



T.C.

BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**MOBİLYA SATIŞ TAHMİNİ İÇİN TEKRARLAYAN SINIR AĞLARI VE
TOPLULUK ÖĞRENMESİNİ BİRLEŞTİREN HİBRİT BİR ZAMAN SERİSİ
TAHMİN MODELİ**

YÜKSEK LİSANS TEZİ

ONUR ŞAHİN

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2026

10806193

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĐİ TEZLİ YÜKSEK LİSANS PROGRAMI

**MOBİLYA SATIŐ TAHMİNİ İÇİN TEKRARLAYAN SİNİR AĐLARI VE
TOPLULUK ÖĐRENMESİNİ BİRLEŐTİREN HİBRİT BİR ZAMAN SERİSİ
TAHMİN MODELİ**

YÜKSEK LİSANS TEZİ

ONUR ŐAHİN

TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2026

10806193

BEYAN

Mobilya Satış Tahmini İçin Tekrarlayan Sinir Ağları ve Topluluk Öğrenmesini Birleştiren Hibrit Bir Zaman Serisi Tahmin Modeli başlıklı yüksek lisans tezinin hazırlık ve yazım aşamasında bilimsel araştırma ve etik kurallarına uyduğumu, Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Faaliyetlerinde Üretken Yapay Zekâ Kullanımına Dair Etik Rehberine uygun olarak tezimi hazırladığımı, başkalarının eserlerinden yararlandığım bölümlerde bilimsel etik kurallarına uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, çalışmamın herhangi bir kısmının başka bir tez olarak sunulmadığını, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Onur Şahin

...../...../2026

İmza:

ÖN SÖZ

Bu tez çalışması, mobilya satış tahminleri için derin öğrenme ve topluluk öğrenme algoritmalarını birleştiren özgün bir hibrit model önermektedir. Modelin geliştirilmesi sürecinde sağladıkları veri desteği için Bursa merkezli bir mobilya üretim ve perakende şirketine teşekkür ederim. Ayrıca, çalışmanın her aşamasında sunduğu rehberlik ve değerli katkılar için danışmanım Sayın Dr. Öğr. Üyesi Burakhan ÇUBUKÇU'ya şükranlarımı sunarım. Tezde önerilen modelin temel bulgularını özetleyen makale Şahin ve Çubukçu (2026) tarafından Ain Shams Engineering Journal dergisinde yayımlanmıştır.

ÖZET

Mobilya sektöründe talep tahmini, stok yönetimi, üretim planlaması ve tedarik zinciri optimizasyonu açısından kritik bir öneme sahiptir. Perakende satış verilerinin yüksek değişkenliği, mevsimsel dalgalanmalar ve düzensiz sipariş örüntüleri, geleneksel istatistiksel yöntemlerin yetersiz kalmasına neden olmaktadır. Son yıllarda derin öğrenme tabanlı yaklaşımlar bu alanda umut verici sonuçlar sunmuş olsa da tek başına kullanılan modellerin karmaşık zamansal bağımlılıkları yeterince yakalayamadığı görülmektedir. Bu çalışmada, modüler bir çoklu yama yapısı içinde tekrarlayan sinir ağlarını ve topluluk öğrenme algoritmalarını birleştirerek tek adımlı (one-step-ahead) zaman serisi tahmininin doğruluğunu ve kararlılığını artırmak amacıyla MP-LRNet adlı bir derin öğrenme modeli önerilmektedir. Model, farklı zaman aralıklarındaki zamansal desenleri öğrenmek ve sıralı verilerdeki hem kısa hem de uzun dönem bağımlılıkları yakalamak için tasarlanmıştır. MP-LRNet'in performansını değerlendirmek için gerçek bir mobilya satış veri seti kullanılarak deneyler yapılmıştır. Önerilen model, on bağımsız çalışmada ortalama 0,9918 R^2 üretmiş; en iyi yinelemede 0,9927 R^2 değerine ulaşmıştır. Çoklu yama yapısı zamansal temsili geliştirirken, önerilen MP-LRNet yapılandırması (LSTM + Random Forest + (7,14) yama), bu veri seti ve deney protokolü altında dengeli sonuçlar üretmiştir. Bulgular, MP-LRNet'in mobilya satış tahmini bağlamında bu veri seti üzerinde umut verici bir performans gösterdiğine işaret etmektedir. Modelin genellenebilirliği, UCI Household Electric Power Consumption halka açık veri seti üzerinde doğrulanmış ve aynı performans sıralamasının farklı bir alanda da korunduğu gösterilmiştir. Gelecek çalışmalarda önerilen model trafik ve çevresel zaman serileri gibi farklı alanlara uygulanarak modelin başarımının genelliğinin artırılması hedeflenmektedir.

Anahtar Kelimeler: Hibrit derin öğrenme modeli, satış tahmini, tekrarlayan sinir ağı, topluluk öğrenme algoritmaları, zaman serisi tahmini

ABSTRACT

Demand forecasting in the furniture industry is of critical importance for inventory management, production planning, and supply chain optimization. The high variability of retail sales data, seasonal fluctuations, and irregular order patterns render traditional statistical methods insufficient. Although deep learning-based approaches have yielded promising results in this domain in recent years, standalone models have been shown to inadequately capture complex temporal dependencies. In this study, a deep learning model named MP-LRNet is proposed to enhance the accuracy and stability of one-step-ahead time series forecasting by integrating recurrent neural networks and ensemble learning algorithms within a modular Multi-Patch framework. The model is designed to learn temporal patterns across different time intervals and to capture both short-term and long-term dependencies in sequential data. Experiments were conducted using a real-world furniture sales dataset to evaluate the performance of MP-LRNet. The proposed model yielded a mean R^2 of 0.9918 across ten independent runs, achieving an R^2 of 0.9927 in the best iteration. While the Multi-Patch structure enhanced temporal representation, the proposed MP-LRNet configuration (LSTM + Random Forest + (7,14) patch) produced well-balanced results for this dataset and experimental protocol. The findings indicate that MP-LRNet demonstrates promising performance on this dataset in the context of furniture sales forecasting. The generalizability of the model was validated on the UCI Household Electric Power Consumption public dataset, demonstrating that the same performance ranking was preserved in a different domain. Future work aims to extend the proposed model to traffic and environmental time series to further enhance the generalizability of its performance.

Keywords: Ensemble learning algorithms, hybrid deep learning model, recurrent neural networks, sales prediction, time series forecasting

İÇİNDEKİLER

ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR VE SİMGELER LİSTESİ	viii
1. GİRİŞ	10
2. LİTERATÜR TARAMASI	13
3. METOT.....	18
3.1. Veri Seti ve Veri Ön İşleme	19
3.1.1. Veri ön işleme akışı	20
3.1.2. Yeniden örnekleme ve veri bölme	20
3.1.3. Normalizasyon ve yama (patch) oluşturma süreci.....	20
3.1.4. Karşılaştırma için kullanılan evsel elektrik enerjisi tüketimi veri seti	21
3.2. Tekrarlayan Sinir Ağı Tabanlı Modeller	22
3.2.1. Uzun kısa süreli bellek (Long Short-Term Memory - LSTM)	22
3.2.2. Kapılı yinelemeli birim (Gated Recurrent Unit - GRU).....	24
3.2.3. LSTM ile GRU'nun karşılaştırılması.....	25
3.2.4. Çift yönlü uzun kısa süreli bellek (Bidirectional Long Short-Term Memory - BiLSTM).....	25
3.2.5. Çift yönlü kapılı yinelemeli birim (Bidirectional Gated Recurrent Unit - BiGRU).....	26
3.2.6. Ortak mimari yapı ve hiperparametre seçimi.....	27
3.3. Çalışmada Kullanılan Topluluk Öğrenme Algoritmaları	29
3.3.1. Rastgele orman (Random Forest - RF).....	30

3.3.2. Aşırı gradyan artırma (Extreme Gradient Boosting - XGB).....	30
3.3.3. Gradyan artırma regresörü (Gradient Boosting Regressor - GBM)	31
3.3.4. Histogram tabanlı gradyan artırma regresörü (Histogram-based Gradient Boosting Regressor - HGBR)	31
3.4. Çoklu Yama Yaklaşımı	31
3.5. MP-LRNet: Çoklu Yama LSTM-RF Ağı	32
3.5.1. Eğitim protokolü ve sistematik mimari karşılaştırma tasarımı	33
3.6. Performans Değerlendirme Metrikleri.....	34
4. DENEYSEL SONUÇLAR	37
4.1. Mevsimsel Momentum Katmanının Başarıma Etkisi	37
4.2. Çoklu Yamanın Başarıma Etkisi.....	37
4.3. Tekrarlayan Sinir Ağlarının Etkisi.....	38
4.4. Makine Öğrenmesi Algoritmalarının Başarıma Etkisi.....	38
4.5. MP-LRNet ve Diğer Modellerin Performans Karşılaştırması	39
4.6. Halka Açık Veri Seti Üzerindeki Sonuçlar.....	58
4.7. Bileşen Katkı Analizi ve Ablasyon Çalışması.....	59
4.8. İstatistiksel Anlamlılık ve Hesaplama Verimliliği	60
5. TARTIŞMA.....	62
5.1. Modelin Güçlü Yönleri, Sınırlılıkları ve Uygulama Anlamı.....	63
6. SONUÇLAR VE ÖNERİLER	66
KAYNAKÇA.....	68

TABLÖLAR LİSTESİ

Tablo 2.1. Zaman serisi tahmini üzerine yakın tarihte yapılan hibrit model çalışmaları.....	15
Tablo 3.1. Veri setinden örnek bir kesit	19
Tablo 3.2. Tekrarlayan sinir ağı tabanlı modellerde kullanılan hiperparametre değerleri	29
Tablo 4.1. LSTM tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)	43
Tablo 4.2. BiLSTM tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)	45
Tablo 4.3. GRU tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)	47
Tablo 4.4. BiGRU tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması).....	49
Tablo 5.1. Son dönem hibrit ve derin öğrenme tabanlı zaman serisi tahmin çalışmalarının karşılaştırılması	62

ŞEKİLLER LİSTESİ

Şekil 3.1. MP-LRNet ve modellerin	18
Şekil 3.2. Günlük net satış tutarı zaman serisi (çalışma girdisi ve ana değerlendirme çıktısı)	20
Şekil 3.3. UCI veri setinin günlük ortalama küresel aktif güç tüketimi zaman serisi.....	14
Şekil 3.4. LSTM mimarisi.....	23
Şekil 3.5. GRU mimarisi.....	24
Şekil 3.6. BiLSTM mimarisi.....	26
Şekil 3.7. BiGRU mimarisi	27
Şekil 3.8. Çoklu yama yaklaşımı mimarisi	32
Şekil 3.9. Çoklu Yama LSTM-RF Ağı mimarisi	33
Şekil 4.1. MP-LRNet satış tahmin sonuçları.....	40
Şekil 4.2. Gerçek ve tahmin edilen satış değerlerinin dağılımı (scatter)	41
Şekil 4.3. Modellerin ortalama performans metrikleri (R^2 , nMAE, nRMSE, MAPE) genel karşılaştırması.....	51
Şekil 4.4. Çoklu yama konfigürasyonlarına göre ortalama performans metrikleri.....	52
Şekil 4.5. En iyi performans gösteren konfigürasyonların metrik karşılaştırması.....	53
Şekil 4.6. Tekrarlayan sinir ağı ve topluluk öğrenme bileşenlerine göre ortalama eğitim süreleri (dakika).....	53
Şekil 4.7. Modellerin ortalama metriklerinin kutu grafiği (medyan, çeyrekler arası aralık, aykırı değerler)	54
Şekil 4.8. Topluluk (Ensemble) algoritmalarının R^2 skoru üzerindeki etkisi.....	55
Şekil 4.9. Test döneminde tahmin hatasının (gerçek - tahmin) zaman içindeki değişimi	55
Şekil 4.10. MP-LRNet test hatalarının dağılımı (histogram ve normallik)	56
Şekil 4.11. İşaretli yüzdelik hata dağılımı.....	56
Şekil 4.12. Artık değerlerin normal dağılımla karşılaştırması (QQ grafiği)	57
Şekil 4.13. UCI güç tüketimi veri setinde model bileşenlerinin R^2 katkısı.....	59
Şekil 4.14. Farklı yama konfigürasyonlarının R^2 ve MAE üzerindeki etkisi.....	60
Şekil 4.15. Çoklu yama bileşenlerinin özellik önemi katkı oranları	60

KISALTMALAR VE SİMGELER LİSTESİ

ARIMA: Otoregresif Entegre Hareketli Ortalama (AutoRegressive Integrated Moving Average)

BiGRU: Çift Yönlü Kapılı Yinelemeli Birim (Bidirectional Gated Recurrent Unit)

BiLSTM: Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory)

CNN: Evrişimli Sinir Ağı (Convolutional Neural Network)

