptir.

Mobilya sektörü, değişen tüketici talepleri, ekonomik dalgalanmalar ve pazar koşullarındaki belirsizlik gibi faktörlerle sürekli olarak etkileşim halindedir (Jakobsson ve Svahn, 2023). Mobilya satışlarını tahmin etmek için doğru modelin seçilmesi, işletmelerin rekabet avantajını sürdürmeleri açısından kritik bir adımdır. Çeşitli sektör analizleri, mobilya satışlarını etkileyen faktörleri ve bu faktörler arasındaki ilişkileri ortaya koymaktadır. Bu bağlamda, literatürde mobilya ve benzer sektörlerde satış tahmini ile ilgili yapılmış çalışmalar incelenmiş ve bu alandaki önemli bulgular derlenmiştir. Zaman serisi analizi, regresyon analizi, yapay zekâ temelli modeller ve makine öğrenimi yöntemleri, satış tahmininde sıkça kullanılan yaklaşımlar arasındadır. Bu modellerin avantajları, dezavantajları ve uygulama alanları üzerine yapılan çalışmalar, mobilya sektöründeki işletmelerin bu modeller arasında en uygun olanı seçmelerine yardımcı olabilir.

Çalışmanın bu bölümü, mobilya sektöründe gelecek satışlarını tahmin etmeye yönelik bir literatür araştırması sunmaktadır. Bu amaç doğrultusunda, satış tahminleri üzerine yapılmış çalışmaların bulunduğu benzer sektörlerdeki literatür detaylı bir şekilde incelenmiştir. Özellikle otomotiv, elektronik, beyaz eşya, gıda, çelik ve giyim gibi sektörlerdeki önceki araştırmalar, başarılı satış tahmin modellerinin geliştirilmesi konusunda sağlam bir temel oluşturabilir. Bu sektörel literatürde elde edilen bulgular, mobilya sektöründe karşılaşılabilecek benzer zorluklarla ilgili bilgi sağlayarak, çalışmanın temel sorularından birini ele almaktadır. Ardından, mobilya sektöründe yapılmış olan önceki çalışmalara odaklanılacaktır. Bu bağlamda, pazar trendleri, tüketici davranışları ve ekonomik faktörler gibi özel sektör dinamiklerini anlamak amacıyla bu sektördeki literatür kapsamlı bir şekilde gözden geçirilecektir. Mobilya sektörünün kendine özgü özellikleri ve bu sektördeki satış tahmin modellerinin geliştirilmesine yönelik önceki çabalar, çalışmanın odak noktalarını şekillendirerek gelecek tahmin modellerini güçlendirecektir.

Tablo 1, literatürde farklı sektörlerde ve durumlarda gerçekleştirilmiş zaman serisi tahmin çalışmalarını özetleyerek kullanılan yöntemleri ve bu yöntemlerin başarılarını göstermektedir. Her bir çalışma, belirli bir sektördeki tahmin problemini ele almakta ve farklı yöntemlerin etkinliğini karşılaştırmaktadır.

Tablo 1. Literatürde farklı sektörlerde/durumlarda kullanılan tahmin modelleri ve performansları (Forecast models and their performances used in literature in different sectors/situations)

ÇALIŞMA	TAHMİN KONUSU	YÖNTEM	BAŞARI ÖLÇÜTÜ VE SKOR	
Yücesan (Yücesan, 2018)	Beyaz Eşya	ARIMAX ARIMA YSA	R ² - 0,9152 R ² - 0,5588 R ² - 0,8690	
Sönmez ve Zengin (Sönmez ve Zengin, 2019)	Yiyecek ve İçecek	YSA Çoklu Regresyon	R ² - 0,9666 R ² - 0,9130	
Chen vd. (Chen vd., 2024)		ARIMA Sezonsal ARIMA SVR LightGBM LSTM GRU GRU-LightGBM	MAPE - 8,41 MAPE - 7,48 MAPE - 6,94 MAPE - 6,60 MAPE - 5,87 MAPE - 5,74 MAPE - 4,11	
Acar (Acar, 2022)	Enerji (Kömür)	SARIMAX Holt-Winters FB-Prophet XGBoost	R ² - 0,8500 R ² - 0,8600 R ² - 0,4600 R ² - 0,7100	
Ecemiş ve Irmak (Ecemiş ve Irmak, 2018)	Paslanmaz Çelik	Destek Vektör Regresyon YSA	MAPE - 6,21 MAPE - 5,53	
Yılmaz ve Tosun (Yılmaz ve Tosun, 2020)	Konut	YSA	MSE - 0,0076	
Civelek (Civelek, 2021)	Otomotiv	YSA	MAPE - 25,30	
Karaatlı vd. (Karaatlı, Helvacıoğlu ve Tokgöz, 2012)		YSA	MAPE - 16,82	
Yurtsever (Yurtsever, 2022)		Long Short-Term Memory	MAPE - 10,15	
Hülsmann (Hülsmann, Borscheid, Friedrich ve Reith, 2011)		Ordinary Least Squares Kantil Regresyon Destek Vektör Makineleri Karar Ağaçları K-En Yakın Komşu Rastgele Orman	MAPE - 28,89 MAPE - 9,13 MAPE - 4,71 MAPE - 28,28 MAPE - 20,41 MAPE - 12,47	
Kayakuş vd. (Kayakuş, Terzioğlu, Yağmur ve Erdoğan, 2023)		YSA Çoklu Doğrusal Regresyon Karar Ağaçları Regresyonu	R ² - 0,9460 R ² - 0,6410 R ² - 0,8220	
Gür, Eşidir ve Kaldırımçı (Gür, Eşidir ve Kaldırımçı, 2024)		RBF MLP	R ² - 0,7650 R ² - 0,8650	
Kurtgeri (Kurtgeri, 2024)		CatBoost Gradient Boosting Random Forest SVR YSA SARIMA	R ² - 0,8500 R ² - 0,8300 R ² - 0,8100 R ² - 0,7900 R ² - 0,8100 R ² - 0,5200	
Hazır vd. (Hazır, Koç ve Esnaf, 2016)		Mobilya	YSA Regresyon Analizi	MAPE - 1,60 MAPE - 2,10
Nacar, Erdebilli ve Rouyendegh (Nacar, Erdebilli ve Rouyendegh, 2021)			Rastgele Orman Lineer Regresyon ElasticNet Ridge Lasso K-En Yakın Komşu	R ² - 0,8399 R ² - 0,6701 R ² - 0,6631 R ² - 0,6626 R ² - 0,6616 R ² - 0,4404
Akçay ve Kaplan (Akçay ve Yılmaz-Kaplan, 2024)		Kontör Tüketim	ARIMA SARIMA Prophet XGBoost RNN LSTM GRU RNN + GRU RNN + LSTM	R ² - 0,2000 R ² - 0,6900 R ² - 0,1700 R ² - 0,6800 R ² - 0,7600 R ² - 0,8000 R ² - 0,7800 R ² - 0,7900 R ² - 0,7800
Sevinç ve Kaya (Sevinç ve Kaya, 2021)	Sıcaklık	ARIMA LSTM	R ² - 0,9530 R ² - 0,9630	
Qassrawi, Azzeh ve Hijjawi (Qassrawi, Azzeh ve Hijjawi, 2024)	İlaç	LSTM MLP CNN	MAE - 0,75 MAE - 1,57 MAE - 0,92	
Ghazouani vd. (Ghazouani, Masmoudi, Mejri ve Layeb, 2024)	Deterjan	ARIMA LSTM CNN-LSTM	MAPE - 34,00 MAPE - 21,00 MAPE - 15,00	
inap (Sinap, 2024)	Perakende	LR RF KNN XGB DT LGBM	R ² - 0,1294 R ² - 0,6497 R ² - 0,4901 R ² - 0,7484 R ² - 0,6491 R ² - 0,6639	

Tablo 1, mobilya sektörü için en uygun zaman serisi tahmin yöntemini belirlemek adına, farklı sektörlerde denenmiş yöntemlerin ve başarı skorlarının karşılaştırılmasını sağlar. Bu bağlamda, çalışmamızın sonuçları ile literatürdeki diğer modeller arasında karşılaştırmalar yapılarak ve mobilya sektörüne yönelik tahmin modelleri geliştirilmesi konusunda öneriler sunulacaktır.

Yücesan tarafından yürütülen çalışmada, beyaz eşya sektöründe 46 aylık satış verilerini analiz etmek amacıyla YSA, ARIMA ve ARIMAX yöntemlerini kullanılmıştır. Yapılan analiz sonucunda, satış tahmininde en etkili yöntemin YSA olduğu belirlenmiştir. Bu bulgu, beyaz eşya sektöründe YSA'nın potansiyelini vurgulayarak, mevcut literatüre önemli bir katkı sağlamaktadır (Yücesan, 2018). Ecemiş ve Irmak tarafından yürütülen çalışmada, paslanmaz çelik sektöründeki bir distribütör firmanın faaliyet gösterdiği sektörlere yönelik satış tahminleri yapılmıştır. 98 aylık günlük satış verileri kullanılarak, veri madenciliği yöntemleri olan veri ön işleme, destek vektör regresyonu ve YSA kullanılarak genel satış ve sektöre özgü satış tahminleri yapılmıştır. Yapılan karşılaştırmada, destek vektör regresyon yönteminin diğer yöntemlere kıyasla daha etkili olduğu tespit edilmiştir (Ecemiş ve Irmak, 2018).

Sönmez ve Zengin tarafından yürütülen çalışmada, Tokat bölgesinde faaliyet gösteren bir yiyecek-içecek işletmesinin satış tahminini yapmak amacıyla YSA ve çoklu regresyon modellerini kullanmıştır. Matlab ve Python platformlarında gerçekleştirilen iki ayrı uygulama sonucunda, her iki modelin de yüksek başarı oranlarına ulaştığı gözlemlenmiştir. Matlab ortamında yapılan yapay sinir ağı uygulamasında, 2018'in ilk 6 ayını içeren günlük satış verileri kullanılmıştır. Yapılan tahminlerde %95,77 başarı oranı elde edilmiştir. Diğer bir uygulama ise Python programlama dili ile gerçekleştirilmiş ve çoklu regresyon modeli kullanılmıştır. Bu uygulamada ise doğruluk oranı %91,3 olarak belirlenmiştir. İki model arasındaki karşılaştırmada, YSA'nın daha yüksek başarı oranlarına ulaştığı ve işletme talep tahmininde daha etkili olduğu görülmüştür (Sönmez ve Zengin, 2019). Civelek tarafından gerçekleştirilen çalışmada, 2016-2019 yılları arasındaki belirlenmiş veri setleri üzerinde YSA yöntemleri kullanılarak traktör satış tahminleri yapılmıştır. İleri beslemeli geri yayılım yapay sinir ağı modeli, 2 ve 3 katmanlı yapılar kullanılarak test edilmiş ve en etkili tahminin, 3 katmanlı yapıda LOGSIG transfer fonksiyonu ile elde edildiği sonucuna varılmıştır (Civelek, 2021).

Karaatlı vd. tarafından yürütülen çalışmada, 53 aylık veriler kullanılarak gayri safi yurtiçi hasıla, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman gibi bağımsız değişkenler üzerinden satılan toplam araç sayısının tahminleri gerçekleştirilmiştir. Yapılan tahminlerin değerlendirilmesi için MAPE değeri %16,82 olarak hesaplanmış ve tahmin edilen ile gerçekleşen değerlerin birbirlerine yakın olduğu görülmüştür (Karaatlı vd., 2012). Yurtsever tarafından yürütülen bir çalışmada, çok değişkenli zaman serileri üzerinde araç satış tahmini gerçekleştirmek amacıyla LSTM modeli kullanılmıştır. Çalışmada, modelin girdisi olarak petrol fiyatı, işsizlik oranı, tüketici fiyat endeksi gibi ekonomik göstergeler kullanılmıştır. Yapılan tahminler, LSTM'in çok değişkenli zaman serilerinde başarılı bir tahmin doğruluğuna sahip olduğunu göstermiştir (Yurtsever, 2022).

Acar tarafından yürütülen çalışmada, Tarım Kredi Kooperatifleri Sakarya Bölge Birliği'ne bağlı 21 kooperatif tarafından gerçekleştirilen kömür satışlarının tahmin edilmesi amaçlanmıştır. 2014-2022 yılları arasındaki kömür satış verileri kullanılarak yıllık ve iki yıllık toplam kömür satış miktarı ton olarak tahmin edilmiştir. Bu tahminler için SARIMAX, Holt-Winters, FB-Prophet zaman serisi yöntemleri ve XGBoost makine öğrenme algoritması kullanılmıştır. Sonuçlar, XGBoost ve SARIMAX yöntemlerinin uzun vadeli tahminlerde başarılı olduğunu göstermiştir (Acar, 2022). Yılmaz ve Tosun tarafından gerçekleştirilen çalışma, Antalya ilindeki konut taleplerinin öngörüsüne odaklanmıştır. İstatistiksel tahmin metodlarına ek olarak, yapay zekâ teknikleri de talep tahmini için etkili bir biçimde kullanılmıştır. Veri seti, 2013-2017 yılları arasında aylık periyotlarla toplanmıştır. EvIEWS programı kullanılarak elde edilen çok değişkenli doğrusal regresyon analizi sonucunda elde edilen talep tahmin modeli, aynı veri seti üzerinde Matlab programı aracılığıyla uygulanan ileri beslemeli geri yayımlı YSA kıyaslanmıştır. Yapılan karşılaştırmada, YSA'nın regresyon analizine göre %1 daha düşük bir hata oranına sahip olduğu belirlenmiştir (Yılmaz ve Tosun, 2020).

Hazır vd. tarafından yürütülen çalışmada, Türkiye'deki mobilya talebinin 2004-2013 temel göstergeleri kullanılarak 2023 yılına yönelik yapay zekâ ve regresyon analizi ile tahmin edilmiştir. Araştırma sonuçlarına göre, çok değişkenli regresyon analizi ile yapılan tahmin 24 milyar dolar, yapay zekâ yöntemi ile yapılan tahmin ise 21 milyar dolar olarak elde edilmiştir. Bulgular, her iki yöntemin de düşük MAPE ve RMSE değerleri ile doğru tahminler elde ettiğini göstermekle birlikte YSA'nın regresyon analizine kıyasla daha üstün bir performans sergilediğini göstermektedir (Hazır vd., 2016). Salttürk tarafından yürütülen araştırma, mobilya sektöründe faaliyet gösteren bir firmanın talep tahminini gerçekleştirmeyi amaçlamaktadır. Çalışmada, yapay zekâ tekniklerinden biri olan YSA kullanılarak 2017-2020 yılları arasındaki 48 aylık veri analiz edilmiştir. ABC analizi ile belirlenen yatak ve kanepeler için satış tahminleri, mobilya sektörü sanayi üretim endeksi, dolar kuru ve fiyat değişimi gibi faktörler kullanılarak YSA modeli oluşturularak gerçekleştirilmiştir. Araştırmanın bulguları, YSA'nın yüksek doğrulukla tahminler elde edebildiğini ortaya koymaktadır (Salttürk, 2022).

Erol ve İnkaya tarafından yürütülen çalışmada, transfer öğrenme (TL) yöntemi ile farklı ürünlerin satış tahmin modellerinden elde edilen bilgilerin gelecekteki tahmin modellerine aktarılması amaçlanmıştır. Satış verisi tek değişkenli zaman serisi olarak ele alınmış ve transfer öğrenme yöntemi olarak gerçek cezalı düzenleme uzaklığı (ERP) kullanılarak kaynak veriden hedef veriye bilgi aktarımı gerçekleştirilmiştir. Özellikle uzun kısa-süreli bellek

(LSTM) ağı kullanılarak elde edilen model, transfer öğrenme prensipleri ile eğitilmiş ve gelecekteki tahmin modelleri için kullanılmıştır. Yapılan deneysel çalışmalar, önerilen ERP-LSTM-TL yönteminin klasik tahmin ve makine öğrenmesi yöntemlerine göre daha yüksek doğruluk sağladığını, ayrıca eğitim sürelerini önemli ölçüde kısalttığını göstermiştir (Erol ve İnkaya, 2023). Sharma ve Sinha tarafından yürütülen çalışmada, Hindistan'da faaliyet gösteren otomobil endüstrisinde bulunan Maruti Suzuki Ltd'nin satış tahmini incelenmiştir. Bu şirketin otomobil satış tahminini etkileyen en önemli parametrelerin enflasyon oranı, benzin fiyatı ve önceki ay satışı olduğu belirlenmiştir. Model, Bulanık Yapay Sinir Ağı Geri Yayılım Algoritması kullanılarak eğitilmiştir. Elde edilen sonuçlar, çoklu regresyon tekniği gibi diğer istatistiksel tekniklerle karşılaştırılmıştır. Önerilen algoritma tarafından elde edilen sonuçların, çoklu doğrusal regresyon tekniği ile elde edilen sonuçlardan üstün olduğu bulunmuştur (Sharma, 2012).

Hülsmann vd. tarafından yürütülen çalışmada, otomobil pazarındaki satış tahminine odaklanan çeşitli geliştirilmiş metodolojiler ve modeller ele alınmıştır. Çalışmanın sonuçlarına göre, aylık tahminlerin özellikle mutlak, normalize edilmiş dışsal parametreler kullanılarak geliştirilen metodoloji ile iyileştirildiği görülmüştür. Karar Ağaçları, bu durumda hem doğru hem de açıklanabilir sonuçlar sunduğu için en uygun yöntem olarak değerlendirilmiştir. Destek Vektör Makinesinin de güvenilir bir yöntem olduğu belirtilmiştir. Özellikle aylık tahminlerde, Karar Ağaçları kullanılarak elde edilen metodolojinin, diğer Veri Madenciliği yöntemlerine kıyasla daha iyi sonuçlar verdiği belirtilmiştir. Tahmin hatalarının %10'un altında olması, bu metodolojinin etkili olduğunu göstermektedir (Hülsmann vd., 2011). Yücesan vd. tarafından yürütülen çalışmada, Türkiye'nin Karadeniz bölgesinde faaliyet gösteren bir mobilya üreticisinin aylık satışlarını tahmin etmek için MATLAB kullanılarak bir yapay sinir ağı (YSA) tabanlı bir model önerilmiştir. Önerilen modelin performansı, Bayesian düzenleme ile eğitilen YSA'nın kullanılmasının, kurumsal mobilya fabrikasının aylık satışlarını başarıyla tahmin etmek için etkili bir seçenek olduğunu göstermektedir. Modelin başarı ölçütleri, YSA'nın gerçek verilere daha yakın tahminler ürettiğini ve bu sayede satış tahmininde etkili bir araç olabileceğini göstermektedir (Yucesan, Gul ve Celik, 2017). Nacar ve Erdebili tarafından yürütülen çalışmada, bir makine öğrenmesi proje süreci ele alınmıştır. Makine öğrenmesi algoritmaları, doğrusal regresyon, Ridge, Lasso, Elastic Net, K-en yakın komşu ve Rastgele Orman gibi yöntemlerle bir satış tahmin modeli geliştirilmiştir. Yapılan analizlerde, Rastgele Orman algoritmasının en düşük hatayı verdiği ve en etkili tahmin olduğu belirlenmiştir (Nacar vd., 2021).

Yücesan vd. tarafından yürütülen başka bir çalışma, mobilya ürünlerinin satışlarını tahmin etmek için geliştirilmiş bir karşılaştırmalı tahmin çerçevesini içermektedir. Uygulanan modeller arasında ARIMAX, YSA ve ARIMAX-YSA hibritleşmesi bulunmaktadır. Modeller, Türkiye'nin Karadeniz bölgesinde bulunan bir mobilya üretim şirketinin aylık satış rakamlarını tahmin etmek için kullanılmıştır. Sonuçlar, her ürün miktarı için geliştirilen ARIMAX-YSA hibrid modelinin, tek başına modellere göre daha iyi doğruluk değerleri verdiğini göstermiştir (Yucesan, Gul ve Celik, 2018). Zhao ve Wang tarafından yürütülen çalışma, E-ticarette satış tahminini ele almaktadır. Evrişimli Sinir Ağı (CNN) kullanarak yapılandırılmış verilerden otomatik özellik öğrenmeye odaklanan bir yaklaşım önerilmektedir. Çalışma, CaiNiao.com'dan alınan gerçek dünya verileri üzerinde test edilmiş ve deneysel sonuçlar yöntemin etkinliğini doğrulamıştır (Zhao ve Wang, 2017). Elmasdotter ve Nystömer tarafından yürütülen çalışmada, LSTM ve ARIMA adlı iki tahmin modeli karşılaştırılmıştır. Modeller, farklı ürünlerin satış verileri üzerinde bir gün ve yedi gün öncesiyle alakalı tahminlerde bulunuyor. Yapılan karşılaştırmalara göre, modeller arasındaki farkın bir gün öncesi tahminlerde istatistiksel olarak anlamlı olmadığı, ancak yedi gün öncesi tahminlerde LSTM modelinin daha yüksek doğruluk sağladığı sonucuna ulaşılmıştır (Elmasdotter ve Nyströmer, 2018).

Akçay ve Kaplan, farklı makine öğrenmesi ve derin öğrenme algoritmaları kullanarak müşteri kontör tüketimlerini tahmin etmeyi amaçlamıştır. Bir teknoloji şirketinin 9 yıllık (2014-2022) verilerini kullanan araştırmacılar, ARIMA, SARIMA, Prophet ve XGBoost gibi geleneksel yöntemleri; RNN, LSTM ve GRU gibi derin öğrenme yöntemleriyle karşılaştırmışlardır. Sonuçlar, RNN+GRU ve RNN+LSTM gibi hibrit derin öğrenme modellerinin en başarılı tahmin performansını sergilediğini göstermiştir. Çalışma, bu tür tahminlerin şirketlerin gelecekteki kontör satışlarını tahmin etmelerine ve stratejik planlamalar yapmalarına yardımcı olabileceğini vurgulamıştır (Akçay ve Yiltas-Kaplan, 2024). Sevinç ve Kaya, Diyarbakır ili için hava sıcaklığı tahmininde derin öğrenme yöntemlerinin uygulanabilirliğini araştırmıştır. 2014-2020 yılları arası meteorolojik verileri kullanarak, derin öğrenme mimarisi LSTM ve geleneksel zaman serisi analizi modeli ARIMA ile tahminler yapılmıştır. Her iki model de gerçek hava sıcaklığına yakın değerler üretmiş, LSTM modeli 0.96 R-kare değeri ile yüksek doğruluk göstermiştir. Çalışma, LSTM ve ARIMA'nın hava sıcaklığı tahmininde başarılı bir şekilde kullanılabileceğini ortaya koymuştur (Sevinç ve Kaya, 2021). Kayakuş vd., Türkiye'deki hafif ticari araç satışlarını makine öğrenmesi yöntemleri kullanarak tahmin etmeyi amaçlamıştır. Araştırmacılar, Ocak 2006-Haziran 2022 dönemini kapsayan 1782 veri noktasından oluşan bir veri seti kullanmış ve YSA, çoklu doğrusal regresyon ve karar ağacı regresyonu yöntemlerini karşılaştırmışlardır. Sonuçlar, YSA modelinin %94.6'lık bir R² değeri ile en yüksek tahmin başarısını gösterdiğini ortaya koymuştur. Çalışma, YSA'nın Türkiye'deki hafif ticari araç satışlarının tahmininde başarılı bir şekilde

kullanılabileceği sonucuna varmış ve bu tahminlerin otomotiv sektörü ve ilgili paydaşlar için stratejik karar alma süreçlerine katkı sağlayabileceğini vurgulamıştır (Kayakuş vd., 2023).