GBM: Gradyan Artırma Regresörü (Gradient Boosting Regressor)

GRU: Kapılı Yinelemeli Birim (Gated Recurrent Unit)

HGBR: Histogram Tabanlı Gradyan Artırma Regresörü (Histogram-based Gradient Boosting Regressor)

IQR: Çeyrekler Arası Aralık (Interquartile Range)

LSTM: Uzun Kısa Süreli Bellek (Long Short-Term Memory)

MAE: Ortalama Mutlak Hata (Mean Absolute Error)

MAPE: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)

MP-LRNet: Çoklu Yama LSTM-RF Ağı (Multi-Patch LSTM-RF Network)

n: Toplam veri sayısı / Gözlem sayısı

nMAE: Normalize Edilmiş Ortalama Mutlak Hata (normalized Mean Absolute Error)

nRMSE: Normalize Edilmiş Kök Ortalama Kare Hata (normalized Root Mean Square Error)

QQ: Kantil-Kantil Grafiği (Quantile-Quantile Plot)

ReLU: Doğrultulmuş Lineer Birim (Rectified Linear Unit)

RF: Rastgele Orman (Random Forest)

RMSE: Kök Ortalama Kare Hata (Root Mean Square Error)

RNN: Tekrarlayan Sinir Ağı (Recurrent Neural Network)

R^2 : Belirleme Katsayısı

SARIMA: Mevsimsel Otoregresif Entegre Hareketli Ortalama (Seasonal ARIMA)

SVR: Destek Vektör Regresyonu (Support Vector Regression)

UCI: University of California, Irvine - Makine Öğrenmesi Veri Havuzu

XAI: Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence)

X : Orijinal veri değeri

X_{max} : İlgili özelliğin maksimum değeri

X_{min} : İlgili özelliğin minimum değeri

X_{norm} : Normalize edilmiş veri değeri

XGB / XGBoost: Aşırı Gradyan Artırma (Extreme Gradient Boosting)

y_i : Gerçek değer

\hat{y}_i : Tahmin edilen değer

\bar{y} : Gerçek değerlerin ortalaması

1. GİRİŞ

Satış tahmini, modern işletmelerde hem operasyonel hem de stratejik kararların şekillendirilmesinde kilit bir rol oynamaktadır (Gupta & Agarwal, 2024). Küresel pazarlarda artan rekabet, tedarik zinciri kesintileri ve tüketici davranışlarındaki belirsizlik, doğru tahmin modellerine duyulan ihtiyacı her zamankinden daha kritik hâle getirmiştir (Louis Eyo-Udo vd., 2024; Madas vd., 2024; Olaleye vd., 2024). Perakende ve imalat gibi sektörlerde, etkili stok kontrolü ve kaynak planlaması doğrudan satış tahminlerinin kalitesiyle ilişkilidir (Alsoussi & Tahboub, 2025). Sonuç olarak, tahmin doğruluğunu artırmak için geleneksel yöntemlerin ötesine geçmek zorunlu hale gelmiştir. Perakende talep tahmininde XGBoost ve derin öğrenme modellerinin karşılaştırmalı kullanımı güncel çalışmalarda incelenmekte; bu tür modellerin tahmin doğruluğunu artırdığı raporlanmaktadır (Balusani vd., 2025). Yanlış tahminler, aşırı stok maliyetleri, stok tükenmeleri ve müşteri kaybı gibi sonuçlara yol açabildiğinden, tahmin doğruluğunu artırmak yalnızca akademik bir hedef değil, aynı zamanda işletmeler için operasyonel bir zorunluluk hâline gelmiştir (Theodorou vd., 2025).

Mobilya sektörü, talep dalgalanmalarının mevsimsellik, kampanyalar ve makroekonomik koşullarla sıkı biçimde ilişkili olduğu bir alan olarak bu zorluğu özellikle hissetmektedir. Ürün çeşitliliği, uzun tedarik süreleri ve depolama maliyetleri, doğru satış tahminini hem zor hem de değerli kılmaktadır. Bu bağlamda, veri odaklı yaklaşımlar ve gelişmiş analitik yöntemler, daha hassas ve uyarlanabilir tahmin süreçlerinin geliştirilmesini mümkün kılmıştır. Zaman serisi tahmininde derin öğrenme tabanlı tekniklerin kullanımı giderek yaygınlaşmakta ve bu alan sürekli gelişmektedir (Ferdowsy, 2024). Makine öğrenmesi tabanlı modellerin stok tükenmelerini azalttığı ve talep tahmin doğruluğunu artırdığı; derin öğrenme tekniklerinin ise mevsimsellik ve dışsal faktörleri daha etkili biçimde yakalayarak tedarik zinciri performansında iyileşmeler sağladığı gösterilmiştir (Madas vd., 2024).

Bununla birlikte, geleneksel istatistiksel yöntemler karmaşık ve dinamik veri yapılarıyla karşılaştığında sınırlı kalmakta; ARIMA ile yapay sinir ağlarını birleştiren hibrit modellerin bu sınırları aşmada erken dönemde önerildiği ve tahmin performansını iyileştirebileceğinin gösterildiği bilinmektedir (Zhang, 2003).

Bu da araştırmacıları derin öğrenme ve topluluk (ensemble) öğrenmesini birleştiren hibrit modellere yöneltmektedir; LSTM ile Rastgele Orman'ı birleştiren hibrit modellerin farklı uygulama alanlarında performans artışı sağladığı çeşitli çalışmalarda raporlanmıştır

(Djaballah vd., 2024; Hassan ve Hassan, 2024; Punia vd., 2020).

Ancak mevcut literatür incelendiğinde, özellikle mobilya perakende sektörüne özgü satış tahmin çalışmalarının oldukça sınırlı kaldığı görülmektedir. Genel perakende ve e-ticaret alanlarında başarılı sonuçlar veren modeller, mobilya sektörünün kendine has dinamikleri karşısında yeterli performans gösteremeyebilmektedir (Fildes vd., 2022). Ayrıca, çoğu çalışma tek bir model mimarisi üzerine odaklanmakta; farklı tekrarlayan sinir ağı türleri, topluluk öğrenme algoritmaları ve çoklu yama yapılarının sistematik karşılaştırması yapılmamaktadır (Makridakis vd., 2020).

Bu eksiklikleri gidermek amacıyla, bu tez çalışmasında gerçek bir mobilya perakendecisinden elde edilen satış verisi üzerinde kapsamlı bir deneysel çerçeve oluşturulmuştur. Önerilen MP-LRNet modeli, tekrarlayan sinir ağları ile topluluk öğrenme yöntemlerini çoklu yama yapısı altında birleştirerek hem kısa vadeli dalgalanmaları hem de orta vadeli eğilimleri yakalamayı hedeflemektedir. Model, 200 farklı mimari konfigürasyonla sistematik biçimde karşılaştırılarak yama yapısı, tekrarlayan ağ türü ve topluluk algoritması seçiminin performans üzerindeki etkisi ayrıntılı olarak incelenmekte; böylece hibrit mimarinin satış tahmini bağlamındaki katkısı bütüncül bir biçimde değerlendirilmektedir.

Bu tez kapsamında ele alınan temel araştırma soruları aşağıdaki gibi özetlenebilir:

- Bu tez kapsamında taranan 200 karşılaştırmalı konfigürasyon içinde Mevsimsel Momentum Katmanı, çoklu yama yapısı, tekrarlayan sinir ağı türü ve topluluk algoritması seçimleri arasında hangi bileşen kombinasyonları daha yüksek tahmin doğruluğu üretmektedir?
- Farklı yama boyutları, kısa ve orta vadeli zamansal örüntülerin temsil edilmesine ve model kararlılığına nasıl katkı sağlamaktadır? LSTM, BiLSTM, GRU ve BiGRU aileleri ile Rastgele Orman, XGBoost, Gradyan Artırma Regresörü ve Histogram Tabanlı Gradyan Artırma Regresörü kombinasyonları arasında doğruluk, kararlılık ve hesaplama maliyeti bakımından nasıl bir denge oluşmaktadır?
- Önerilen hibrit çerçeve, bu veri seti altında güncel hibrit zaman serisi tahmin çalışmalarıyla bağlamsal olarak nasıl konumlandırılabilir?

Bu sorulara yanıt ararken, çalışmanın temel amacı; mobilya satış tahmini için kurulan hibrit mimarinin iç bileşen kombinasyonlarını sistematik olarak karşılaştırmak, önerilen MP-

LRNet yapılandırmasını belirlemek ve bu yapılandırmayı geniş bir mimari arama uzayı içinde değerlendirmektir.

Bu tezin literatüre sağladığı katkılar aşağıdaki biçimde özetlenebilir:

- Yöntemsel katkı: LSTM, Rastgele Orman ve çoklu yama yaklaşımını tek bir modüler mimaride birleştiren MP-LRNet modelinin önerilmesi. Yapılan literatür taraması kapsamında, satış tahmini bağlamında LSTM, Rastgele Orman ve çoklu yama yaklaşımını birlikte ele alan doğrudan karşılaştırılabilir bir çalışmaya rastlanmamıştır.
- Deneysel katkı: Önerilen modelin, aynı veri seti ve aynı ön işleme koşulları altında 200 farklı mimari konfigürasyonla karşılaştırılarak değerlendirilmesi; böylece yama yapısı, tekrarlayan ağ türü ve topluluk algoritması seçiminin performans üzerindeki etkisinin sistematik biçimde incelenmesi.
- Uygulama katkıları: Gerçek bir mobilya perakendecisinden elde edilen gerçek dünya verisi kullanılması; sonuçların stok planlaması ve kapasite yönetimi gibi operasyonel karar süreçlerini destekleme potansiyeli taşıyan bir tahmin çerçevesi sunduğunun gösterilmesi.

Tezin kalan bölümleri şu şekilde düzenlenmektedir. 2. Literatür Taraması ve İlgili Çalışmalar bölümünde, zaman serisi tahmininde kullanılan klasik yöntemler, derin öğrenme tabanlı modeller, hibrit ve çoklu yama yaklaşımları ile perakende ve satış tahmini uygulamaları kapsamlı biçimde ele alınmakta; araştırma boşluğu ve MP-LRNet'in bu boşluktaki konumu tartışılmaktadır. 3. Metot bölümünde, kullanılan veri seti ve veri ön işleme adımları, tekrarlayan sinir ağı tabanlı modeller (LSTM, GRU, BiLSTM, BiGRU), topluluk öğrenme algoritmaları, çoklu yama yaklaşımı ve önerilen MP-LRNet mimarisi ile performans metrikleri ayrıntılı olarak açıklanmaktadır. 4. Deneysel Sonuçlar bölümünde, MP-LRNet'in ve karşılaştırmalı modellerin performansı sayısal tablolar ve grafiklerle sunulmakta; yama konfigürasyonları, tekrarlayan ağ türleri ve topluluk algoritmalarının etkisi yorumlanmaktadır. 5. Tartışma bölümünde, bulgular literatürdeki güncel çalışmalarla karşılaştırılmakta ve modelin güçlü yönleri ile sınırlılıkları tartışılmaktadır. 6. Sonuç ve Öneriler bölümünde ise çalışmanın özeti, uygulama önerileri ve gelecek araştırma yönleri sunulmaktadır.

2. LİTERATÜR TARAMASI

Zaman serisi tahmini, geçmişten günümüze çeşitli yöntemsel evrimler geçirmiştir. Klasik dönemde otoregresif bütünleşik hareketli ortalama (ARIMA) modelleri ve üstel düzgünleştirme yöntemleri, durağan zaman serilerinin modellenmesinde ve kısa vadeli tahminlerde standart araçlar olarak yaygın biçimde kullanılmıştır (Holt, 2004; Winters, 1960). Ancak bu klasik yöntemler, doğrusal olmayan ilişkileri yakalamada ve yüksek boyutlu verileri işlemede sınırlı kalmaktadır.

Makine öğrenmesi döneminde, destek vektör regresyonu (SVR), rastgele orman ve gradyan artırma gibi algoritmalar zaman serisi tahmininde klasik yöntemlere alternatif olarak öne çıkmıştır (Sapankevych & Sankar, 2009). Bu yöntemler doğrusal olmayan ilişkileri modelleyebilme kapasiteleri sayesinde özellikle karmaşık ve düzensiz verilerde üstün performans göstermiştir. Bununla birlikte, bu modeller zamansal bağımlılıkları açıkça modelleyemediğinden, sıralı verilerde uzun vadeli örüntülerin yakalanmasında derin öğrenme tabanlı yaklaşımlara kıyasla dezavantajlı konumda kalmışlardır.