Bu literatür araştırması, başta mobilya sektörü olmak üzere birçok sektörün satış tahminlerini değerlendirmek amacıyla yapılan çeşitli çalışmaları içeren kapsamlı bir inceleme sunmaktadır. Çeşitli sektörlerdeki benzer çalışmaların incelenmesi, mobilya sektöründe gelecek satışları tahmin etmek için güçlü modellerin geliştirilmesi konusunda önemli bir kaynak sağlamaktadır. Özellikle otomotiv, elektronik, beyaz eşya, gıda, çelik ve giyim gibi sektörlerdeki önceki araştırmaların incelenmesi, satış tahmin modellerinin oluşturulması konusunda sağlam bir temel oluşturmuştur. Her sektörde farklı zorluklarla karşılaşılmasına rağmen, ortak noktaların belirlenmesi ve bu sektörel benzerliklerin mobilya sektöründeki tahmin modelleri için değerli bir rehberlik sağlaması önemlidir.

Çalışmalardan elde edilen bulgular, farklı yöntemlerin (örneğin, YSA, ARIMA, destek vektör regresyonu, çoklu regresyon) farklı sektörlerde başarıyla kullanılabileceğini göstermektedir. Bu yöntemlerin mobilya sektöründeki uygulanabilirliği ve etkinliği, sektöre özgü dinamikler ve özellikler göz önüne alınarak değerlendirilmelidir. Mobilya sektörüne odaklanan önceki çalışmaların incelenmesi, pazar trendleri, tüketici davranışları ve ekonomik faktörler gibi sektöre özgü dinamikleri anlamak için önemlidir. Bu bilgi, gelecek satışları tahmin etmek için daha hassas ve spesifik modellerin geliştirilmesine yardımcı olabilir.

Yapılan çalışmalardan birçoğu, YSA satış tahmininde etkili bir araç olduğunu göstermiştir. Ayrıca, destek vektör regresyonu gibi diğer yöntemlerin de başarılı sonuçlar elde ettiği görülmüştür. Bu, mobilya sektöründe çeşitli yöntemlerin kullanılabileceğini ve birbiriyle karşılaştırıldığında belirli durumlarda bir yöntemin diğerlerine göre daha etkili olabileceğini göstermektedir. Ayrıca, literatür araştırması kapsamında, mobilya sektöründe satış tahminlerini geliştirmek için kullanılan çeşitli yöntemlere ek olarak, LSTM, BiLSTM, GRU ve BiGRU gibi yinelemeli sinir ağı modellerinin de incelendiği belirtilmelidir. Bu modeller, zaman serileri analizi ve gelecek satış tahminleri konusunda özellikle güçlü performans sergileyen YSA türleridir.

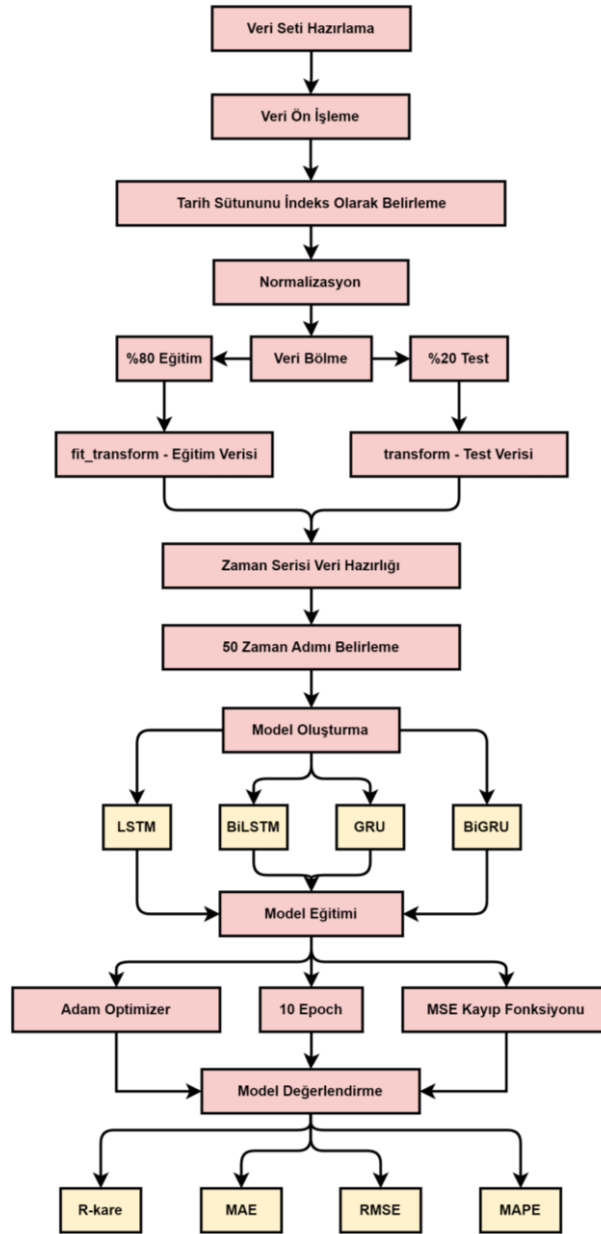
Yapılan karşılaştırmalarda, LSTM, BiLSTM, GRU ve BiGRU gibi yinelemeli sinir ağı modellerinin mobilya sektöründe tahmin performansını artırma potansiyeline sahip olduğu ortaya çıkabilir. Bu modellerin, özellikle zaman içindeki trendleri ve dalgalanmaları daha etkili bir şekilde öğrenme yetenekleri, literatüre yeni bir bakış açısı getirebilir ve gelecekteki çalışmalara ilham kaynağı olabilir. Bu modellerin kullanımı, mobilya sektöründe satış tahminlerini iyileştirmek için gelecekte yapılabilecek araştırmalarda dikkate alınması gereken önemli bir alanı temsil eder. Yinelemeli sinir ağı modellerinin, özellikle karmaşık veri yapıları ve dinamik pazar koşulları gibi zorlu senaryolarda, daha kesin ve güvenilir tahminler yapma potansiyeline sahip olduğu unutulmamalıdır.

Geleneksel yöntemlerin yanı sıra YSA ve yinelemeli sinir ağı modellerinin ele alındığı bu çalışma, sektöre özgü dinamikleri anlama ve gelecekteki satışları daha doğru bir şekilde tahmin etme amacı taşımaktadır. Mevcut literatürü derinleştirerek, mobilya sektöründe satış tahminlerini iyileştirmek için daha güçlü ve etkili modellerin geliştirilmesine katkıda bulunmayı hedeflemektedir. Bu çalışma, sektörel profesyonellerin ve araştırmacıların ileriye yönelik çalışmalarında ilham alabileceği bir kaynak olmayı amaçlamaktadır.

3. Materyal ve Yöntem (Material and Method)

Bu bölümde, çalışmada kullanılan materyal ve yöntemler detaylı bir şekilde ele alınmaktadır. Araştırma, yinelemeli sinir ağı modellerini kullanarak gelecekteki satış tutarlarını tahmin etmeyi amaçlamaktadır. Bu doğrultuda, veri toplama sürecinden model seçimine, veri ön işlemeden model eğitimi ve değerlendirmesine kadar olan tüm aşamalar sistematik bir yaklaşımla açıklanmıştır. Şekil 1, çalışmanın materyal ve yöntem aşamalarını görsel olarak özetlemektedir. Bu şema, araştırma sürecimizin ana hatlarını ve aşamalar arasındaki ilişkileri göstermektedir. İlerleyen bölümlerde, her bir aşama ayrıntılı olarak incelenecek ve kullanılan teknikler, veri seti ve analiz yöntemleri hakkında kapsamlı bilgiler sunulacaktır.

Çalışmada kullanılan ve günlük satış verilerini içeren veri seti, günlük satış verilerini içeren bir Excel dosyasından elde edilmiştir. Sipariş tarihine göre kronolojik olarak düzenlenen veri setinde, tarih sütunu indeks olarak belirlenmiştir. Veri seti daha sonra %80'i eğitim ve %20'si test olmak üzere iki kümeye ayrılmıştır. Bu kümelere normalizasyon işlemi uygulanarak veriler 0 ile 1 aralığına sınırlandırılmıştır. Eğitim verileri üzerinde fit_transform yöntemi uygulanmış ve test verileri üzerinde transform yöntemi kullanılmıştır. Zaman serisi veri hazırlığı için oluşturulan fonksiyon, belirli bir zaman adımı sayısı (50 zaman adımı) belirlenerek önceki dönemlerin verilerini kullanarak özellikler ve hedef değişkenler oluşturur. Önceki dönemlerin belirlenen zaman adımı kadarı, her bir örnekte bir araya getirilir ve bu örneklerin her biri, belirli bir zaman noktasında mevcut durumu tahmin etmek için kullanılan girdi ve çıktı özelliklerini içerir. Bu şekilde, modelin zaman serisi verileri işlemesi için uygun bir formata getirilmiş veri kümesi elde edilir.



Şekil 1. Çalışmada kullanılan materyal ve yöntemlerin akış diyagramı (Flow chart of materials and methods used in the study)

Çalışmada kullanılan RNN modelleri LSTM, BiLSTM, GRU ve BiGRU olmuştur. Her model, bir zaman serisi tahmin problemi için uygun olan katmanlarla birlikte Sequential API kullanılarak oluşturulmuştur. Model optimizasyonu için Adam optimizer kullanılmıştır. Kayıp fonksiyonu olarak MSE kullanılmıştır. Her model 10 epoch eğitilmiş ve bu sırada, her epoch sonunda kayıp (loss) değerleri kaydedilmiştir. Eğitilen modeller, test veri kümesi üzerinde tahminlerde bulunmuş ve gerçek değerlerle karşılaştırılmıştır. Değerlendirme metrikleri olarak R-kare, MAE, RMSE ve MAPE kullanılmıştır. Çalışmanın sonuçlarını görselleştirmek için çeşitli grafikler oluşturulmuştur. Bunlar arasında gerçek ve tahmini satış verilerini karşılaştıran zaman serisi grafiği, model eğitim sürecindeki kayıp değerlerini gösteren grafikler ve tahmin hatalarının histogramı bulunmaktadır. Gerçek ve tahmini satış verilerini interaktif bir şekilde görselleştirmek için Plotly Express kullanılmıştır. Bu grafikler, gerçek ve tahmini satışları dinamik olarak karşılaştırmak için oluşturulmuştur. Eğitilen modeller, sonradan kullanılmak üzere .h5 dosyası biçiminde kaydedilmiştir. Kullanılan materyal ve yöntemler, alt bölümlerde ayrıntılı bir şekilde sunulmaktadır.

3.1. Veri Yükleme, Hazırlama ve Ön İşleme (Data Loading, Preparation and Preprocessing)

Çalışmanın başlangıcında, Python programlama dilinde sıklıkla kullanılan temel kütüphaneler yüklenmiştir. Bu kütüphaneler arasında, veri analizi ve manipülasyonu için pandas, matematiksel operasyonlar için numpy, grafik ve görselleştirme işlemleri için matplotlib.pyplot, yinelemeli sinir ağı modelleri oluşturmak ve eğitmek için tensorflow, interaktif grafikler oluşturmak için plotly.express, ve makine öğrenimi algoritmalarını içeren scikit-learn bulunmaktadır.