Derin öğrenme alanındaki gelişmeler, özellikle tekrarlayan sinir ağlarının ortaya çıkışı ile zaman serisi tahmininde yeni bir dönem başlatmıştır. Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ve Kapılı Yinelemeli Birim (Gated Recurrent Unit - GRU) gibi gelişmiş mimariler, uzun vadeli bağımlılıkları öğrenme kapasiteleri sayesinde finansal tahmin, enerji tüketimi ve talep tahmini gibi çeşitli alanlarda başarılı sonuçlar elde etmiştir (Hewamalage vd., 2021). Ayrıca çift yönlü mimariler (Bidirectional LSTM - BiLSTM ve Bidirectional GRU - BiGRU), hem geçmiş hem de gelecek bağlam bilgisini kullanarak tahmin doğruluğunu artırmayı amaçlamıştır (Lim & Zohren, 2021).

Son dönemde, tek bir model türünün sınırlılıklarını aşmak amacıyla hibrit modeller ön plana çıkmıştır (Makridakis vd., 2020). Bu yaklaşımlar, farklı model türlerinin güçlü yönlerini birleştirerek daha doğru ve kararlı tahminler üretmeyi hedeflemektedir. Özellikle derin öğrenme modellerinin topluluk öğrenme algoritmaları ile birleştirilmesi, hem zamansal bağımlılıkların yakalanmasını hem de tahmin kararlılığının artırılmasını mümkün kılmaktadır (Smyl, 2020). Bu bağlamda, aşağıda hibrit ve çoklu yama tabanlı yaklaşımları ele alan güncel çalışmalar incelenmektedir.

Zaman serisi analizi, tarihsel veriler içindeki örüntüleri belirlemek ve gelecek değerleri tahmin etmek için uzun süredir kullanılan bir yöntemdir (Ferdowsy, 2024). Geleneksel yaklaşımlar, özellikle Otoregresif Entegre Hareketli Ortalama (ARIMA) (Zhang, 2003) ve

onun mevsimsel uzantısı olan Mevsimsel ARIMA (SARIMA), doğrusal ilişkileri ve durağan veri dağılımlarını modellemede etkili olduğunu kanıtlamıştır. ARIMA ile Prophet gibi modern yöntemleri birleştiren hibrit yaklaşımların tahmin doğruluğunu artırdığı da güncel çalışmalarda raporlanmaktadır (Sherly vd., 2025). Ancak bu yöntemler, karmaşık ve dinamik veri yapılarına uygulandığında önemli sınırlamalarla karşılaşmaktadır. Bu yöntemler; ani talep artışlarını veya birden fazla dışsal faktör arasındaki etkileşimleri yakalamakta zorlanırlar ve büyük veri kümeleriyle çalışırken hesaplama açısından verimsiz hâle gelebilirler. Bu eksiklikler, özellikle perakende satış verisi analizi gibi yüksek varyanslı, çok faktörlü ortamlarda daha belirgin hâle gelmektedir (Hassan & Hassan, 2024).

Geleneksel zaman serisi modellerinin sınırlamaları, araştırmacıları derin öğrenme ve hibrit modelleme tekniklerini keşfetmeye yöneltmiştir. LSTM ve GRU gibi mimariler, uzun dönemli bağımlılıkları ve doğrusal olmayan örüntüleri yakalama konusunda güçlü yetenekler sergilemiştir. Heterojen veri kaynaklarıyla çalışırken ise yalnızca derin öğrenme yeterli olmayabilir; bu durumda derin öğrenmeyi Rastgele Orman (Random Forest - RF), XGBoost (Extreme Gradient Boosting - XGB), Gradyan Artırma Regresörü (Gradient Boosting Regressor - GBM) ve HGBR gibi topluluk (ensemble) makine öğrenmesi yöntemleriyle birleştiren hibrit modeller daha esnek ve güvenilir bir çözüm sunmaktadır. Örneğin, Djaballah vd. (2024), LSTM ve RF’i birleştiren hibrit bir modelin rulman arıza tespitinde tek başına kullanımlara kıyasla daha iyi performans gösterdiğini ve %98,97 doğruluk elde ettiğini rapor etmiştir. Hibrit yaklaşımlara ek olarak, tahmin doğruluğunu artırmak için çoklu yama yaklaşımı da ilgi görmektedir: zaman serisi verilerinin farklı ölçeklerde analiz edilmesine olanak tanıyarak hem yüksek frekanslı dinamiklerin hem de uzun vadeli eğilimlerin tek bir modelde bütünleştirilmesini sağlar (Woo vd., 2024). Benzer biçimde, bulanık kümeleme ile makine öğrenmesini birleştiren hibrit zaman serisi modellerinin güç tüketimi tahmininde yüksek doğruluk sağladığı ; CNN-LSTM ve dikkat mekanizmaları kullanan modellerin güç yükü tahmininde etkili olduğu raporlanmaktadır. Perakende kanallarında LSTM ve RF’i birleştiren hibrit modellerin talep tahmininde tek bileşenli yöntemlere kıyasla istatistiksel olarak anlamlı iyileşme sağladığı da raporlanmıştır .(Hochreiter & Schmidhuber, 1997)(Chung vd., 2014)(Breiman, 2001; H. A. Salman vd., 2024)(Chen & Guestrin, 2016)(Friedman, 2002)(Djaballah vd., 2024)(Naghashi vd., 2025; Woo vd., 2024; Xu vd., 2025)(Alsalem, 2025)(Guo vd., 2025)(Punia vd., 2020)

Tablo 2.1, bu alandaki güncel çalışmaları özetleyerek LSTM, GRU, BiLSTM, CNN ve Transformer gibi derin öğrenme yöntemlerini RF ve XGBoost gibi topluluk teknikleriyle

birleştiren çeşitli hibrit mimarileri karşılaştırmaktadır. Tablo ayrıca enerji, finans, arıza tespiti, hava kirliliği ve satış tahmini gibi uygulama alanlarını ve her çalışmada raporlanan performans metrikleri ile avantaj ve sınırlılıkları sunmaktadır.

Satış tahmini literatürü yalnızca hibrit derin öğrenme modelleriyle sınırlı değildir; ARIMA/SARIMA ailesi, Prophet gibi ayrıştırma temelli yöntemler ve RF ile XGBoost gibi makine öğrenmesi tabanlı yaklaşımlar da önemli karşılaştırma eksenleri sunmaktadır. Ayrıca geniş ölçekli tahmin yarışmaları, özellikle Makridakis'in M-serisi karşılaştırmaları, yöntemlerin farklı veri yapıları ve tahmin ufukları altındaki davranışlarını değerlendirmek için temel bir çerçeve sağlamaktadır. Bu tezde literatür özeti ağırlıklı olarak hibrit ve çoklu yama odaklı güncel çalışmalara yoğunlaşmış; satış tahminine özgü klasik ve yarışma-temelli arka plan da bu bağlam içinde dikkate alınmıştır.

Tablo 2.1. Zaman serisi tahmini üzerine yakın tarihte yapılan hibrit model çalışmaları

Çalışma Yılı	Model	Uygulama Alanı	Sonuçlar	Avantajlar / Sınırlılıklar
(Djaballah vd., 2024)	2024 LSTM + RF + GWO	Rulman Arızası Tespiti	Acc. = %98.97 Prec. = %99.28 Kappa = 99.13	Avantaj: GWO aracılığıyla öznitelik seçimi, yüksek sınıflandırma doğruluğu. Sınırlılık: Sadece sınıflandırma yapılmıştır; regresyon test edilmemiştir.
(Kabir vd., 2025)	2025 LSTM + Transformer + MLP	Finansal Zaman Serisi Tahmini	Kıyaslama modellerine göre üstün MSE, RMSE, MAE	Avantaj: Öz-dikkat (self-attention) mekanizması uzun vadeli bağımlılıkları yakalar. Sınırlılık: Yüksek hesaplama maliyeti, çoklu yama (Multi-Patch) kullanılmamıştır.
(Mariappan vd., 2025)	2025 CNN + Yığılmış (Stacked) LSTM + Slime Mould Optimizasyonu	Güneş Radyasyonu Tahmini	MSE = 0.0359 R ² = 0.9790 Ort R ² = 0.9789	Avantaj: Hiperparametre ayarı için meta-sezgisel yöntem, öznitelik seçimi için RFE. Sınırlılık: Tek bir alanda test edilmiştir, çoklu yama yoktur.
(Ma vd., 2024)	2024 VMD + BiLSTM + GRU	Kısa Vadeli Trafik Akışı	Temel modellere göre daha iyi MAE, R ² , RMSE	Avantaj: VMD ile gürültü azaltma, BiLSTM ve GRU ile zamansal modelleme. Sınırlılık: Topluluk (ensemble) yapısı yoktur, çoklu yama kullanılmamıştır.
(Shi vd., 2024)	2024 LSTM + Transformer	Maden Suyu Akışı Tahmini	LSTM, CNN, Transformer ve CNN-LSTM'e göre daha yüksek doğruluk	Avantaj: Uzun vadeli bağımlılıklar için öz-dikkat kullanımı. Sınırlılık: Yüksek eğitim maliyeti, veri seti ayırma optimizasyonu gerekliliği.

Tablo 2.1. Devamı

Çalışma	Yıl	Model	Uygulama Alanı	Sonuçlar	Avantajlar / Sınırlılıklar
(Abumohsen vd., 2024)	2024	CNN + LSTM + RF	Güneş Enerjisi Tahmini	$R^2 = 0.92$ RMSE = 0.07kW MAE = 0.05kW	Avantaj: Uzaysal, zamansal ve doğrusal olmayan modellemeyi birleştirir. Sınırlılık: Sadece tek bir bölgede test edilmiştir.
(Guo vd., 2025)	2025	CNN + MHSA + LSTM + Dikkat Mekanizmaları	Güç Yüklü Tahmini	Ana akım modellere kıyasla daha yüksek doğruluk	Avantaj: Çoklu dikkat mekanizmaları, uzaysal-zamansal modelleme. Sınırlılık: Karmaşık mimari, yüksek eğitim süresi.
(He vd., 2025)	2025	Wavelet + CNN + BiGRU + BiLSTM	PM2.5 Konsantrasyonunu Tahmini	$R^2 = 0.9952$ RMSE = 1.4935 MAE = 1.2091 MAPE = %7.3782	Avantaj: Gürültü giderme için Wavelet, çift yönlü modelleme. Sınırlılık: Karmaşık ve hesaplama açısından yoğundur.
(D. Salman vd., 2024)	2024	Wavelet + LSTM + Transformer	Şebeke Arızası Tahmini	Geleneksel yöntemlerden daha yüksek doğruluk	Avantaj: Wavelet ile ayrıştırma, LSTM + Transformer sinerjisi. Sınırlılık: Büyük veri setlerinde uzun eğitim süresi.
(Zhang ve Yan, 2025)	2025	GRU + Attention + LSTM	Hisse Senedi Fiyatı Tahmini	CNN-LSTM'den daha yüksek doğruluk	Avantaj: GRU ile geliştirilmiş dikkat, LSTM ile uzun vadeli hafıza. Sınırlılık: CNN içermez, uzaysal öznitelik çıkarımı eksiktir.
(Wen vd., 2024)	2024	GRU + TCN + Dikkat Mekanizması	Kısa Vadeli Yük Tahmini	Geleneksel yöntemlere göre daha düşük hata	Avantaj: Zamansal modelleme, çok ölçekli öznitelikler, dikkat mekanizması. Sınırlılık: Çift yönlü mimariler içermez

Tablo 2.1, satış tahminiyle doğrudan ilişkili çalışmaların sınırlı; yöntemsel olarak benzer hibrit yapıların ise farklı uygulama alanlarında yaygın olduğunu göstermektedir. Hibrit derin öğrenme modellerinin çok değişkenli trafik ve hava kalitesi tahmininde yüksek R^2 üretebildiği (Mahmoud & Mohammed, 2024); kısa vadeli yük tahmininde benzer hibrit yaklaşımların düşük hata üretebildiği (Wen vd., 2024) de raporlanmıştır. Ayrıca LSTM ve GRU tabanlı yapıların RF veya XGBoost ile birleştirildiğinde daha yüksek doğruluk sağlayabildiği (Abumohsen vd., 2024; Djaballah vd., 2024) belirtilmektedir. Bu çerçevede tablodaki çalışmalar, önerilen yapının yöntemsel dayanağını desteklemekte; ancak satış tahmini bağlamında LSTM, RF ve çoklu yama yaklaşımını birlikte kullanan örneklerin sınırlı

olduğunu göstermektedir. Topluluk bileşeni içermeyen çalışmalar (Ma vd., 2024; Shi vd., 2024); çoklu yama içermeyen çalışmalar ise (Kabir vd., 2025; Ma vd., 2024; Mariappan vd., 2025) sınırlı kalmaktadır. Perakende veya mobilya satışına özgü çalışmaların sınırlı olması, bu tezdeki uygulama alanı seçimini gerekçelendirmektedir. Perakende talep tahmininde XGBoost ve derin öğrenme modellerinin karşılaştırmalı kullanımı (Balusani vd., 2025) gibi örnekler de alanın gelişmekte olduğunu göstermektedir.