Çalışmanın odak noktasını oluşturan temel veri seti, "dataset.xlsx" dosyası, pandas kütüphanesi kullanılarak yüklenmiştir. Bu veri seti, bir mobilya firmasının satış verilerini içermektedir. Her bir satırında farklı siparişlere ait detaylı bilgiler bulunmaktadır, bu bilgiler arasında sipariş tarihi, ürünlerin miktarı ve fiyatları gibi önemli detaylar yer almaktadır. Veri seti, belirli bir tarih aralığı olan 1 Ocak 2022 ile 31 Ekim 2023 tarihleri arasında (22 ay) gerçekleşen toplam 37.006 farklı siparişi içermektedir. Bu süre zarfında, mobilya firması tarafından gerçekleştirilen satışların geniş bir yelpazesi bulunmaktadır, bu da veri setinin çeşitliliğini ve hacmini göstermektedir. Bu zengin veri seti, makine öğrenimi modellemesi ve zaman serisi analizi için uygun bir temel oluşturmaktadır.

Siparişlerin miktarları ve fiyatları, bu tarihsel aralığa göre sıralanmıştır, böylece zaman içindeki değişiklikleri anlamak mümkündür. Veri setindeki "Sipariş Miktarı" ve "Birim Fiyat" sütunları, her bir siparişin miktarını ve birim fiyatını göstermektedir. Ayrıca, "Net Fiyat" sütunu, her bir siparişin toplam fiyatını ifade etmektedir ve bu değer, sipariş miktarı ile birim fiyatın çarpılmasıyla elde edilmiştir.

Bu analiz ve modelleme aşaması, veri setindeki temel özellikleri anlamak ve gelecekteki trendleri öngörebilmek adına önemlidir. Kullanılan kütüphaneler, veriyi etkili bir şekilde işlemek, görselleştirmek ve makine öğrenimi modelleri oluşturmak için güçlü araçlar sunmaktadır. Ayrıca Verilerin düzgün bir şekilde işlenebilmesi için Min-Max ölçekleme yöntemi uygulanmıştır, bu işlem verilerin 0 ile 1 arasına ölçeklendirilmesini yani normalizasyonunu sağlamaktadır. Normalizasyon işleminin formülü Eşitlik 1'de gösterilmektedir.

$$\text{Normalize}(x) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

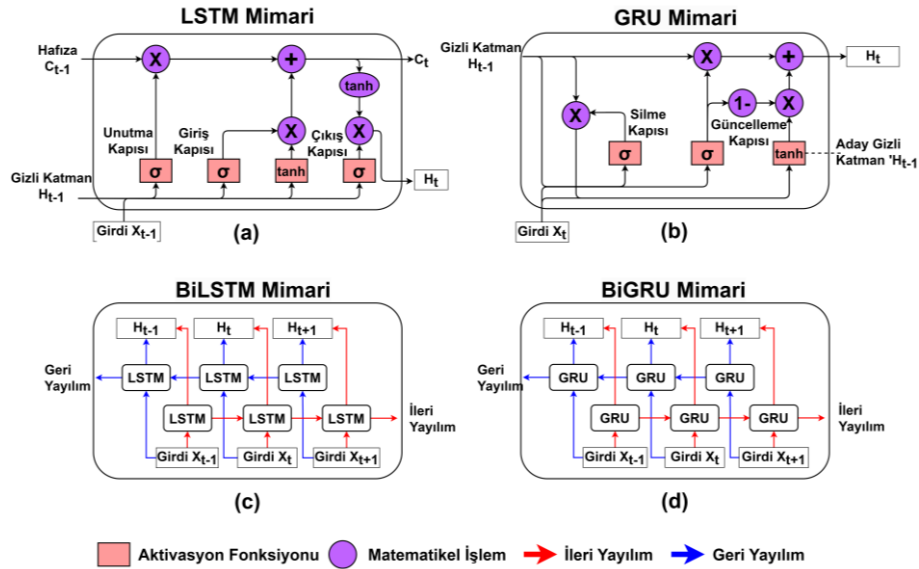
x : Normalizasyon işlemine tabi tutulacak olan veri, $\min(x)$ veri kümesindeki en küçük değer, $\max(x)$ veri kümesindeki en büyük değer.

3.2. Yinelemeli Sinir Ağı Modelleri ve Zaman Serisi Veri Oluşturma (Recurrent Neural Network Models and Time Series Data Generation)

Eğitim ve test verileri, belirlenen zaman adımları kullanılarak zaman serisi veri setine dönüştürüldü. Bu aşama, geçmiş zaman adımları kullanılarak gelecekteki bir zaman adımının tahmin edilebilmesi amacıyla gerçekleştirildi. Çalışmada kullanılacak yinelemeli sinir ağı modelleri belirlendi, bu modeller arasında LSTM, BiLSTM, GRU ve BiGRU yer aldı. Her bir mimari, zaman serisi veri setindeki örüntüleri farklı şekillerde yakalamak üzere seçildi. LSTM ve GRU gibi yinelemeli sinir ağı yapıları, zaman içindeki bağımlılıkları etkili bir şekilde modelleyebilmektedir. Diğer yandan, Bidirectional mimariler, hem geçmiş hem de gelecek zaman adımlarındaki bilgileri kullanarak daha kapsamlı bir anlayış sunmayı hedeflemektedir. Bu farklı mimarilerin seçimi, zaman serisi tahmin performansının karşılaştırılmasına olanak tanıyarak çalışmanın temelini oluşturacaktır.

LSTM, sıralı veri setlerinde etkili olan bir RNN türüdür. Her bir hücre, geçmiş ve gelecekteki bilgileri hatırlama yeteneğine sahiptir (Gers, Schmidhuber ve Cummins, 2000). BiLSTM, her zaman adımında hem ileri hem de geri yönde çalışan iki ayrı LSTM içerir. Bu, hem geçmiş hem de gelecek bilgilerini daha iyi anlamak için daha fazla bağlam sağlar (Huang, Research, Xu ve Baidu, 2015). GRU, zaman serileri analizi gibi sıralı veri setlerinde kullanılan bir RNN türüdür (Dey ve Salemt, 2017). GRU'nun öne çıkan özelliklerinden biri, LSTM'ye kıyasla daha basit bir yapıya sahip olmasıdır. Bu basitlik, daha az parametre ile daha hızlı eğitim süreçleri sağlayabilir. GRU'nun temel yapısında, hücrelerin geçmiş bilgileri güncel bilgilerle nasıl birleştirdiği kapılar (gates) olarak adlandırılan mekanizmalar tarafından kontrol edilir. BiGRU, hem ileri hem de geri yönde çalışan iki ayrı GRU içerir (Li vd., 2022). Bu, her bir zaman adımında hem geçmiş hem de gelecek bilgilerini dikkate alabilme yeteneği sağlar. İki yönlü mimari, özellikle zaman serileri gibi bağlamın önemli olduğu problemlerde daha iyi performans gösterebilir. BiGRU modeli, daha az parametre içerir ve bu da genellikle daha hızlı eğitim süreçleri anlamına gelebilir. Şekil 2'de bu dört modelin mimarileri gösterilmiştir.

LSTM, GRU, BiLSTM ve BiGRU mimarileri, zaman serisi verileri ve dizisel bilgi akışlarını işleyebilen güçlü modellerdir. Her biri, girdilere göre belirli bir zaman diliminde bilgi işleyip, uzun vadeli bağımlılıkları öğrenme yeteneğine sahiptir. Bu mimarilerin her biri farklı yapısal özellikler taşısa da, ortak amaçları uzun vadeli bilgiyi korumak ve kısa vadeli hafıza sorunlarını ortadan kaldırmaktır. Görselde bu yapılar daha detaylı bir şekilde gösterilmektedir.



Şekil 2. LSTM, GRU, BiLSTM ve BiGRU modellerinin mimarileri (Architectures of LSTM, GRU, BiLSTM and BiGRU models)

(a) LSTM mimarisi, zaman serisi verilerini işlerken uzun dönemli bağımlılıkların öğrenilmesini sağlar. Görselde de görülebileceği gibi, LSTM'nin yapısında üç ana kapı mekanizması bulunmaktadır: unutma kapısı, giriş kapısı ve çıkış kapısı. Unutma kapısı, önceki hücre durumunun ne kadarının hatırlanacağını belirlerken, giriş kapısı mevcut verinin ne kadarının hücre durumuna ekleneceğini kontrol eder. Çıkış kapısı ise gizli katmandaki bilgiyi kullanarak hücre çıktısını oluşturur. Bu mekanizmalar arasındaki etkileşim, LSTM'nin sadece uzun vadeli ilişkileri öğrenmesini sağlamakla kalmaz, aynı zamanda eski ve gereksiz bilgileri de unutarak yeni bilgilerin işlenmesine olanak tanır. Şematik olarak gösterilen "X" ve "+" işaretleri matematiksel işlemleri, sigma (σ) ve tanh ise aktivasyon fonksiyonlarını temsil eder.

(b) GRU mimarisi, LSTM'nin daha sadeleştirilmiş bir versiyonudur. GRU, LSTM gibi uzun dönemli bağımlılıkları öğrenebilse de, yapısı daha basittir ve hesaplama açısından daha verimlidir. GRU'nun yapısında iki ana kapı mekanizması bulunmaktadır: silme kapısı ve güncelleme kapısı. Silme kapısı, LSTM'deki unutma kapısına benzer şekilde, eski bilginin ne kadarının korunacağını belirler. Güncelleme kapısı ise mevcut bilginin ne kadarının yeni hücre durumuna ekleneceğini kontrol eder. Bu sadeleştirilmiş yapı, GRU'nun daha hızlı çalışmasına ve daha az bellek kullanmasına olanak tanır, ancak bazı durumlarda bu sadelik performans kaybına neden olabilir. Görselde, GRU'nun akış diyagramı kapıların nasıl etkileştiğini ve bilgiyi nasıl güncellediğini açıkça göstermektedir.

(c) BiLSTM mimarisi, zaman serisi verilerini çift yönlü işleyen bir yapıdır. Klasik LSTM sadece ileri yönde veri işlerken, BiLSTM veriyi hem ileri hem de geri yönde işler. Bu çift yönlü veri akışı, modelin sadece geçmiş bilgileri değil, aynı zamanda gelecekteki bilgileri de kullanarak daha kapsamlı bir öğrenme gerçekleştirmesini sağlar. Görselde, BiLSTM mimarisinin çift yönlü veri akışı (ileri ve geri yayılım) kırmızı ve mavi oklarla temsil edilmektedir.

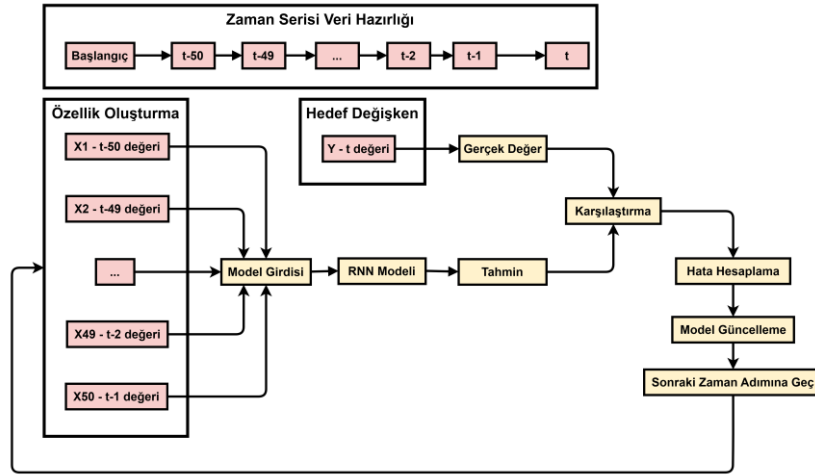
(d) BiGRU mimarisi, GRU'nun çift yönlü versiyonudur. BiGRU, GRU'nun sunduğu hesaplama avantajlarını çift yönlü veri işleme yeteneğiyle birleştirir. BiLSTM gibi, BiGRU da veriyi hem ileri hem de geri yönde işleyerek daha geniş bir bilgi yelpazesi üzerinden öğrenme gerçekleştirir. Görselde, BiGRU mimarisinin çift yönlü veri işleme süreci benzer şekilde kırmızı ve mavi oklarla gösterilmiştir. BiGRU, daha hafif yapısı sayesinde, bazı uygulamalarda BiLSTM'ye göre daha hızlı ve verimli çalışabilir.

Özetle, bu mimarilerin her biri zaman serisi verilerinin işlenmesinde ve uzun vadeli bağımlılıkların öğrenilmesinde kullanılır. LSTM ve GRU, zaman serisi verilerinde ardışık bağımlılıkları öğrenirken, BiLSTM ve BiGRU gibi çift yönlü mimariler veriyi ileri ve geri yönde işleyerek daha kapsamlı bir öğrenme sağlar.

Her bir model, Adam optimizyer kullanılarak derlenmiştir. Adam optimizyer, öğrenme hızını adapte edebilen bir optimizasyon algoritmasıdır (Kingma ve Ba, 2014). Öğrenme hızı (Learning Rate), 0.001 olarak belirlenmiştir. Öğrenme hızı ağırlıkların güncellenmesi için kullanılan adım büyüklüğünü temsil eder (Zeiler, 2012). Bu değer genellikle deneme yanılma yoluyla belirlenir ve modelin öğrenme sürecini düzenler. Modellerin eğitim süreci, 10 epoch ve 64'lük bir batch size kullanılarak gerçekleştirildi. Epoch, modelin tüm eğitim verilerini bir kez geçtiği eğitim iterasyonunu temsil eder. Her bir epoch boyunca, model eğitim verilerini kullanarak tahminler yapar ve gerçek değerlerle karşılaştırarak bir hata değeri üretir. Eğitim sürecinde, her epoch sonunda oluşan hata değerleri

kaydedildi. Bu durum, modelin eğitim sürecindeki performansının gözlemlenmesini ve değerlendirilmesini sağlar. Hata değerlerinin kaydedilmesi ise, eğitim sürecinin ilerleyişini izlemek ve gerektiğinde modelin hiperparametrelerini ayarlamak için önem arz eder.

Verilerin %80'i eğitim için ayrıldı, bu da veri setinin büyük bir bölümünün modelin eğitiminde kullanıldığı anlamına gelmektedir. Bu oran, genellikle modelin daha iyi genelleme yapmasına yardımcı olur, çünkü model, daha fazla çeşitlilik içeren bir veri kümesi üzerinde eğitildiği için daha genel ve güvenilir öğrenmeler yapabilir. Eğitilen modeller, %20'lik test verileri üzerinde tahminler yapmak için kullanıldı. Bu, modellerin eğitim sırasında görmediği ve genelleme yeteneklerini ölçmek için ayrılmış olan bir veri kümesidir. Tahminler, ölçeklendirme işleminden tersine çevrildi ve orijinal ölçeklere getirildi. Bu adım, önce verinin ölçeğini düşük boyutlardan büyük boyutlara getirilen normalizasyon işlemi veriyi orijinal ölçeklere geri getirir. Bu, tahminlerin gerçek dünya değerleriyle karşılaştırılabilir olmasını sağlamaktadır. Tüm modeller için, tek katmanlı yapılar kullanılmıştır. Her katmanda 200 katman bulunmaktadır. Öğrenme hızı 0.001 olarak belirlenmiştir. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Batch boyutu 64 olarak ayarlanmıştır. Kayıp fonksiyonu MSE tercih edilmiştir. Her model için eğitim süresi 10 epoch olarak belirlenmiştir ve her epoch için 50 zaman adımı alınmıştır. Şekil 3'te Zaman serisi veri hazırlığı ve özellik çıkartma işleminin çalışma prensibi sunulmuştur.



Şekil 3. Zaman serisi veri hazırlama ve özellik çıkartma döngüsü (Time series data preparation and feature extraction cycle)

Şekil 3, zaman serisi analizinde kullanılan 50 adımlık pencere yaklaşımını ve tahmin sürecini görselleştirmektedir. Süreç, zaman serisi veri hazırlığı ile başlar, burada t-50'den t'ye kadar olan zaman adımları sıralanır. Her bir adım, bir önceki zaman noktasını temsil eder. Ardından, özellik oluşturma aşamasında, model için girdi özellikleri hazırlanır. X1'den X50'ye kadar olan özellikler, sırasıyla t-50'den t-1'e kadar olan zaman noktalarındaki değerleri temsil eder. Hedef değişken Y, tahmin edilmek istenen t zamanındaki değeri gösterir. Oluşturulan özellikler, LSTM, BiLSTM, GRU veya BiGRU gibi bir RNN modeline girdi olarak verilir. Model bu girdileri işleyerek t zamanı için bir tahmin üretir. Üretilen tahmin, gerçek değer ile karşılaştırılır ve aralarındaki fark hesaplanarak hata belirlenir. Bu hata bilgisi kullanılarak model güncellenir. Süreç, bir sonraki zaman adımı için tekrarlanır. Bu yaklaşım, her bir tahmin için önceki 50 zaman adımının nasıl kullanıldığını, modelin nasıl eğitildiğini ve tahminlerin nasıl yapıldığını göstererek, zaman serisi analizindeki karmaşık süreci basit ve anlaşılır bir şekilde özetlemektedir.

3.3. Performans Değerlendirmesi (Performance Evaluation)

Modellerin performansı, R-kare, MAE, RMSE ve MAPE değerleri kullanılarak değerlendirildi. Eşitlik 2'de verilen R-kare, bağımsız değişkenin bağımlı değişkeni ne kadar iyi açıkladığını gösteren bir istatistiksel ölçüdür. Sonuç 1 sayısına ne kadar yakınsa, modelin o kadar iyi olduğunu gösterir (Chicco, Warrens ve Jurman, 2021)

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (2)$$

m: Gözlem Sayısı, X_i : Bağımsız değişkenin i . gözlemdeki değeri. Y_i : Gerçek bağımlı değişkenin i . Gözlemindeki değeri, \bar{Y} : Bağımlı değişkenlerin ortalaması.

R-kare, YSA modelinin eğitiminin ardından elde edilen tahminlerin gerçek değerlere ne kadar yakın olduğunu değerlendirmek için kullanılır.

MAE, Her bir gözlem için gerçek değer ile model tahmini arasındaki mutlak farkları toplar ve bunların ortalamasını alır. Bu, modelin genel performansını ölçen bir metrik olarak kullanılır. İdeal durumda, MAE değeri sıfıra ne kadar yakınsa, modelin tahminleri gerçek değerlere o kadar yakındır (Chai ve Draxler, 2014). Formülü Eşitlik 3'te gösterilmektedir.

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (3)$$

m : Gözlem Sayısı, X_i : i . Gözlemdeki Gerçek Değer, Y_i : i . Gözlemdeki Tahmin Değeri.

MAE, özellikle hata büyüklüğünün önemli olduğu durumlarda YSA modelinin doğruluğunu değerlendirmek için kullanılır.

Eşitlik 4'te sunulan RMSE, gerçek değerlerle tahmin edilen değerler arasındaki kare farkların ortalamasının karekökünü ifade eder. İdeal durumda, RMSE değeri sıfıra ne kadar yakınsa, modelin tahminleri gerçek değerlere o kadar yakındır (Çalasan, Abdel Aleem ve Zobaa, 2020).

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \quad (4)$$

m : Gözlem Sayısı X_i : i . Gözlemdeki Gerçek Değer, Y_i : i . Gözlemdeki Tahmin Değeri.

RMSE, özellikle büyük hataların maliyetli olduğu durumlarda YSA modelinin performansını değerlendirmek için kullanılır.

Formülü Eşitlik 5'te gösterilen MAPE, gerçek değerlerle tahmin edilen değerler arasındaki mutlak yüzde farklarının ortalamasını ifade eder. Bu metrik, özellikle yüzde hata ölçümü gereken durumlarda kullanılır. İdeal durumda, MAPE değeri sıfıra ne kadar yakınsa, modelin tahminleri gerçek değerlere o kadar yakındır. Ancak, MAPE'nin sıfır olması mümkün değildir, bu nedenle düşük bir MAPE değeri genellikle iyi bir model performansını gösterir (de Myttenaere, Golden, Le Grand ve Rossi, 2016).

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right| \quad (5)$$

m : Gözlem Sayısı X_i : i . Gözlemdeki Gerçek Değer, Y_i : i . Gözlemdeki Tahmin Değeri.

MAPE, özellikle farklı ölçeklerde değişen veriler için YSA modelinin performansını değerlendirmek için kullanılır.

Bu metrikler, genellikle YSA modelinin eğitimi ve değerlendirmesi sırasında kullanılır. Model eğitildikten sonra, test verileri üzerinde tahminler yapılır ve bu tahminler gerçek değerlerle karşılaştırılır. Karşılaştırma sonucunda R-kare, MAE, RMSE ve MAPE değerleri hesaplanır. Bu değerler, modelin performansını anlamak ve farklı modeller arasında karşılaştırma yapmak için kullanılır.

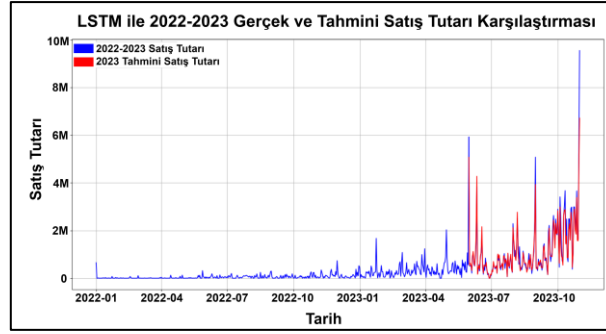
YSA modelleri kullanılarak gelecekteki satış tutarları başarıyla tahmin edilmiştir. Elde edilen sonuçlar, ilgili grafikler ve R-kare, MAE, RMSE ve MAPE gibi performans metrikleriyle detaylı bir şekilde rapor edilmiştir. Bu kapsamlı analiz, çalışmanın ana bulgularını ortaya koymanın yanı sıra, gelecekteki satış tahminleri için hangi modelin daha güvenilir olduğunu belirlemeye de yardımcı olmuştur.

4. Deneysel Sonuçlar (Experimental Results)

Bu çalışma, bilgisayar ortamında Python programlama dili kullanılarak gerçekleştirilmiş ve yinelemeli sinir ağı modelleri olan LSTM, BiLSTM, GRU ve BiGRU kullanılarak zaman serisi satış verileri üzerinde tahminleme gerçekleştirilmiştir. İşletmenin gelecekteki satışlarını doğru bir şekilde öngörebilmek, planlama süreçlerini optimize etmek açısından kritik öneme sahiptir. Modellerin eğitim süreçleri, hata eğrileri ve gerçek ve tahmin karşılaştırmaları üzerinden her bir modelin performansı değerlendirilmiştir.