Mobilya sektörü özelinde gerçekleştirilen önceki bir karşılaştırmalı çalışmada (Şahin & Çubukçu, 2024) tekrarlayan sinir ağı tabanlı modeller (LSTM, GRU, BiLSTM, BiGRU) ele alınmış ve hibrit yapıların satış tahmininde öne çıktığı raporlanmıştır.

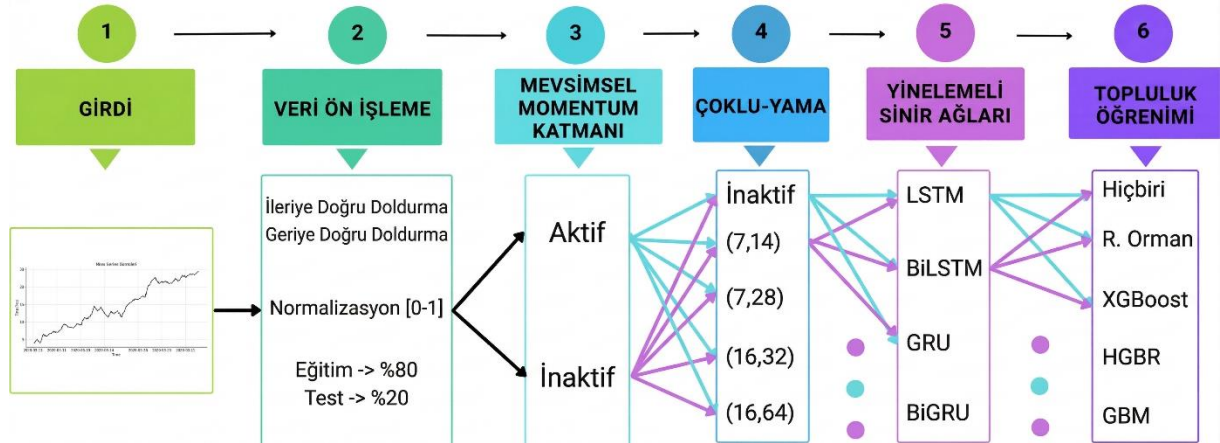
Literatür, derin öğrenme ve makine öğrenmesi tekniklerinin hibrit kullanımının giderek yaygınlaştığını göstermesine rağmen, bu tez kapsamında incelenen çalışmalar içinde, satış tahmini bağlamında LSTM, RF ve çoklu yama yaklaşımını bir arada kullanan bir modele rastlanmamıştır. Ayrıca, önerilen modellerin çoğu sınırlı sayıda karşılaştırmalı mimari ile test edilmiş; gerçek dünya satış verisi üzerinde geniş bir mimari arama (örneğin 200 konfigürasyon) ile sistematik değerlendirme yapılmamıştır.

Bu nedenlerle, bu tez kapsamında gerçek bir mobilya perakendecisinden elde edilen verilerle satış tahmini yapmak üzere LSTM, RF ve çoklu yama yaklaşımını birleştiren Çoklu Yama LSTM-RF Ağı (MP-LRNet) önerilmekte ve model, 200 farklı mimari konfigürasyonla karşılaştırılarak değerlendirilmektedir. Bir sonraki bölümde, kullanılan veri seti, veri ön işleme adımları, tekrarlayan sinir ağı tabanlı modeller, topluluk öğrenme algoritmaları, çoklu yama yaklaşımı ve MP-LRNet mimarisi ayrıntılı olarak açıklanmaktadır.

3. METOT

Mobilya sektöründe satış tahmini için önerilen MP-LRNet modeli, Bursa merkezli bir mobilya üretim ve perakende şirketinden elde edilen gerçek dünya veri seti üzerinde uygulanmıştır. Bu veri setinin tek bir firmaya ve tek bir sektöre ait olması, model performansının kampanya dönemleri, konut ve yenileme talebiyle ilişkili dönemsel hareketler ile firmaya özgü operasyonel örüntülerden etkilenebileceği anlamına gelmektedir. Bu nedenle, önerilen modelin literatürdeki çalışmalarla doğrudan sayısal karşılaştırması sınırlı yorumlanmalı; değerlendirme öncelikle önerilen yapı ile aynı temel bileşenlerden türetilen 200 karşılaştırmalı konfigürasyon üzerinden gerçekleştirilmelidir.

Önerilen MP-LRNet'in ve karşılaştırmalı modellerin oluşturulma süreci Şekil 3.1'de gösterilmektedir. Tüm deneylerde tutarlılığı sağlamak amacıyla aynı giriş verileri ve aynı ön işleme adımları uygulanmıştır. Ön işlemenin ardından karşılaştırmalı konfigürasyonlar; Mevsimsel Momentum Katmanı'nın varlığı ya da yokluğu, çoklu yama yapılandırmalarından biri (İnaktif, (7,14), (7,28), (16,32) veya (16,64)), bir tekrarlayan sinir ağı türü (LSTM, BiLSTM, GRU veya BiGRU) ve bir topluluk öğrenme yöntemi (Yok, RF, XGBoost, HGBR veya GBM) sistematik olarak birleştirilerek oluşturulmuştur. Oluşturulan 200 kombinasyonun her biri, aynı koşullar altında on kez çalıştırılmış ve her yapılandırma için ortalama performans metrikleri hesaplanmıştır.



Şekil 3.1. MP-LRNet ve modellerin yapısal akış şeması


Tüm deneyler, 11. Nesil Intel(R) Core i7-1195G7 işlemciye (2.90 GHz - 2.92 GHz) ve 16 GB RAM'e sahip, ayırık ekran kartı bulunmayan bir dizüstü bilgisayar üzerinde gerçekleştirilmiştir. Bu nedenle eğitim süreleri mutlak bir donanım benchmark'ı olarak değil, aynı deney ortamı içindeki görece karşılaştırmalar olarak yorumlanmalıdır. Yazılım ortamı Python 3.9, TensorFlow 2.10.0, Scikit-learn 1.1.3 ve Pandas 1.5.1 sürümlerini içermektedir.

3.1. Veri Seti ve Veri Ön İşleme

Bu çalışmada kullanılan veri kümesi, Bursa merkezli bir mobilya üretim ve perakende şirketine ait satış kayıtlarından oluşmakta olup 1 Ocak 2022 ile 31 Ekim 2023 dönemini kapsamaktadır. Veri kümesi toplam 37.006 satır içermekte ve sipariş tarihi, sipariş miktarı, birim fiyat ve net fiyat gibi temel nitelikleri barındırmaktadır. Sipariş miktarları 1 ile 750 adet arasında değişirken, net fiyatlar 390 TL ile 304.297 TL arasında değişmektedir. Tablo 3.1, veri kümesinden örnek bir kesit sunmaktadır; Şekil 3.2 ise bu çalışmada kullanılan girdiyi göstermektedir. Bu tezde performans değerlendirmesi, bu kayıtlardan türetilen günlük toplam net satış tutarı serisi üzerinden raporlanmaktadır.

Tablo 3.1. Veri setinden örnek bir kesit

Sipariş Tarihi	Sipariş Miktarı	Fiyat (TRY)	Net Fiyat (TRY)
14.04.2022	1	6.199,31	6.199,31
14.04.2022	1	2.596,41	2.596,41
14.04.2022	1	773,09	773,09
14.04.2022	2	860,61	1.721,22
14.04.2022	1	10.881,60	10.881,60
14.04.2022	2	2.698,52	5.397,04
14.04.2022	6	300,00	1.800,00
14.04.2022	1	9.845,96	9.845,96
15.04.2022	1	3.230,93	3.230,93
15.04.2022	1	3.011,64	3.011,64
15.04.2022	1	3.859,57	3.859,57



Şekil 3.2. Günlük net satış tutarı zaman serisi (çalışma girdisi ve ana değerlendirme çıktısı)

3.1.1. Veri ön işleme akışı

DeneySEL iş akışında ayrı bir eksik değer doldurma adımı uygulanmamıştır. İşlem bulunmayan günler günlük toplamda 0 satış olarak temsil edilmiş ve seriden çıkarılmamıştır. Ayrı bir aykırı değer bastırma adımı uygulanmamıştır. Uygulanan ön işleme akışı; sipariş kayıtlarının tarih sırasına göre düzenlenmesi, günlük net satış tutarı serisinin türetilmesi, kronolojik eğitim/test ayırımı ve Min-Max normalizasyonu adımlarından oluşmaktadır (Moritz & Bartz-Beielstein, 2017).

3.1.2. Yeniden örnekleme ve veri bölme

Ardından veriler, zaman serisi analizine uygunluğu sağlamak için günlük bazda toplanarak günlük toplam net satış tutarı serisi oluşturulmuştur. Veri kümesi %80 eğitim ve %20 test alt kümelerine zamansal sıraya uygun (chronological split) biçimde ayrılmıştır: önce gelen zaman dilimi eğitim, sonra gelen dilim test olarak kullanılmıştır. Böylece modelin gelecekteki dönemlere genellemesi değerlendirilmiş ve veri sızıntısı (data leakage) engellenmiştir (Bergmeir & Benítez, 2012). Eğitim kümesi model parametrelerini öğrenmek için kullanılırken, test kümesi modellerin genelleme performansını değerlendirmek için ayrılmıştır. Tahmin görevinde bilgi kesim noktası kesin biçimde korunmuştur: ertesi gün (t+1) için yapılan tahminde yalnızca t ve daha önceki günlere ait bilgiler giriş penceresinde yer almış; hedeflenen güne (t+1) ait net satış değeri ve sonraki dönemlere ait bilgiler modele girdi özelliği olarak verilmemiştir.

3.1.3. Normalizasyon ve yama (patch) oluşturma süreci

Veri ölçekleme için Min-Max normalizasyonu uygulanarak tüm değerler [0, 1]

aralığına dönüştürülmüştür D.1. Burada X_{norm} normalize edilmiş değeri, X orijinal değeri, X_{min} ve X_{max} ise ilgili özelliğin sırasıyla minimum ve maksimum değerlerini ifade etmektedir. Normalizasyon parametreleri yalnızca eğitim kümesi üzerinde fit edilmiş; test kümesi aynı scaler nesnesi ile dönüştürülmüştür. Bu tercih, veri sızıntısını önlemek ve test dönemindeki bilgilerin eğitim aşamasına taşınmamasını sağlamak için uygulanmıştır. Min-Max seçimi, RNN tabanlı modellerde gradyan davranışını iyileştirmesi ve farklı ölçekteki özellikleri aynı aralığa getirmesi nedeniyle tercih edilmiştir.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (D.1)$$


Yama (patch) oluşturma süreci şu şekilde uygulanmıştır: normalize edilmiş giriş değişkenleri üzerinde sabit uzunlukta pencereler (örneğin 7 ve 14 gün) kaydırılarak ardışık segmentler elde edilmiş; her segment bir “yama” olarak derin öğrenme modeline girdi oluşturmuştur. İki farklı yama boyutu (7 ve 14) kullanıldığında, kısa vadeli (haftalık) ve orta vadeli (iki haftalık) zamansal örüntüler aynı anda temsil edilmiştir. Bu çalışmada modele sipariş miktarı, birim fiyat ve net fiyat değişkenleri birlikte verilmiştir. Pencereleme ve ilk aşama tahminleri kayıt düzeyinde çok değişkenli olarak kurulmuş; ancak nihai performans değerlendirmesi bu çıktılardan türetilen günlük toplam net fiyat serisi üzerinden raporlanmıştır. Dolayısıyla tezin ana raporlanan değerlendirme hedefi günlük toplam net satış tutarıdır; Sipariş miktarı ve Birim fiyat değişkenleri ise model yapısına dahil edilen yardımcı değişkenler olarak değerlendirilmiştir. Modele girdi olarak verilen sipariş miktarı, birim fiyat ve net fiyat değişkenlerinin tümü, tahmin edilen güne değil giriş penceresindeki geçmiş günlere (t ve öncesi) aittir; dolayısıyla tahmin edilen güne ait hiçbir bilgi modele taşınmamıştır.

3.1.4. Karşılaştırma için kullanılan evsel elektrik enerjisi tüketimi veri seti

Önerilen modelin genellenebilirliğini değerlendirmek amacıyla UCI Machine Learning Repository’de bulunan Evsel Elektrik Enerjisi Tüketimi (Household Electric Power Consumption) veri seti karşılaştırma amaçlı kullanılmıştır. Bu veri seti, Fransa’nın Sceaux şehrinde bir konuttan Aralık 2006 ile Kasım 2010 arasında dakikalık çözünürlükte toplanan enerji tüketim ölçümlerini içermektedir (Hebrail & Berard, 2012). Günlük bazda yeniden örneklendikten sonra toplam 1.433 gözlem elde edilmiş ve mobilya satış verisi ile aynı ön işleme hattı (normalizasyon, yama oluşturma, kronolojik %80-%20 bölme) uygulanmıştır.