4.1. Uzun Kısa Süreli Bellek Sonuçları (Long Short-Term Memory Results)


LSTM modeliyle eğitilen ve gelecekteki satış verilerini tahmin etmeyi amaçlayan yöntem %92,6 başarımla elde etmiştir. Şekil 4'teki grafikte 22 ay boyunca elde edilen günlük veriler ve tahmin edilen son 5 ayın durumu gösterilmektedir.



Şekil 4. LSTM ile tahminlerin ve tüm verilerin karşılaştırılması (Comparison of LSTM data and predictions)

Şekil 4'te, modelin gerçek satış verileri ile bu veriler üzerinde yaptığı tahminlerin karşılaştırması gösterilmektedir. Modelin %92,6 başarı elde etmesi, genel olarak gerçek satış verileri ile tahmin edilen veriler arasında güçlü bir uyum olduğunu göstermektedir.

Şekil 5'te son 5 ay için LSTM modelinin gerçek ve tahmini satış tutarlarını zaman içinde karşılaştırılması gösterilmektedir.



Şekil 5. LSTM ile gerçek ve tahmini satış tutarlarının karşılaştırması (Actual and estimated sales comparison with LSTM)

Şekil 5, modelin performansını daha yakından inceleme fırsatı sunmaktadır. Grafik üzerinde, gerçek satışlar ile modelin tahmin ettiği satışlar arasındaki benzerlik veya farklar daha ayrıntılı bir şekilde incelenebilir. Eğer modelin başarısı yüksekse, bu grafikte gerçek ve tahmini satış tutarları arasında belirgin bir benzerlik görülecektir.

%92,6 başarı elde edilen bu LSTM modeli, genel olarak gelecekteki satış verilerini başarılı bir şekilde tahmin edebilmektedir. Ancak, özellikle Şekil 2'ye odaklanarak, belirli zaman dilimlerinde modelin tahminlerinin gerçek verilerden ne kadar sapma gösterdiği analiz edilmelidir. Bu inceleme, modelin belirli koşullar altında ne kadar güvenilir olduğunu ve hangi durumlarda hatalar yapabileceğini anlamak için önemlidir.

4.2. Çift Yönlü Uzun Kısa Süreli Bellek Sonuçları (Bidirectional Long Short-Term Memory Results)

BiLSTM modeliyle eğitilen ve gelecekteki satış verilerini tahmin etmeyi amaçlayan yöntem %93,7 başarı elde etmiştir. Şekil 6'da gösterilen grafikte 22 ay boyunca elde edilen günlük veriler ve tahmin edilen son 5 ayın durumu gösterilmektedir.



Şekil 6. BiLSTM ile tahminlerin ve tüm verilerin karşılaştırılması (Comparison of BiLSTM data and predictions)

Grafikte, modelin gerçek satış verileri ile bu veriler üzerinde yaptığı tahminlerin karşılaştırması gösterilmektedir. Modelin %93,7 başarı elde etmesi, genel olarak gerçek satış verileri ile tahmin edilen veriler arasında LSTM

modeline göre daha güçlü bir uyum olduğunu göstermektedir.

Şekil 7'de son 5 ay için BiLSTM modelinin gerçek ve tahmini satış tutarlarını zaman içinde karşılaştırılması gösterilmektedir.




Şekil 7. BiLSTM ile gerçek ve tahmini satış tutarlarının karşılaştırması (Actual and estimated sales comparison with BiLSTM)

%93,7 başarı elde eden BiLSTM modeli, genel olarak gelecekteki satış verilerini LSTM modeline göre daha etkili bir biçimde tahmin edebilmektedir. Özellikle Şekil 7'ye odaklanarak, belirli zaman dilimlerinde modelin tahminlerinin gerçek verilere göre olan sapmalarının analizi büyük önem taşımaktadır. Bu detaylı inceleme, modelin belirli koşullar altında ne kadar güvenilir olduğunu ve hangi durumlarda hata yapabileceğini anlamak için kritik bir rol oynamaktadır.

4.3. Kapı Özyinelemeli Geçit Sonuçları (Gated Recurrent Unit Results)

GRU modeliyle eğitilen ve gelecekteki satış verilerini tahmin etmeyi amaçlayan yöntem %86,6 başarı elde etmiştir. Şekil 8'deki grafikte 22 ay boyunca elde edilen günlük veriler ve tahmin edilen son 5 ayın durumu gösterilmektedir.



Şekil 8. GRU ile tahminlerin ve tüm verilerin karşılaştırılması (Comparison of GRU data and predictions)

Grafikte, modelin gerçek satış verileri ile bu veriler üzerinde yaptığı tahminlerin karşılaştırması gösterilmektedir. Modelin %86,6 başarı elde etmesi, genel olarak gerçek satış verileri ile tahmin edilen veriler arasında güçlü bir uyum olduğunu göstermektedir.

Şekil 9'da son 5 ay için GRU modelinin gerçek ve tahmini satış tutarlarını zaman içinde karşılaştırılması gösterilmektedir.



Şekil 9. GRU ile tahmin edilen ve gerçek satış tutarlarının karşılaştırması (Actual and estimated sales comparison with GRU)

%86,6 başarı elde eden GRU modeli gelecekteki satış verilerini LSTM ve BiLSTM modeline göre daha az yakınlıkta tahminde bulunmaktadır. Özellikle Şekil 9'a odaklanarak, belirli zaman dilimlerinde modelin tahminlerinin gerçek

verilere göre olan sapmalarının analizi büyük önem taşımaktadır. Bu detaylı inceleme, modelin belirli koşullar altında ne kadar güvenilir olduğunu ve hangi durumlarda hata yapabileceğini anlamak için kritik bir rol oynamaktadır.

4.4. Çift Yönlü Kapı Özyinelemeli Geçit Sonuçları (Bidirectional Gated Recurrent Unit Results)

BiGRU modeliyle eğitilen ve gelecekteki satış verilerini tahmin etmeyi amaçlayan yöntem %94,7 başarımla elde etmiştir. Şekil 10'daki grafikte 22 ay boyunca elde edilen günlük veriler ve tahmin edilen son 5 ayın durumu gösterilmektedir.



Şekil 10. BiGRU ile tahminlerin ve tüm verilerin karşılaştırılması (Comparison of BiGRU data and predictions)

Grafikte, modelin gerçek satış verileri ile bu veriler üzerinde yaptığı tahminlerin karşılaştırması gösterilmektedir. Modelin %94,7 başarımla elde etmesi, genel olarak gerçek satış verileri ile tahmin edilen veriler arasında güçlü bir uyum olduğunu göstermektedir.

Şekil 11'de son 5 ay için BiGRU modelinin gerçek ve tahmini satış tutarlarını zaman içinde karşılaştırılması gösterilmektedir.

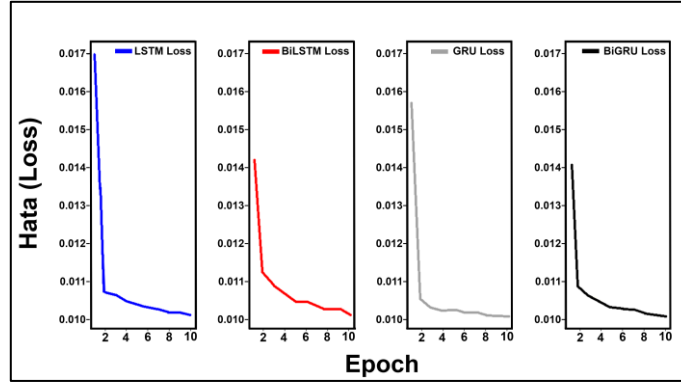


Şekil 11. BiGRU ile tahmin edilen ve gerçek satış tutarlarının karşılaştırması (Actual and estimated sales comparison with BiGRU)

Bu çalıştırma aşamasında %94,7 başarımla elde eden BiGRU modeli gelecekteki satış verilerini LSTM, BiLSTM ve GRU modellerine göre daha etkili bir biçimde tahmin edebilmektedir. Özellikle Şekil 10'a odaklanarak, belirli zaman dilimlerinde modelin tahminlerinin gerçek verilere göre olan sapmalarının analizi büyük önem taşımaktadır. Bu detaylı inceleme, modelin belirli koşullar altında ne kadar güvenilir olduğunu ve hangi durumlarda hata yapabileceğini anlamak için kritik bir rol oynamaktadır.

4.5 Satış Tahmininde Yöntemlerin Kıyaslanması (Comparison of Methods in Sales Forecasting)

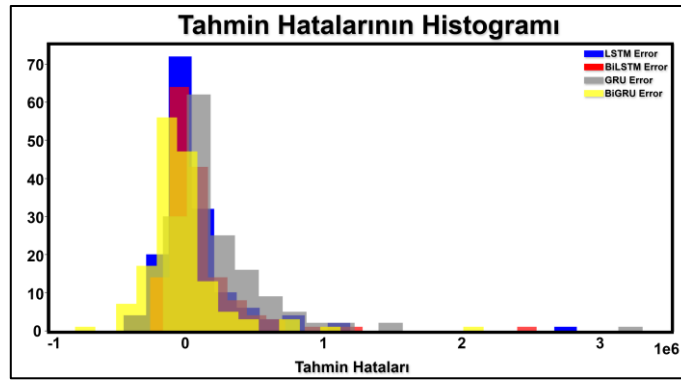
Eğitim (Loss) değeri modellerin eğitim sürecindeki hata değerlerinin epoch (eğitim iterasyonu) sayısına göre değişimini gösterir. Bu, grafik modelin ne kadar iyi öğrendiğini ve eğitildiğini değerlendirmek için kullanılır. İdeal durumda, eğitim hatası zamanla azalmalıdır. Daha fazla düşmediği yere kadar geldiğinde iterasyonların durdurulması önerilir. Şekil 12'de LSTM, BiLSTM, GRU ve BiGRU için Eğitim (Loss) değerleri gösterilmiştir.



Şekil 12. Modellerin eğitim loss değişimi (Training loss change of models)

Bu grafik, her bir modelin eğitim sürecindeki performansını karşılaştırmak ve hangi modelin daha hızlı veya daha iyi öğrendiğini belirlemek için kullanılır. Modelin öğrenme sürecini doğru bir şekilde değerlendirmek, uygun bir model seçimi ve aşırı öğrenmeyi önlemek için önemlidir.

Şekil 13'teki grafik, her bir modelin yaptığı tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini gösterir. Histogram, tahmin hatalarının dağılımını belirtir. İdeal durumda, hataların ortalaması sıfır olmalıdır.



Şekil 13. Modellerin tahmin hatalarının histogramı (Histogram of models' forecast errors)

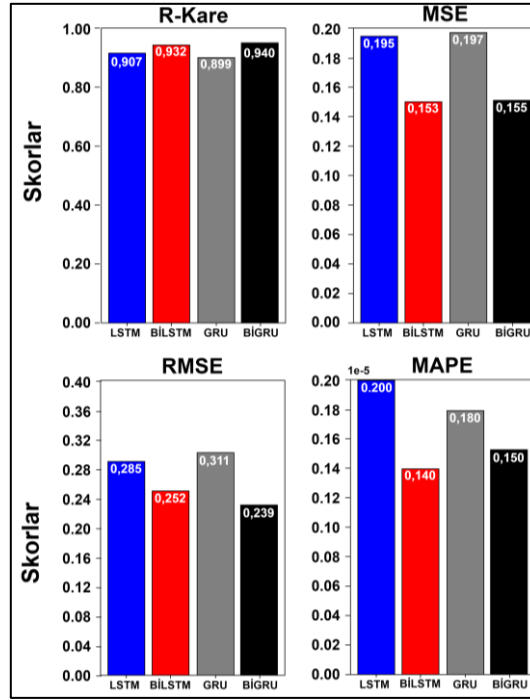
Histogram, tahmin hatalarının hangi aralıklarda yoğunlaştığını ve hangi aralıklarda daha az yoğun olduğunu göstererek, modellerin belirli hata düzeylerinde ne kadar başarılı olduğunu ortaya koyar. Bu analiz, her bir modelin belirli durumlarda daha iyi veya daha kötü performans gösterip göstermediğini anlamak açısından önemlidir. Ayrıca, eğer hataların ortalaması sıfıra yakın değilse, bu durum modelin belirli koşullarda sistematik bir sapma yapabileceğini gösterebilir. LSTM daha pozitif değerlerde sapmalar yaşarken BiLSTM 0'a oldukça yakın sapmalar yapmaktadır. Bu durum BiLSTM yönteminin LSTM yöntemine göre daha doğru sonuç elde etmesiyle sonuçlanır.

Bu uygulamada R-kare, MAE, RMSE, MAPE değerleri her bir model için ayrı şekilde hesaplanmıştır. R-kare modelin tahmin yeteneğini ölçer. 1'e ne kadar yakınsa, modelin tahmin yeteneği o kadar iyidir. MAE Gerçek ve tahmini değerler arasındaki ortalama mutlak hatayı gösterir. RMSE Hata karelerinin ortalamasının kareköküdür. Büyük hataları vurgular. MAPE Yüzde cinsinden ortalama mutlak hatadır, büyük hataları vurgular.

Bu metrikler, modellerin performansını karşılaştırmak ve hangi modelin verilere daha iyi uyduğunu belirlemek için kullanılır. Her bir metrik, belirli bir yönüyle modelin performansını ölçer, bu nedenle birden fazla metriği göz önünde bulundurmak genellikle daha sağlıklı bir değerlendirme sağlar.

Şekil 14'te bu metriklerin LSTM, BiLSTM, GRU ve BiGRU modelleri için sonucu gösterilmektedir.

Bu metrikler, modellerin performansını objektif bir şekilde değerlendirmek ve karşılaştırmak için kullanılır. Şekil 14, her bir modelin belirli metriklerdeki performansını görsel olarak karşılaştırarak, hangi modelin belirli bir ölçüt üzerinde daha iyi veya daha zayıf performans gösterdiğini anlamamıza yardımcı olur. Daha doğru sonuçlar elde etmiş olduğumu gözlemlediğimiz BiLSTM ve BiGRU yöntemleri daha yüksek R-kare, daha düşük MAE, MAPE VE RMSE değerleriyle dikkat çekmektedir.



Şekil 14. Hata metriklerinin karşılaştırılması (Comparison of error metrics)

Tablo 2, farklı modellerin performansını ölçen çeşitli hata metriklerini içermektedir. Hata metrikleri arasında R-kare, MAE, RMSE ve MAPE bulunmaktadır. Her model için en kötü, en iyi ve ortalama performans değerleri verilmiştir. Bu değerler belirlenen hiperparametre değerleriyle yapılan 10 tekrarlı çalışmanın sonucu olarak raporlanmıştır.

Tablo 1'deki hata metrik sonuçları incelediğinde; LSTM, BiLSTM, GRU ve BiGRU modelleri arasında en iyi performans BiGRU modeliyle elde edilmiştir. BiGRU modeli, ortalama R-kare değeri olarak 0,940, ortalama MAE değeri olarak 0,155, ortalama RMSE değeri olarak 0,239 ve ortalama MAPE değeri olarak 0,016 elde etmiştir. Bu değerler, modelin genel olarak verilere daha iyi uyum sağladığını ve tahminlerinin gerçek değerlere daha yakın olduğunu göstermektedir.

Tablo 2. Modellere göre hata metriklerinin karşılaştırılması (Comparison of error metrics according to models)

MODEL	SENARYO	R-KARE	MAE	RMSE	MAPE
LSTM	En Kötü	0,749	0,359	0,500	0,032
	Ortalama	0,907	0,195	0,285	0,020
	En İyi	0,974	0,096	0,158	0,012
BiLSTM	En Kötü	0,864	0,230	0,368	0,018
	Ortalama	0,932	0,153	0,252	0,014
	En İyi	0,979	0,092	0,142	0,011
GRU	En Kötü	0,838	0,276	0,402	0,024
	Ortalama	0,899	0,197	0,311	0,018
	En İyi	0,956	0,150	0,208	0,014
BiGRU	En Kötü	0,901	0,18	0,314	0,016
	Ortalama	0,940	0,155	0,239	0,015
	En İyi	0,968	0,112	0,177	0,013

Diğer taraftan, en kötü performans GRU modeliyle elde edilmiştir. GRU modeli, en düşük ortalama R-kare değeri olan 0,899, en yüksek ortalama MAE değeri olan 0,197, en yüksek ortalama RMSE değeri olan 0,311 ve yüksek ortalama MAPE değeri olan 0,018 elde etmiştir. Bu sonuçlar, GRU modelinin diğer modellere göre daha düşük performans gösterdiğini göstermektedir.

Genel olarak bakıldığında, BiLSTM ve BiGRU modellerinin diğer modellere göre daha iyi performans sergilediği gözlemlenmiştir. Bu modeller, R-kare, MAE, RMSE ve MAPE değerleri açısından daha iyi sonuçlar elde etmiştir. Bu, zaman serisi tahminleme görevinde tekrar eden işlemlerde bu veriseti özelinde çift yönlü modellerin daha etkili olduğunu göstermektedir.

5. Sonuç ve Tartışma (Result and Discussion)

Bu çalışma, mobilya sektöründeki bir firmanın satış verilerinin tahminlerini gerçekleştirmek için LSTM, BiLSTM, GRU ve BiGRU olmak üzere dört farklı RNN modeli kullanılarak bir zaman serisi analizini detaylı bir şekilde incelemektedir. Çalışma, zaman serisi tahminleme problemini ele almaktadır. Kullanılmış olan RNN modellerinin her birinin performansını değerlendirmek için R-kare, MAE, RMSE ve MAPE gibi dört temel metrik kullanılmıştır. Tekrarlayan işlemlerdeki alınan ortalama sonuçlar incelendiğinde, BiGRU modelinin diğerlerine kıyasla daha yüksek bir R-kare değeri (0.940) ve daha düşük hata oranlarına sahip olduğu görülmüştür. BiGRU'nun ardından sırasıyla BiLSTM (0.932), LSTM (0.907), ve GRU (0.899) modelleri gelmektedir.

Modellerin en iyi durumlarının sonuçlarına bakıldığında ise, BiLSTM modelinin en yüksek R-kare değerine, en düşük MAE, RMSE ve MAPE değerlerine sahip olduğu gözlemlenmektedir. Sonuç olarak, bu çalışma BiGRU ve BiLSTM modellerinin genel performans açısından etkileyici sonuçlar elde ettiğini, ancak ortalamada en yüksek performansın BiGRU modeli tarafından sağlandığını ortaya koymaktadır.

Bidirectional (İki Yönlü) yapıya sahip modeller, özellikle BiGRU ve BiLSTM, tek değişkenli zaman serisi tahminleme görevlerinde üstün performans göstermektedir. Bu yapı, geçmiş ve gelecek bilgileri aynı anda entegre ederek daha kapsamlı bir bağlam oluşturur. Bu sayede, geçmiş verilere dayalı olarak gelecekteki değerleri tahmin etmekle kalmaz, aynı zamanda gelecek bilgilerini de dikkate alarak daha güçlü ve tutarlı tahminler yapar. Bu özellik, zaman içindeki desenleri daha iyi anlama ve öğrenme yeteneği sağlar, bu da tek değişkenli zaman serisi tahminleme görevlerinde büyük bir avantaj sağlar. Her bir modelin güçlü ve zayıf yönleri dikkate alındığında, uygulama senaryosuna bağlı olarak seçilecek en iyi modelin belirlenmesi önemli bir karar sürecini gerektirebilir. Bu yapı için Bidirectional yapıya sahip modellerin seçilmesi daha gerçekçi sonuçlar elde edilebileceğini göstermektedir.

Gelecekteki çalışmalarda modellerin performansını artırmak için çeşitli yaklaşımlar kullanılabilir. Öncelikle, farklı hiperparametre kombinasyonlarının dikkatlice incelenmesi ve modelin en iyi performans gösterdiği kombinasyonların belirlenmesi gerekmektedir. Bunun için geniş bir hiperparametre aralığında denemeler yapılabilir ve en iyi sonuçları veren parametreler seçilebilir. Ayrıca, modelin daha iyi genelleştirme yapabilmesi için daha geniş bir zaman aralığında eğitilmesi düşünülebilir.

Veri seti işlemleri dışında başarıyı artırma için YSA dışında farklı makine öğrenimi modellerinin kullanılması da düşünülebilir. Destek vektör makineleri, karar ağaçları veya rastgele ormanlar gibi farklı modellerin performansı karşılaştırılarak en uygun olanı seçilebilir. Bu şekilde, modelin tahmin yeteneği artırılabilir.

Yine gelecek çalışmalarda performans metriklerini iyileştirmek için model fine-tuning süreçleri uygulanabilir. Bu süreçte, modelin parametreleri daha küçük bir öğrenme oranı veya daha uzun eğitim süreleri gibi farklı ayarlarla tekrar eğitilir ve performansı iyileştirilir. Ayrıca, modelin daha iyi sonuçlar vermesi için özellik seçimi veya özellik mühendisliği gibi stratejiler de denenebilir. Sonuç olarak, bu önerilerin ve analizlerin dikkate alınması, gelecekteki satış tahminleme çalışmalarında daha iyi performans elde etmek için önemlidir. Modelin doğruluğunu artırmak için yapılan her adım, işletmelerin karar alma süreçlerinde daha güvenilir ve etkili tahminler yapmalarına yardımcı olacaktır.

Bu çalışma, BiGRU ve BiLSTM modellerinin zaman serisi tahminlerinde üstün performans gösterdiğini ortaya koymuştur. BiGRU, en yüksek doğruluk ve en düşük hata oranları ile öne çıkarken, BiLSTM de etkileyici sonuçlar sağlamıştır. Gelecekte, model performansını artırmak için hiperparametre ayarları ve model optimizasyonları yapılabilir. Doğru model seçiminin, satış tahminlerinin doğruluğunu artırarak stratejik karar alma süreçlerine önemli katkı sağlayacağı düşünülmektedir.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Acar, G. (2022). Zaman serisi yöntemleri ve XGBoost algoritması ile kömür satış tahmini: Türkiye Tarım Kredi Kooperatifleri uygulaması = Sales prediction using time series and XGBoost algorithm: Application of Agricultural Credit Cooperatives of Turkey. <https://acikerisim.sakarya.edu.tr/handle/20.500.12619/101133>
- Agarwal, H., Mahajan, G., Shrotriya, A. ve Shekhawat, D. (2024). Predictive Data Analysis: Leveraging RNN and LSTM Techniques for Time Series Dataset. *Procedia Computer Science*, 235, 979-989. doi:10.1016/J.PROCS.2024.04.093