Bu halka açık veri setinin tercih edilmesinin başlıca nedenleri şunlardır: (i) belirgin

haftalık ve mevsimsel periyodikliklere sahip olması, (ii) mobilya satış verisi ile karşılaştırılabilir uzunlukta (yaklaşık dört yıllık) bir zaman aralığını kapsamaması ve (iii) farklı bir alandan (perakende yerine enerji tüketimi) gelmesi nedeniyle modelin alan bağımsız performansını test etmeye elverişli olmasıdır. Şekil 3.3, UCI veri setinin günlük ortalama küresel aktif güç tüketimi serisini göstermektedir.



Şekil 3.3. UCI veri setinin günlük ortalama küresel aktif güç tüketimi zaman serisi

3.2. Tekrarlayan Sinir Ağı Tabanlı Modeller

Zaman serisi verisinde ardışık gözlemler arasında bağımlılık vardır; klasik tek katmanlı veya çok katmanlı ileri beslemeli ağlar bu zamansal yapıyı doğrudan modelleyemez. Tekrarlayan sinir ağları (RNN'ler), gizli durumun zaman adımları boyunca taşınmasıyla dizileri işleyebilir; ancak basit RNN'ler uzun dizilerde gradyanın zaman içinde sönmesi veya patlaması (vanishing/exploding gradient) nedeniyle uzun vadeli bağımlılıkları öğrenmekte zorlanır. Kapılı mimariler olan LSTM ve GRU, bu sorunu unutma ve güncelleme mekanizmalarıyla hafifleterek hem kısa hem uzun vadeli bağımlılıkları daha etkili öğrenir. Bu nedenle mobilya satış tahmini için dört farklı yinelemeli sinir ağı mimarisi kullanılmıştır: LSTM, GRU ve bunların çift yönlü türevleri BiLSTM ve BiGRU. Bu modeller, zaman serisi verilerindeki ardışık ilişkileri ve uzun vadeli bağımlılıkları yakalamak üzere tasarlanmıştır.

3.2.1. Uzun kısa süreli bellek (Long Short-Term Memory - LSTM)

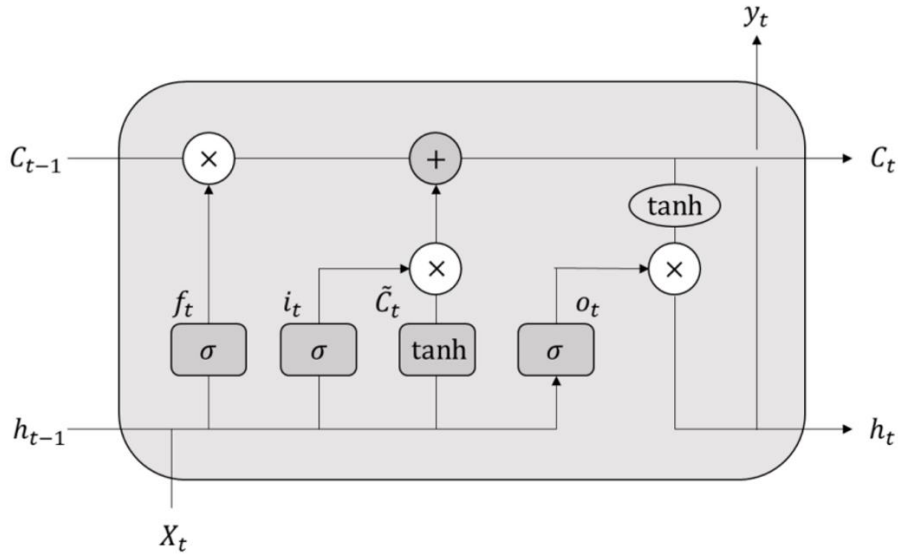
Uzun Kısa Süreli Bellek ağı, standart tekrarlayan sinir ağlarında karşılaşılan kaybolan gradyan problemini çözmek amacıyla Hochreiter ve Schmidhuber (1997) tarafından önerilmiştir. Bu mimari, bilginin uzun süreler boyunca korunmasını ve gerektiğinde güncellenmesini sağlayan özel bir hücre durumu (cell state) mekanizmasına sahiptir. LSTM hücresinin temel bileşenleri unutma kapısı, giriş kapısı ve çıkış kapısı olmak üzere üç kapı mekanizmasından oluşmaktadır.

Unutma kapısı, önceki zaman adımından gelen bilginin ne kadarının hücre durumunda tutulacağını belirler. Bu kapı, sigmoid aktivasyon fonksiyonu kullanarak 0 ile 1 arasında bir değer üreterek bilginin tamamen unutulmasından tamamen korunmasına kadar bir yelpazede

kontrol sağlar. Giriş kapısı ise yeni bilginin hücre durumuna ne ölçüde ekleneceğini düzenler; sigmoid fonksiyonu ile hangi değerlerin güncelleneceğini, hiperbolik tanjant fonksiyonu ile de yeni aday değerleri belirler. Son olarak çıkış kapısı, hücre durumundan elde edilen bilginin ne kadarının bir sonraki katmana veya zaman adımına aktarılacağını kontrol eder.

LSTM mimarisinin bu seçici bellek mekanizması, özellikle zaman serisi tahmininde uzun vadeli mevsimsel örüntülerin ve trend bileşenlerinin yakalanmasında önemli bir avantaj sağlamaktadır. Finansal piyasa tahmini, enerji tüketimi öngörüsü ve talep tahmini gibi alanlarda yaygın biçimde kullanılmaktadır. Bu çalışmada LSTM, mobilya satış verilerindeki haftalık ve mevsimsel bağımlılıkları modellemek üzere temel tekrarlayan ağ mimarilerinden biri olarak seçilmiştir.

Şekil 3.4 temel LSTM mimarisini göstermektedir.(Jiang vd., 2023)(Fan vd., 2024)



Şekil 3.4. LSTM mimarisi

LSTM hücresi, her zaman adımında gizli durum vektörü h_t ve hücre durumu c_t olmak üzere iki farklı iç durumu güncelleyerek uzun vadeli bağımlılıkları modellemektedir. Temel güncelleme denklemleri aşağıdaki gibi ifade edilir (Hochreiter & Schmidhuber, 1997):

$$\text{Unutma Kapısı: } f_t = \sigma(W_f \cdot [h_{\{t-1\}}, x_t] + b_f) \quad (\text{D.2})$$

$$\text{Giriş Kapısı: } i_t = \sigma(W_i \cdot [h_{\{t-1\}}, x_t] + b_i) \quad (\text{D.3})$$

$$\text{Aday Hücre Durumu: } \tilde{c}_t = \tanh(W_c \cdot [h_{\{t-1\}}, x_t] + b_c) \quad (\text{D.4})$$

$$\text{Hücre Durumu Güncellemesi: } c_t = f_t \odot c_{\{t-1\}} + i_t \odot \tilde{c}_t \quad (\text{D.5})$$

$$\text{Unutma Kapısı: } f_t = \sigma(W_f \cdot [h_{\{t-1\}}, x_t] + b_f) \quad (\text{D.2})$$

$$\text{Çıkış Kapısı: } o_t = \sigma(W_o \cdot [h_{\{t-1\}}, x_t] + b_o) \quad (\text{D.6})$$

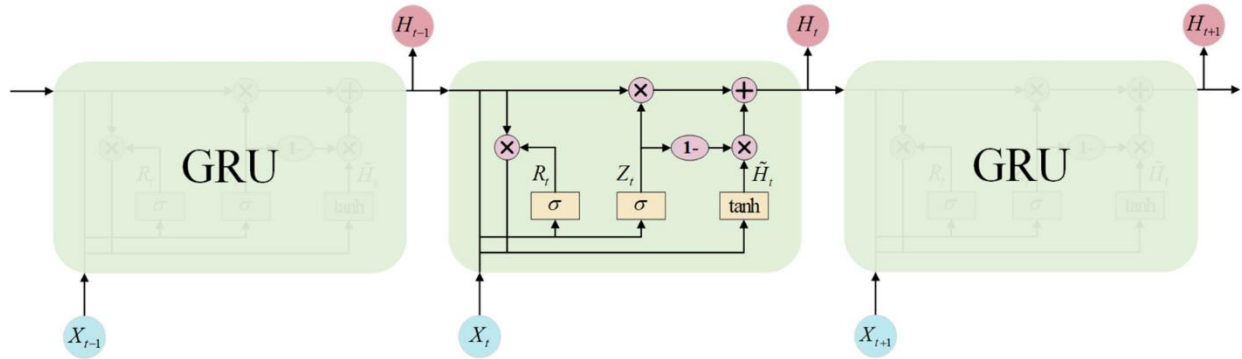
$$\text{Gizli Durum: } h_t = o_t \odot \tanh(c_t) \quad (\text{D.7})$$

Burada x_t giriş vektörünü, σ sigmoid aktivasyon fonksiyonunu ve \odot Hadamard (bileşen bazlı çarpma) işlemini göstermektedir. Unutma kapısı f_t , önceki hücre durumundan ne kadar bilginin korunacağını; giriş kapısı i_t ile aday hücre durumu \tilde{c}_t ise yeni bilginin ne ölçüde ekleneceğini kontrol eder. Çıkış kapısı o_t ise gizli durumun güncel hücre durumundan ne kadarının dış katmanlara aktarılacağını belirler.

3.2.2. Kapılı yinelemeli birim (Gated Recurrent Unit - GRU)

Kapılı Yinelemeli Birim, (Cho vd., 2014) LSTM mimarisinin daha basit ve hesaplama açısından daha verimli bir alternatifi olarak önerilmiştir. GRU, LSTM'deki üç kapı mekanizmasını iki kapıya indirgemektedir: sıfırlama kapısı ve güncelleme kapısı. Bu sadeleştirme, modelin parametre sayısını azaltarak eğitim süresini kısaltırken, birçok uygulamada LSTM ile karşılaştırılabilir performans sunmaktadır.

(Jiang vd., 2023)(Fan vd., 2024)Şekil 3.5, temel GRU mimarisini göstermektedir.



Şekil 3.5. GRU mimarisi

Güncelleme kapısı, LSTM'deki unutma ve giriş kapılarının işlevlerini tek bir mekanizmada birleştirir. Bu kapı, önceki gizli durumdan ne kadar bilginin korunacağını ve yeni bilginin ne ölçüde dahil edileceğini eş zamanlı olarak belirler. Sıfırlama kapısı ise önceki gizli durumun yeni aday gizli durumun hesaplanmasında ne ölçüde kullanılacağını kontrol eder; düşük değerler önceki bilginin göz ardı edilmesine, yüksek değerler ise korunmasına yol açar.

GRU mimarisinin LSTM'ye kıyasla en belirgin avantajı, daha az parametre içermesi nedeniyle eğitim süresinin kısalması ve küçük veri kümelerinde aşırı uyum riskinin azalmasıdır. Öte yandan, çok uzun vadeli bağımlılıkların modellenmesinde LSTM'nin ayrı hücre durumu mekanizması daha etkili olabilmektedir. Bu çalışmada GRU, hesaplama verimliliği ile tahmin doğruluğu arasındaki dengeyi değerlendirmek amacıyla karşılaştırmalı mimarilerden biri olarak kullanılmıştır.

GRU hücresinin güncelleme denklemleri aşağıdaki gibi ifade edilir:

$$\text{Güncelleme Kapısı: } z_t = \sigma(W_z \cdot [h_{\{t-1\}}, x_t] + b_z) \quad (\text{D.8})$$

$$\text{Sıfırlama Kapısı: } r_t = \sigma(W_r \cdot [h_{\{t-1\}}, x_t] + b_r) \quad (\text{D.9})$$

$$\text{Aday Gizli Durum: } \tilde{h}_t = \tan h(W_h \cdot [r_t \odot h_{\{t-1\}}, x_t] + b_h) \quad (\text{D.10})$$

$$\text{Gizli Durum Güncellemesi: } h_t = (1 - z_t) \odot h_{\{t-1\}} + z_t \odot \tilde{h}_t \quad (\text{D.11})$$

Burada z_t güncelleme kapısı, r_t sıfırlama kapısı ve \tilde{h}_t aday gizli durumdur. z_t 1'e yakınken önceki gizli durum büyük ölçüde korunur; 0'a yakınken yeni hesaplanan aday gizli durum ağır basar. r_t ise aday hesaplanırken $h_{\{t-1\}}$ 'in ne kadarının kullanılacağını belirler; bu da GRU'nun kısa vadeli bağlamı "unutma" veya yeniden yazma esnekliği sağlar.