- Akçay, H. ve Yiltas-Kaplan, D. (2024). ZAMAN SERİLERİ TAHMİNLEME ALGORİTMALARI İLE KONTÖR TÜKETİM TAHMİNLEMESİ VE KARŞILAŞTIRMALI UYGULAMASI. Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences, 27(1), 166-189. doi:10.17780/KSUJES.1369811
- Çalasan, M., Abdel Aleem, S. H. E. ve Zobaa, A. F. (2020). On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function. Energy Conversion and Management, 210, 112716. doi:10.1016/J.ENCONMAN.2020.112716
- Chai, T. ve Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. Geoscientific Model Development, 7(3), 1247-1250. doi:10.5194/GMD-7-1247-2014
- Chen, Y., Xie, X., Pei, Z., Yi, W., Wang, C., Zhang, W. ve Ji, Z. (2024). Development of a Time Series E-Commerce Sales Prediction Method for Short-Shelf-Life Products Using GRU-LightGBM. Applied Sciences 2024, Vol. 14, Page 866, 14(2), 866. doi:10.3390/APP14020866
- ChenShijie, ZhangYu ve YangQiang. (2024). Multi-Task Learning in Natural Language Processing: An Overview. ACM Computing Surveys. doi:10.1145/3663363
- Chicco, D., Warrens, M. J. ve Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. PeerJ Computer Science, 7, 1-24. doi:10.7717/PEERJ-CS.623/SUPP-1
- Chung, J., Gulcehre, C., Cho, K. ve Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. <https://arxiv.org/abs/1412.3555v1>
- Civelek, Ç. (2021). Yapay Sinir Ağları Kullanarak Türkiye Traktör Satış Adedinin Tahmin Edilmesi. Avrupa Bilim ve Teknoloji Dergisi, (31), 375-381. doi:10.31590/EJOSAT.1000964
- de Myttenaere, A., Golden, B., Le Grand, B. ve Rossi, F. (2016). Mean Absolute Percentage Error for regression models. Neurocomputing, 192, 38-48. doi:10.1016/J.NEUCOM.2015.12.114
- Dey, R. ve Salemt, F. M. (2017). Gate-variants of Gated Recurrent Unit (GRU) neural networks. Midwest Symposium on Circuits and Systems, 2017-August, 1597-1600. doi:10.1109/MWSCAS.2017.8053243
- Ecemiş, O. ve Irmak, S. (2018). PASLANMAZ ÇELİK SEKTÖRÜ SATIŞ TAHMİNİNDE VERİ MADENCİLİĞİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI. Sosyal Bilimler Dergisi, 8(15), 148-169. doi:10.31834/KILISSBD.395317
- Elmasdotter, A. ve Nyströmer, C. (2018). A comparative study between LSTM and ARIMA for sales forecasting in retail. DEGREE PROJECT TECHNOLOGY. <https://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-229747>
- Erol, B. ve İnkaya, T. (2023). Satış tahmini için uzun kısa-süreli bellek ağı tabanlı derin transfer öğrenme yaklaşımı. Gazi Üniversitesi Mühendislik Fakültesi Dergisi, 39(1), 191-202. doi:10.17341/GAZIMMFD.1089173
- Fetzer, J. H. (1990). What is Artificial Intelligence?, 3-27. doi:10.1007/978-94-009-1900-6_1
- Gers, F. A., Schmidhuber, J. ve Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. Neural Computation, 12(10), 2451-2471. doi:10.1162/089976600300015015
- Ghazouani, I., Masmoudi, I., Mejri, I. ve Layeb, S. B. (2024). A CNN-LSTM Hybrid Deep Learning Model for Detergent Products Demand Forecasting: A Case Study. International Journal of Supply and Operations Management, 0, xx-xx. doi:10.22034/IJSOM.2024.109931.2752
- Graves, A. ve Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. Neural Networks, 18(5-6), 602-610. doi:10.1016/J.NEUNET.2005.06.042
- Gür, Y. E., Eşidir, K. A. ve Kaldırımçı, Ş. G. (2024). Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı. Afyon Kocatepe University Journal of Economics and Administrative Sciences, 26(Özel Sayı), 17-34. doi:10.33707/AKUİIBFD.1426338
- Gürpınar, K. ve Barca, M. (2007). Türk Mobilya Sektörünün Uluslararası Rekabet Gücü Düzeyi ve Nedenleri. Kocatepe Üniversitesi Sandıklı MYO, Afyon Üniversitesi İİBF, Sakarya Bölümü, İşletme, 2(2), 41-61.
- Hazır, E., Koç, K. H. ve Esnaf, Ş. (2016). Türkiye Mobilya Satış Değerlerinin Örnek Bir Yapay Zeka Uygulaması ile Tahmini. Selçuk Üniversitesi Teknik Online Dergisi, 7(2), 343-354. doi:10.2/JQUERY.MIN.JS
- Hochreiter, S. ve Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780. doi:10.1162/NECO.1997.9.8.1735
- Huang, Z., Research, B., Xu, W. ve Baidu, K. Y. (2015). Bidirectional LSTM-CRF Models for Sequence Tagging. <https://arxiv.org/abs/1508.01991v1>
- Hülsmann, M., Borscheid, D., Friedrich, C. M. ve Reith, D. (2011). General Sales Forecast Models for Automobile Markets Based on Time Series Analysis and Data Mining Techniques. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 6870 LNAI, 255-269. doi:10.1007/978-3-642-23184-1_20
- Jakobsson, A. ve Svahn, M. (2023). "In the middle of difficulty lies opportunity": A qualitative study on inflation and uncertainties impact on global furniture export companies. <https://urn.kb.se/resolve?urn=urn:nbn:se:lnu:diva-122464>
- Karaatlı, M., Helvacioğlu, C. ve Tokgöz, G. (2012). YAPAY SİNİR AĞLARI YÖNTEMİ İLE OTOMOBİL SATIŞ TAHMİNİ. Uluslararası Yönetim İktisat ve İşletme Dergisi, 8(17), 87-100. doi:10.11122/IJMEB.2012.8.17.290
- Kayakuş, M., Terzioğlu, M., Yağmur, A. ve Erdoğan, D. (2023). Forecasting Light Commercial Vehicle Sales in Turkey by Machine Learning Methods. Journal of Engineering Sciences, 9(4), 100-112. doi:10.30855/gmbd.0705S11
- Khasim, S., Ghosh, H., Rahat, I. S., Shaik, K. ve Yesubabu, M. (2024). Deciphering Microorganisms through Intelligent Image Recognition: Machine Learning and Deep Learning Approaches, Challenges, and Advancements. EAI Endorsed Transactions on Internet of Things, 10. doi:10.4108/EETIOT.4484
- Kingma, D. P. ve Ba, J. L. (2014). Adam: a method for stochastic optimization. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, 2023, 1-13. doi:10.1155/2023/7037124
- Kurtgeri, B. (2024). Yapay sinir ağları ve makine öğrenmesi ile otomobil satış tahmininin yapılması ve zaman serileri analizi ile karşılaştırılması. <https://acikerisim.sakarya.edu.tr/handle/20.500.12619/102419>
- Lecun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. Nature 2015 521:7553, 521(7553), 436-444. doi:10.1038/nature14539

- Li, X., Ma, X., Xiao, F., Xiao, C., Wang, F. ve Zhang, S. (2022). Time-series production forecasting method based on the integration of Bidirectional Gated Recurrent Unit (Bi-GRU) network and Sparrow Search Algorithm (SSA). *Journal of Petroleum Science and Engineering*, 208, 109309. doi:10.1016/J.PETROL.2021.109309
- Nacar, E. N., Erdebilli, B. ve Rouyendegh, B. D. (2021). MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE SATIŞ TAHMİNİ. *Endüstri Mühendisliği*, 32(2), 307-320. doi:10.46465/ENDUSTRIMUHENDISLIGI.811183
- Öztatlıcı, M., Eroğlu, S., Öztatlıcı, H. ve Göl, M. (2024). Artificial Intelligence in Diagnosis and Treatment. *Experimental and Applied Medical Science*, 5(2), 107-118. doi:10.46871/EAMS.1470170
- Öztürk, K. ve Şahin, M. E. (2018). A General View of Artificial Neural Networks and Artificial Intelligence, 6(2), 25-36. <http://www.sloi.org/sloi-name-of-this-article>
- Pacal, I. (2024). Improved Vision Transformer with Lion Optimizer for Lung Diseases Detection. *International Journal of Engineering Research and Development*, 16(2), 760-776. doi:10.29137/UMAGD.1469472
- Parmezan, A. R. S., Souza, V. M. A. ve Batista, G. E. A. P. A. (2019). Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. *Information Sciences*, 484, 302-337. doi:10.1016/J.INS.2019.01.076
- Qassrawi, N., Azzeh, M. ve Hijjawi, M. (2024). Drug sales forecasting in the pharmaceutical market using deep neural network algorithms. *International Journal of Systematic Innovation*, 8(3), 63-83. doi:10.6977/IJOSI.202409_8(3).0006
- Salttürk, B. (2022). Yapay sinir ağları ile ürün satış miktarlarının tahmini: Mobilya sektöründe bir uygulama = Forecasting product sales amounts by artificialneural network: An application in the furnitureindustry. <https://acikerisim.sakarya.edu.tr/handle/20.500.12619/101150>
- Şermet, F. ve Pacal, I. (2024). Deep learning approaches for autonomous crack detection in concrete wall, brick deck and pavement. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 15(2), 503-513. doi:10.24012/DUMF.1450640
- Sevinç, A. ve Kaya, B. (2021). Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneği. *Computer Science, (Special)*, 217-225. doi:10.53070/BBD.990966
- Sharma, R. (2012). Sales Forecast of an Automobile Industry. *Article in International Journal of Computer Applications*, 53(12), 975-8887. doi:10.5120/8474-2403
- Sinap, V. (2024). Perakende Sektöründe Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Performans Analizi: Black Friday Satış Tahminleme. *Journal of Selçuk University Social Sciences Vocational School*, 27(1), 65-90. doi:10.29249/SELÇUKSBMYD.1401822
- Sönmez, O. ve Zengin, K. (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. *European Journal of Science and Technology*, 302-308. doi:10.31590/EJOSAT.638104
- Wang, J., Zhao, R., Wang, D., Yan, R., Mao, K. ve Shen, F. (2017). Machine health monitoring using local feature-based gated recurrent unit networks. *IEEE Transactions on Industrial Electronics*, 65(2), 1539-1548. doi:10.1109/TIE.2017.2733438
- Yılmaz, H. ve Tosun, Ö. (2020). AYLİK KONUT SATIŞLARININ MODELLENMESİ VE ANTALYA ÖRNEĞİ. *Kafkas University Journal of Economics and Administrative Sciences Faculty*, 11(21), 141-158. doi:10.36543/KAUIIBFD.2020.007
- Yücesan, M. (2018). YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. *İşletme Araştırmaları Dergisi*, 10(1), 689-706.
- Yucesan, M., Gul, M. ve Celik, E. (2017). Primjena umjetnih neuronskih mreža uz pomoć Bayesova pravila učenja u predviđanju prodaje za industriju namještaja. *Drvna industrija*, 68(3), 219-228. doi:10.5552/DRIND.2017.1706
- Yucesan, M., Gul, M. ve Celik, E. (2018). Performance Comparison between ARIMAX, ANN and ARIMAX-ANN Hybridization in Sales Forecasting for Furniture Industry. *Drvna industrija*, 69(4), 357-370. doi:10.5552/DRIND.2018.1770
- Yurtsever, M. (2022). LSTM YÖNTEMİ İLE EKONOMİK GÖSTERGELER KULLANILARAK OTOMOBİL SATIŞ TAHMİNİ. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 12(3), 1481-1492. doi:10.30783/NEVSOSBİLEN.987093
- Zeiler, M. D. (2012). ADADELTA: An Adaptive Learning Rate Method. <https://arxiv.org/abs/1212.5701v1>
- Zhang, J., Zeng, Y. ve Starly, B. (2021). Recurrent neural networks with long term temporal dependencies in machine tool wear diagnosis and prognosis. *SN Applied Sciences*, 3(4), 1-13. doi:10.1007/S42452-021-04427-5/FIGURES/7
- Zhao, K. ve Wang, C. (2017). Sales Forecast in E-commerce using Convolutional Neural Network. <https://arxiv.org/abs/1708.07946v1>