3.2.3. LSTM ile GRU'nun karşılaştırılması

LSTM ve GRU, her ikisi de uzun vadeli bağımlılıkları modellemede etkili olan kapılı RNN'lerdir. LSTM, ayrı hücre durumu ve üç kapı (unutma, giriş, çıkış) ile daha fazla parametre içerir; bu da bazı uzun dizilerde ek ifade gücü sağlayabilir. GRU ise iki kapı (güncelleme, sıfırlama) ve tek gizli durum ile daha az parametreye sahiptir; deneysel çalışmalarda birçok zaman serisi ve dizi görevinde LSTM ile benzer performans gösterirken eğitim süresi genelde daha kısadır (Chung vd., 2014). Bu tezde hem LSTM hem GRU (ve çift yönlü türevleri) kullanılmasının nedeni, mobilya satış verisi gibi belirli bir alanda hangi mimarinin daha iyi denge (doğruluk, kararlılık, hesaplama süresi) sağladığını 200 konfigürasyonlu ablation çalışmasıyla ampirik olarak değerlendirmektir.

3.2.4. Çift yönlü uzun kısa süreli bellek (Bidirectional Long Short-Term Memory - BiLSTM)

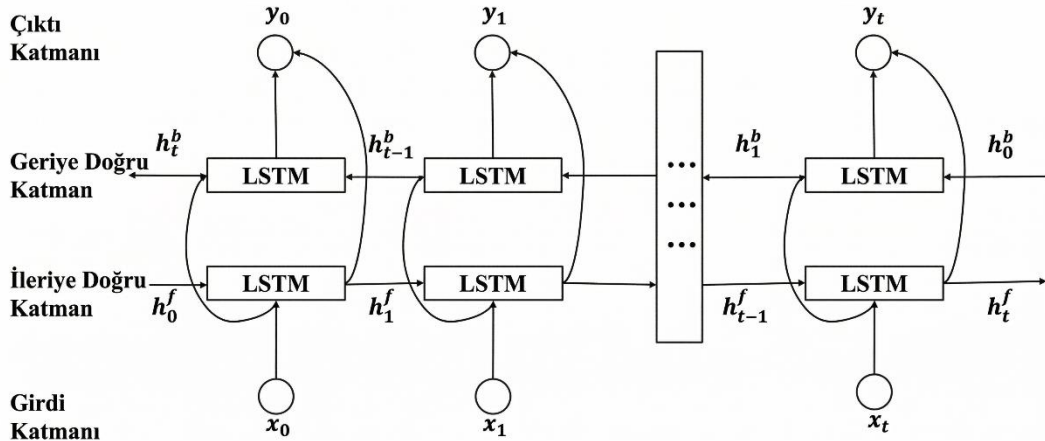
Çift yönlü uzun kısa süreli bellek ağı, standart LSTM mimarisinin hem ileri hem de

geri yönde çalışan iki ayrı katman ile genişletilmiş halidir. İleri yönlü katman girdi dizisini baştan sona, geri yönlü katman ise sondan başa doğru işleyerek her zaman adımında hem geçmiş hem de gelecek bağlam bilgisini birleştirir. Bu çift yönlü işlem, tek yönlü LSTM'nin yalnızca geçmiş bilgiye dayalı temsillerini önemli ölçüde zenginleştirir.

BiLSTM mimarisinde her zaman adımındaki nihai temsil, ileri ve geri yönlü gizli durumların birleştirilmesiyle elde edilir. Bu birleştirme genellikle bağlama (concatenation) yoluyla gerçekleştirilir ve çıktı vektörünün boyutu tek yönlü modelin iki katına çıkar. Bu genişletilmiş temsil kapasitesi, zaman serisindeki karmaşık zamansal ilişkilerin daha kapsamlı biçimde modellenmesine olanak tanır.

Bu çalışmada BiLSTM, mobilya satış verilerindeki çift yönlü zamansal bağımlılıkları yakalama potansiyeli nedeniyle değerlendirilen mimarilerden biri olarak seçilmiştir. Özellikle sipariş örüntülerindeki hem önceki hem de sonraki dönemlerin etkileşimlerini modelleyebilme kapasitesi, tahmin doğruluğunu artırma potansiyeli taşımaktadır. Ancak çift yönlü yapı, parametre sayısını ve dolayısıyla eğitim süresini artırmakta; bu durum hesaplama maliyeti ile performans kazanımı arasındaki dengenin dikkatle değerlendirilmesini gerektirmektedir.

Şekil 3.6 (Jiang vd., 2023) temel BiLSTM mimarisini, Şekil 3.7 (Fan vd., 2024) ise temel BiGRU mimarisini göstermektedir.



Şekil 3.6. BiLSTM mimarisini


3.2.5. Çift yönlü kapılı yinelemeli birim (Bidirectional Gated Recurrent Unit - BiGRU)

Çift yönlü kapılı yinelemeli birim, GRU mimarisinin çift yönlü genişletilmiş versiyonudur. BiLSTM ile benzer şekilde, girdi dizisini hem ileri hem de geri yönde işleyen iki paralel GRU katmanından oluşur. Her zaman adımında her iki yönden elde edilen gizli

durumlar birleştirilerek çift yönlü bağlam bilgisi içeren zenginleştirilmiş bir temsil oluşturulur.

BiGRU, BiLSTM'ye kıyasla daha az parametre içermesi nedeniyle hesaplama açısından daha verimlidir. GRU'nun sadeleştirilmiş kapı yapısı, çift yönlü mimaride de korunarak eğitim süresinin kısalmasına katkı sağlar. Bu özellik, özellikle çok sayıda konfigürasyonun sistematik olarak karşılaştırıldığı bu çalışma gibi kapsamlı deneysel çerçevelerde önemli bir avantaj oluşturmaktadır.

Bu çalışmada BiGRU, hem çift yönlü bağlam bilgisinden yararlanma hem de hesaplama verimliliğini koruma amacıyla değerlendirilen dördüncü ve son tekrarlayan sinir ağı mimarisi olarak kullanılmıştır. 200 konfigürasyonluk karşılaştırmalı analizde BiGRU, doğruluk ve hesaplama süresi arasında dengeli bir konum sergilemiştir.



Şekil 3.7. BiGRU mimarisi

3.2.6. Ortak mimari yapı ve hiperparametre seçimi

Uygulanan tüm modeller ortak bir mimari kurulum paylaşmaktadır. Her bir model, 200 nöron içeren tek katmanlı bir yapı olarak uygulanmıştır. Sinir ağlarının temel hesaplama birimleri olan nöronlar, veri noktaları arasındaki karmaşık ilişkileri yakalayabilme kapasitesine sahiptir. Nöron sayısının 200 olarak seçilmesi, yeterli temsil gücü sağlarken 200 konfigürasyonun makul sürede eğitilmesini mümkün kılan bir denge kurmak amacıyla yapılmıştır. Genelleştirmeyi artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla hem dropout hem de recurrent dropout oranları %20 olarak ayarlanmıştır. Dropout, eğitim sırasında bazı nöronları rastgele devre dışı bırakarak çalışır; bu da modelin belirli örnekleri ezberlemek yerine genel örüntüleri öğrenmesini teşvik eder (Srivastava vd., 2014).

Zaman serisi verilerinde doğal olarak bulunan mevsimsel örüntüleri daha iyi yakalamak için, Mevsimsel Momentum Katmanı (SeasonalMomentumLayer) yalnızca etkin olduğu konfigürasyonlarda çekirdek tekrarlayan katmanın önüne yerleştirilmektedir. Bu katman, her zaman adımındaki girdiyi haftanın ilgili gününe karşılık gelen öğrenilebilir bir ağırlık katsayısıyla yeniden ölçeklendirir. Mevsimsellik periyodu P , veri kümesinin başlangıç günü ve her gün konumuna ait ağırlık vektörü olmak üzere üç parametre ile tanımlanmaktadır. Bu çalışmada $P = 7$ olarak alınmış ve zaman indeksleri haftalık ağırlıklarla eşleştirilmiştir. Bu tercih, günlük örneklenen satış serisi üzerinde haftanın günü etkisini inceleyen ön analizler ve bu çalışmada kullanılan haftalık mevsimsel ayrıştırma adımıyla uyumludur. Aylık ($P = 30$) veya yıllık ($P = 365$) periyotlar bu proje kapsamında ayrıca sınanmamıştır; dolayısıyla Mevsimsel Momentum Katmanı yalnızca haftalık periyot altında değerlendirilmiş ve bu durum çalışmanın bir sınırlılığı olarak kabul edilmiştir. Böylece her zaman adımındaki girdi, haftanın ilgili gününe karşılık gelen katsayıyla yeniden ölçeklenmektedir. Tekrarlayan bileşenin ardından, modelin iç temsillerinden anlamlı tahminler elde etmek için 200 nöronlu bir yoğun (Dense) katman eklenmektedir.

Mevsimsel Momentum Katmanı'nın matematiksel formülasyonu şu şekilde tanımlanmaktadır: Katman, her bir giriş değerini haftanın ilgili gününe karşılık gelen öğrenilebilir bir ağırlık ile çarparak çıktı üretir. Biçimsel olarak, b mini-yığın indeksini, t zaman adımını ve j özellik indeksini göstermek üzere, katmanın çıktısı $Y(b, t, j) = X(b, t, j) \cdot W_s[s(t), j]$ biçiminde hesaplanır. Burada $s(t) = (t + d_0) \bmod P$ ifadesi mevsimsel indeksi belirler; $P = 7$ haftalık periyodu, d_0 ise veri setinin başlangıç gününün haftanın hangi gününe denk geldiğini gösteren sabit ofseti temsil eder.

Bu katmanda $W_s \in \mathbb{R}^{P \times J}$ boyutundaki ağırlık matrisi Glorot düzgün dağılım ile başlatılır ve eğitim süresince geri yayılım yoluyla güncellenir. Modülo işlemi sayesinde her zaman adımı otomatik olarak haftanın ilgili gününe eşlenir ve haftalık tekrar eden örüntüler öğrenilebilir hale gelir. Bu yaklaşım, geleneksel sabit mevsimsel ayrıştırma yöntemlerinden farklı olarak veri temelli ve uçtan uca eğitilebilir bir mevsimsellik modelleme mekanizması sunmaktadır.

$$Y[b, t, j] = X[b, t, j] \cdot W_s[s(t), j], s(t) = (t + d_0) \bmod P \quad (D.12)$$

Tüm modeller, verimliliği ve uyarlanabilir öğrenme oranlarıyla bilinen Adam optimizasyon algoritması (Kingma & Ba, 2014) kullanılarak eğitilmiştir. Öğrenme oranı tüm

yapılandırmalar için 0.001 olarak ayarlanmıştır. Kayıp fonksiyonu olarak regresyon görevi için uygun olan Ortalama Kare Hata (Mean Squared Error - MSE) kullanılmıştır. Derin öğrenme modellerinde kullanılan hiperparametreler Tablo 3.2’de özetlenmiştir.

Tablo 3.2. Tekrarlayan sinir ağı tabanlı modellerde kullanılan hiperparametre değerleri

Kategori	Hiperparametre	Değer(ler)
Temel Parametreler	Epoch Sayısı	20
	Batch Boyutu	64
	Öğrenme Oranı	0.001
	Optimizasyon Algoritması	Adam
	Kayıp Fonksiyonu	Mean Squared Error
	Dropout Oranı	0.2
	Recurrent Dropout Oranı	0.2
Model Yapısı	Nöron Sayısı	200, Yoğun Katman: 200
	Aktivasyon Fonksiyonu	ReLU
Girdi Yapısı	Ölçeklenen Sütunlar ve Yama Boyutları	Sipariş miktarı, Birim fiyat, Net fiyat; yama boyutları: [7, 14], [7, 28], [16, 32], [16, 64]

3.3. Çalışmada Kullanılan Topluluk Öğrenme Algoritmaları

Derin öğrenme modelleri (LSTM, GRU, BiLSTM, BiGRU) tarafından üretilen tahminlerin doğruluğunu ve sağlamlığını daha da artırmak amacıyla, bu çalışmada ek bir modelleme katmanı olarak topluluk (ensemble) öğrenme algoritmaları kullanılmaktadır. Tekrarlayan sinir ağları zamansal bağımlılıkları yakalamada etkili olsa da, ilk aşamada üretilen tahmin vektörleri ikinci aşama bir regresyon katmanında yeniden işlenerek daha kararlı sonuçlar elde edilebilmektedir. Bu çerçevede, her yama için eğitilen tekrarlayan modellerin ürettiği tahmin vektörleri, topluluk regresörlerinden oluşan ikinci aşama bir tahmin katmanı için girdi olarak kullanılmaktadır. Bunlar, regresyon görevlerindeki güçlü performansları nedeniyle seçilen RF, XGBoost, GBM ve HGBR algoritmalarını içermektedir.

3.3.1. Rastgele orman (Random Forest - RF)

Rastgele orman algoritması, Breiman (2001) tarafından önerilen ve birden fazla karar ağacının bir araya getirilmesiyle oluşturulan bir topluluk öğrenme yöntemidir. Her bir karar ağacı, eğitim verisinin rastgele seçilmiş bir alt kümesi (bootstrap örnekleme) üzerinde bağımsız olarak eğitilir ve her bölünme noktasında yalnızca rastgele seçilen bir özellik alt kümesi değerlendirilir. Bu çift katmanlı rastsallık mekanizması, ağaçlar arasındaki korelasyonu azaltarak modelin genelleme yeteneğini artırır.

Regresyon görevlerinde rastgele orman, her ağacın ürettiği tahminlerin ortalamasını alarak nihai sonucu üretir. Bu ortalama alma işlemi, bireysel ağaçların yüksek varyanslı tahminlerini yumuşatarak daha kararlı ve güvenilir sonuçlar elde edilmesini sağlar. Ayrıca aşırı uyum riskini önemli ölçüde azaltır. Bu çalışmada `n_estimators` parametresi 100 olarak belirlenmiş; bu değer yeterli topluluk çeşitliliği ile makul hesaplama süresi arasında bir denge sağlamaktadır.

Scikit-learn'deki `MultiOutputRegressor` arayüzü, ilk aşamada her yama için üretilen çok değişkenli çıktı vektörlerini ikinci aşama topluluk regresörleriyle işlemek için kullanılmıştır. Sipariş Tarihi indeks olarak ayrıldıktan sonra modele üç sayısal sütun (Sipariş miktarı, Birim fiyat, Net fiyat) birlikte verilmiştir; bu nedenle her pencerenin ara çıktı vektörü üç boyutludur. İki yama için eğitilen tekrarlayan ağların ürettiği [örnek sayısı x 3] boyutlu tahminler ortak uzunlukta hizalanmış, ortalaması alınmış ve yine [örnek sayısı x 3] boyutunda ikinci aşama topluluk (ensemble) girdisi oluşturulmuştur. Nihai performans değerlendirmesi ise yalnızca bu tahminlerden türetilen günlük toplam Net fiyat serisi üzerinde yapılmıştır; dolayısıyla tezin ana raporlanan değerlendirme hedefi günlük toplam net satış tutarıdır.

3.3.2. Aşırı gradyan artırma (Extreme Gradient Boosting - XGB)

Aşırı gradyan artırma (XGBoost), Chen ve Guestrin (2016) tarafından geliştirilen ve gradyan artırma çerçevesinin optimize edilmiş bir uygulamasıdır. Algoritma, zayıf öğrencileri sıralı biçimde ekleyerek her yeni ağacın önceki modelin artık hatalarını düzeltilmesini sağlar. XGBoost, ikinci derece Taylor açılımı kullanarak kayıp fonksiyonunu daha doğru biçimde yakınsar ve düzenleştirme terimleri ile aşırı uyumu kontrol altında tutar.

XGBoost'un temel avantajları arasında verimli bellek kullanımı, paralel hesaplama desteği ve eksik değerlerle başa çıkabilme yeteneği sayılabilir. Ağaç budama stratejisi, maksimum derinliğe ulaşıldıktan sonra geriye doğru budama yaparak gereksiz dallanmaları ortadan kaldırır. Bu çalışmada XGBoost, `n_estimators=100` ve varsayılan hiperparametreler

ile kullanılmış; farklı tekrarlayan ağ çıktıları üzerindeki ikinci aşama regresyon performansı karşılaştırmalı olarak değerlendirilmiştir.

3.3.3. Gradyan artırma regresörü (Gradient Boosting Regressor - GBM)

Gradyan artırma regresörü, (Friedman, 2002) tarafından önerilen genel bir topluluk öğrenme çerçevesidir. Bu yöntem, her yineleme adımında kayıp fonksiyonunun negatif gradyanı yönünde yeni bir zayıf öğrenici ekleyerek modeli kademeli olarak iyileştirir. Scikit-learn kütüphanesindeki GradientBoostingRegressor uygulaması, her bölünme noktasında ortalama kare hatasını minimize eden karar ağaçlarını temel öğrenici olarak kullanır.

GBM'nin temel güçlü yönü, çeşitli kayıp fonksiyonları ile esnek biçimde çalışabilmesidir. Öğrenme oranı parametresi, her ağacın katkısını ölçeklendirerek modelin yakınsama hızını ve genelleme performansını doğrudan etkiler. Bu çalışmada tutarlılık ve karşılaştırılabilirlik amacıyla $n_estimators=100$ ve rastgelelik durumu 42 olarak sabitlenmiştir.

3.3.4. Histogram tabanlı gradyan artırma regresörü (Histogram-based Gradient Boosting Regressor - HGBR)

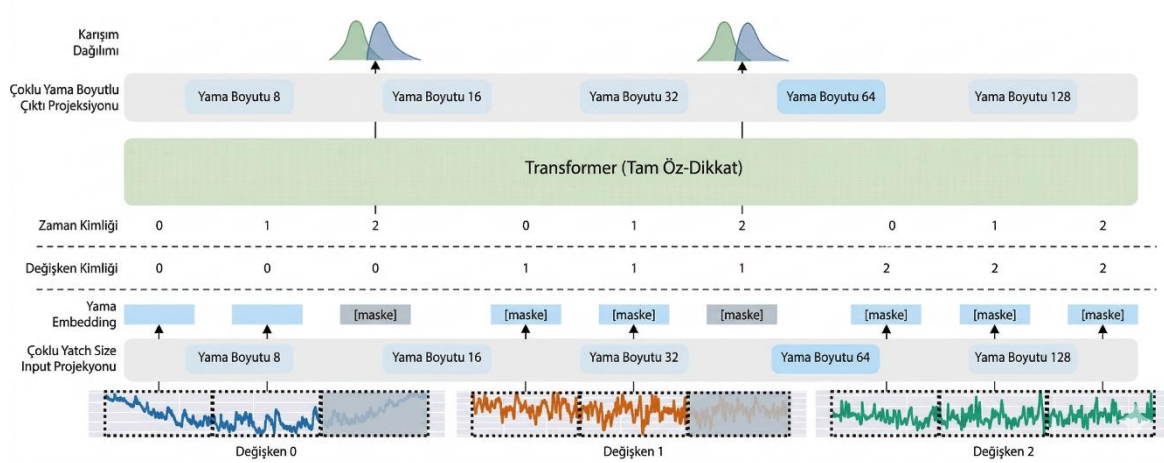
Histogram tabanlı gradyan artırma regresörü, scikit-learn kütüphanesinde bulunan ve büyük veri kümeleriyle verimli çalışacak şekilde tasarlanmış bir gradyan artırma uygulamasıdır. Bu algoritma, sürekli giriş özelliklerini sabit sayıda ayrık kutucuğa (histogram) gruplama stratejisi kullanarak bölünme noktalarının değerlendirilmesini hızlandırır. Bu histogram tabanlı yaklaşım, özellikle büyük örneklem sayılarında standart gradyan artırma yöntemlerine kıyasla önemli bir hesaplama avantajı sağlar.

HGBR, LightGBM algoritmasından esinlenerek geliştirilmiş olup eksik değerleri doğal biçimde işleyebilme yeteneğine sahiptir. Eğitim sırasında her düğümde en iyi bölünme yönünü otomatik olarak belirleyerek eksik değer atama ihtiyacını ortadan kaldırır. Bu çalışmada diğer topluluk algoritmalarıyla tutarlılık sağlamak amacıyla $n_estimators=100$ ve rastgelelik durumu 42 olarak ayarlanmıştır.

3.4. Çoklu Yama Yaklaşımı

Çoklu yama yaklaşımı, zaman serisi verilerini birden fazla zamansal çözünürlükte analiz ederek hem kısa vadeli dalgalanmaları hem de uzun vadeli eğilimleri daha etkili bir şekilde yakalamayı amaçlar. Bu yöntemde, farklı zaman pencerelerinden çıkarılan veri segmentleri (yamalar) ayrı ayrı işlenir ve çıktıları birleştirilerek nihai tahmin üretilir. Literatürde benzer fikirler MOIRAI ve MPMixer gibi yama tabanlı evrensel zaman serisi modellerinde

kullanılmaktadır. Şekil 3.8, çoklu yama yaklaşımının mimarisini göstermektedir.(Woo vd., 2024)(Xu vd., 2025)



Şekil 3.8. Çoklu yama yaklaşımı mimarisini


Bu çalışmada, (7,14), (7,28), (16,32) ve (16,64) gün aralıkları dâhil olmak üzere çeşitli yama konfigürasyonları test edilmiştir. Önerilen model, 7 günlük ve 14 günlük olmak üzere iki özel yama boyutunu kullanmaktadır. 7 günlük yama haftalık örüntüleri yakalamak üzere tasarlanırken, 14 günlük yama iki haftalık dinamikleri hedeflemektedir. Yama üretim algoritması özetle şöyledir:

- Normalize edilmiş günlük seri üzerinde, her bir yama boyutu için sırasıyla pencere kaydırılır;
- Her penceredeki değerler bir örnek (girdi) olarak saklanır;
- İki farklı boyut kullanıldığında iki ayrı girdi seti oluşturulur ve her biri ilgili RNN/topluluk hattına beslenir;
- İki yama hattından elde edilen tahminler ortak uzunlukta hizalandıktan sonra ortalaması alınmakta ve elde edilen tahmin vektörü topluluk regresyon katmanına girdi olarak verilmektedir. Her bir yama, derin öğrenme modeline bağımsız olarak girdi olarak kullanılmakta; yama tabanlı tahminler bir araya getirildikten sonra ikinci aşama topluluk regresyonu ile nihai çıktı üretilmektedir.

3.5. MP-LRNet: Çoklu Yama LSTM-RF Ağı

Önerilen hibrit model olan MP-LRNet (Çoklu Yama LSTM-RF Ağı), çoklu ölçekli zamansal temsilleri çoklu yama giriş mekanizması aracılığıyla derin yinelemeli ağlar ve

topluluk (ensemble) tabanlı iyileştirmelerle birleştirerek doğru satış tahmini elde etmeyi amaçlamaktadır. MP-LRNet mimarisi temel olarak Şekil 3.9’de gösterilmektedir.



Şekil 3.9. Çoklu Yama LSTM-RF Ağı mimarisi

MP-LRNet’te, ham zaman serisi verileri ilk olarak Min-Max ölçeklendirme kullanılarak normalize edilir; böylece giriş değerleri standartlaştırılır ve tüm özelliklerin aynı sayısal aralıkta yer alması sağlanır. Normalizasyonun ardından veriler, farklı zamansal ayrıntı düzeylerini yakalamak amacıyla yamalar (patches) olarak adlandırılan birden fazla zamansal segmente yeniden şekillendirilir. Bu çalışmada, satış verilerindeki kısa vadeli dinamikleri ve orta vadeli mevsimsel eğilimleri eş zamanlı olarak yakalamak için 7 günlük ve 14 günlük olmak üzere iki yama boyutu kullanılmaktadır.

Bu yamaların her biri, sonraki öğrenme bileşeni için bağımsız bir giriş dizisi olarak görev yapar. Her yama, dizideki zamansal bağımlılıkları işleyen bir LSTM modeline giriş olarak verilir. LSTM modelinin son Dense katmanından elde edilen tahmin vektörleri, yama boyutları arasında hizalanıp ortalanarak RF Regresörü’ne giriş olarak kullanılmaktadır. Böylece topluluk katmanı, ilk aşama tekrarlayan modelin ürettiği tahminleri düzeltici bir ikinci aşama öğrenici olarak işlemektedir.

3.5.1. Eğitim protokolü ve sistematik mimari karşılaştırma tasarımı

MP-LRNet mimarisinin değerlendirilmesi için, modelin temel bileşenlerinin etkilerini karşılaştıran kapsamlı bir sistematik mimari karşılaştırma tasarlanmıştır. Bu amaçla, dört temel boyut üzerinde sistematik bir mimari tarama gerçekleştirilmiştir:

- Mevsimsel Momentum Katmanının varlığı/yokluğu,
- Yama yapısı (None, (7,14), (7,28), (16,32), (16,64)),
- Tekrarlayan ağ türü (LSTM, BiLSTM, GRU, BiGRU) ve
- İkinci aşama topluluk (ensemble) algoritması (Yok, RF, XGB, GBM, HGBR).

Bu kombinasyonlar sonucunda toplam 200 farklı model konfigürasyonu elde edilmiş ve her biri aynı eğitim/test bölünmesi ve hiperparametreler (20 epoch, batch boyutu 64,

öğrenme oranı 0.001, Adam optimizasyon algoritması) altında on kez çalıştırılmıştır. Bu değerler, derin öğrenme uygulamalarında yaygın başlangıç ayarları olmaları ve tüm konfigürasyonların karşılaştırılabilir sürede eğitilmesine izin vermeleri nedeniyle sabit tutulmuştur; ancak ayrı bir doğrulama kümesi üzerinde optimize edilmemiştir. Erken durdurma uygulanmamış olması, bazı yapılandırmaların hafif eksik öğrenme veya aşırı uyum eğilimi taşıyabilmesi anlamına gelmektedir. Ayrıca değerlendirme tek bir kronolojik bölünme ve yaklaşık beş aylık bir test dönemi üzerinden yapılmıştır; bu nedenle bulgular bu veri seti ve deney protokolü altında yorumlanmalıdır. Tüm deneylerde rastgelelik durumu 42 kullanılarak veri bölme ve topluluk (ensemble) yöntemlerindeki rastgelelik kontrol altına alınmış, böylece farklı yapılandırmaların adil biçimde karşılaştırılması sağlanmıştır. 200 karşılaştırmalı konfigürasyonun tamamı aynı kronolojik test dönemi üzerinden değerlendirilmiş ve en iyi yapılandırma da bu test dönemi sonuçlarına göre belirlenmiştir. Ayrı bir doğrulama (validation) kümesi veya zaman serisine uygun çapraz doğrulama (rolling-origin) kullanılmadığından, en iyi konfigürasyonun seçimi model seçim yanlılığı (model selection bias) içerebilir; bu nedenle sonuçlar mutlak bir üstünlük kanıtı olarak değil, bu veri seti ve protokol altındaki kontrollü karşılaştırmanın bulguları olarak yorumlanmalıdır.

3.6. Performans Değerlendirme Metrikleri

Modellerin performansını değerlendirmek için dört farklı değerlendirme metriği kullanılmıştır: Belirleme Katsayısı (R^2), Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE). Bu metrikler, modellerin doğruluğunun farklı bakış açılarından değerlendirilmesine olanak tanır.

R^2 , varyansın ne oranda açıklandığını 0-1 aralığında ölçtüğü için karşılaştırmalarda yaygın ve yorumu kolaydır; ancak sabit sapma (bias) durumunda yanıltıcı olabilir. MAE ve RMSE ham hata büyüklüğünü verir; RMSE büyük hatalara daha duyarlıdır, MAE ise ortalama sapmayı daha dengeli yansıtır (Chai & Draxler, 2014). MAPE, hatayı yüzde cinsinden ifade ettiği için iş birimleriyle iletişimde faydalıdır; ancak gerçek değerlerin sıfıra yakın olduğu durumlarda aşırı büyüyebilir. Bu çalışmada sıfır satış günleri seriden çıkarılmamış, günlük toplamda 0 olarak korunmuştur; MAPE hesabında sıfıra bölünmeyi önlemek için paydaya küçük bir epsilon değeri eklenmiştir. Bu tercih yüzde hatayı tanımlı tutsa da, sıfır satış günlerinin seriye dahil edilmesi düşük varyanslı dönemlerin sayısını artırabileceği için R^2 yorumunun da bu veri hazırlama tercihi bağlamında temkinli yapılması gerekir. Satış tahmini bağlamında ana değerlendirme değişkeni günlük net satış tutarıdır. R^2 , nMAE, nRMSE ve MAPE bu seri üzerinden raporlanmıştır; burada nMAE ve nRMSE, günlük net satış serisi için

hesaplanan ham MAE ve RMSE değerlerinin test dönemi aralığına bölünerek yüzde cinsine ölçeklenmiş biçimleridir. Denklem D.13 ve D.14'te bu normalizasyon gösterilmektedir:

$$nMAE = 100 * \frac{MAE}{\max(y_{test}) - \min(y_{test})} \quad (D.13)$$

$$nRMSE = 100 * \frac{RMSE}{\max(y_{test}) - \min(y_{test})} \quad (D.14)$$

Bu nedenle nMAE ve nRMSE değerleri ham TL hatasını değil, test dönemi aralığına göre ölçeklenmiş yüzde hatayı göstermektedir. Ham TL cinsinden MAE ve RMSE bu çalışmada ayrıca raporlanmamış olup, bu durum çalışmalar arası doğrudan karşılaştırmayı sınırlandırmaktadır.

Denklem D.15'de gösterilen R^2 , hedef değişkendeki varyansın model tarafından açıklanan oranını ölçer ve değerleri 0 ile 1 arasında değişir. 1'e daha yakın değerler, veriyi açıklamada daha iyi model performansını gösterir (Chicco vd., 2021). Denklem D.16'da sunulan nMAE, günlük net satış serisi için hesaplanan MAE değerinin test dönemindeki değer aralığına bölünerek yüzde cinsinden ifade edilmiş hâlidir. Denklem D.17'de tanımlanan nRMSE ise RMSE değerinin aynı aralığa göre ölçeklenmiş biçimidir. MAPE, Denklem D.18'de verildiği üzere, mutlak hatanın gerçek değerlere oranının ortalama yüzdesini hesaplayarak hatayı yüzde cinsinden yorumlanabilir bir metrik olarak sunar (de Myttenaere vd., 2016).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (D.15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (D.16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (D.17)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (\text{D.18})$$

4. DENEYSEL SONUÇLAR

Bu bölümde, önerilen MP-LRNet modelinin performansı kapsamlı bir deneysel çerçeve içinde değerlendirilmektedir. Mevsimsel Momentum Katmanı, çoklu yama yapıları, tekrarlayan sinir ağı türleri ve topluluk öğrenme algoritmaları olmak üzere dört temel bileşenin tüm kombinasyonları sistematik olarak test edilerek toplamda 200 farklı model konfigürasyonu oluşturulmuştur. Her konfigürasyon aynı koşullar altında on kez çalıştırılmış ve ortalama performans metrikleri hesaplanmıştır. İlk olarak her bileşenin performans etkisi ayrı ayrı incelenmekte, ardından MP-LRNet ve diğer modellerin kapsamlı karşılaştırması sunulmaktadır.

4.1. Mevsimsel Momentum Katmanının Başarıma Etkisi

Farklı tekrarlayan sinir ağı yapı kombinasyonları, çoklu yama ayarları, topluluk (ensemble) algoritmaları ve Mevsimsel Momentum Katmanı durumları altında test edilen 200 karşılaştırmalı konfigürasyonun tamamı genel olarak yüksek tahmin doğruluğu üretmiştir. Bu tarama genelinde ortalama R^2 değeri 0,9586 olarak ölçülmüş; en iyi karşılaştırmalı konfigürasyon 0,9915'e ulaşırken, en düşük değer 0,8007 olarak kaydedilmiştir. Buna ek olarak, ayrı olarak raporlanan önerilen MP-LRNet ana deneyi on bağımsız çalışmada ortalama 0,9918 R^2 üretmiştir. Bu sonuçlar, farklı ayarlarda dahi yüksek doğruluk elde edilebildiğini göstermekte; ancak önerilen yapı ile karşılaştırmalı konfigürasyon uzayının aynı istatistik başlığı altında karıştırılmaması gerektiğini de ortaya koymaktadır.

Bu karşılaştırmalı konfigürasyonlardan yola çıkılarak, Mevsimsel Momentum Katmanının etkisi tüm tekrarlayan sinir ağı yapıları üzerinde analiz edilmiştir. Bulgular, bu katmanın tahmin doğruluğuna katkısının sınırlı olduğunu göstermektedir. 200 konfigürasyonun ortalaması alındığında, ortalama R^2 değeri 0,9749'dan 0,9737'ye hafifçe düşmüş; nMAE ve nRMSE değerleri ise sırasıyla 0,0223 ve 0,0429 oranında az miktarda artış göstermiştir. Genel olarak Mevsimsel Momentum Katmanı bu veri setinde belirgin bir performans kazanımı üretmemiştir. Bu sonuç, önerilen bir bileşenin her veri hazırlama tercihinde ve her mimaride aynı ölçüde yarar sağlamayabileceğini gösteren önemli bir negatif bulgu olarak değerlendirilmelidir. Daha sonra, çoklu yama konfigürasyonları tahmin kararlılığı ve doğruluğu üzerindeki etkilerini değerlendirmek amacıyla incelenmiştir.

4.2. Çoklu Yamanın Başarıma Etkisi

Çoklu yama mekanizması, geçmiş verileri daha küçük zaman dilimi parçalarına bölerek periyodik bağımlılıkları yakalamayı ve böylece modelin kısa ve orta vadeli talep

değişimlerine duyarlılığını artırmayı amaçlamaktadır. Karşılaştırmalı tablolar içinde en doğru ve en kararlı sonuçlar sürekli olarak (7, 14) yama boyutu kombinasyonu ile elde edilmiştir; bu alt uzayda LSTM tabanlı yapı için en yüksek R^2 0,9910, BiLSTM tabanlı yapı için ise 0,9915 olarak ölçülmüştür. Aynı şekilde raporlanan önerilen MP-LRNet ana deneyinde de (7,14) yapısı ortalama 0,9918 R^2 üretmiştir. Buna karşılık, özellikle (16, 64) gibi daha büyük yama konfigürasyonları tahmin doğruluğunu düşürme eğiliminde olmuş; R^2 değerleri genellikle 0,98'in altında kalmıştır. Yama kullanılmayan konfigürasyonlar genel eğilim olarak daha düşük performans göstermiştir; ancak bazı topluluk (ensemble) destekli yapılar orta-üst düzey sonuçlar üretmiştir. Bu bulgular, (7, 14) yama yapısının bu veri seti altında duyarlılık ile genelleme arasında uygun bir denge sunduğunu göstermektedir.

4.3. Tekrarlayan Sinir Ağlarının Etkisi

Sonraki aşamada, en başarılı model yaklaşımını belirlemek için çeşitli tekrarlayan sinir ağı mimarilerinin (LSTM, BiLSTM, GRU ve BiGRU) performansı incelenmiştir. En iyi tekil konfigürasyonlar LSTM tabanlı modelde 0,9918 ve BiLSTM tabanlı modelde 0,9915 R^2 üretmiştir. Buna karşılık aile ortalaması ve kararlılık bakımından LSTM daha tutarlı görünmektedir; tüm topluluk kombinasyonlarında ortalama R^2 0,9786, ortalama nMAE 1,09 ve nRMSE 1,83 olarak ölçülmüştür. BiGRU varyantı yakından takip etmiştir ($R^2 = 0,9778$) ancak hata değerleri biraz daha yüksek olduğu gözlemlenmiştir (+0,031 nMAE ve +0,045 nRMSE). BiLSTM ve GRU modelleriyle de olumlu bulgular elde edilmiştir; ancak özellikle yama kullanılmadığında veya daha zayıf topluluklar uygulandığında daha yüksek değişkenlik gözlemlenmiştir. Hesaplama verimliliği açısından, GRU tabanlı modeller ortalama %10-15 daha hızlı olurken, BiLSTM modelleri çift yönlü işlem nedeniyle en uzun eğitim süresini gerektirmiştir. Genel olarak, sonuçlar LSTM ve BiGRU mimarilerinin doğruluk, kararlılık ve çalışma süresi verimliliği arasında dengeli bir görünüm sunduğunu göstermektedir.

4.4. Makine Öğrenmesi Algoritmalarının Başarıma Etkisi

Topluluk öğrenme algoritmalarının R^2 skoru üzerindeki etkisi Şekil 4.8'de gösterilmektedir.

Topluluk öğrenme algoritmalarının etkisi incelendiğinde, Şekil 4.8'de görüldüğü gibi, RF (RF) tüm tekrarlayan sinir ağı yapılarında tutarlı bir şekilde en yüksek tahmin doğruluğunu elde etmiş ve karşılaştırmalı LSTM- ve BiLSTM tabanlı konfigürasyonlar için sırasıyla 0,9910 ve 0,9915 ile en yüksek R^2 değerlerine ulaşmıştır. XGBoost (XGB) benzer sonuçlarla yakından takip etmiş, genellikle R^2 'de 0,002-0,004 fark ile, ancak nMAE ve nRMSE değerlerinde biraz daha yüksek değerler göstermiştir. Hem GBM (GBM) hem de HGBR

istikrarlı ancak daha az rekabetçi sonuçlar üretmiş, R^2 değerleri çoğunlukla 0,970-0,975 aralığında kalmıştır. Topluluk bileşeni içermeyen modeller (“None”) genel eğilim olarak daha düşük doğruluk üretmiş; ancak bazı yapılandırmalarda orta düzey sonuçlar da gözlemlenmiştir. Çalışma süresi açısından RF ve XGB hız ve doğruluk arasında iyi bir denge sunarken, GBM ve HGBR daha uzun eğitim süreleri gerektirmiş ancak kayda değer bir iyileşme sağlamamıştır. Bu sonuçlar, RF’in MP-LRNet’e entegre edilmesinin, bu veri seti altında sağlamlık ve tahmin doğruluğu arasında uygun bir denge sağladığını göstermektedir. LSTM çıktıları üzerinde ikinci aşama regresör olarak RF kullanımının perakende talep tahmininde performansı artırdığı, bağımsız çalışmalarda da raporlanmıştır (Punia vd., 2020). Bu deneylerde gözlemlenen genel eğilimler, bir sonraki bölümde sunulan karşılaştırmalı tartışma ve yorumlama için temel oluşturmaktadır.

4.5. MP-LRNet ve Diğer Modellerin Performans Karşılaştırması


Önerilen MP-LRNet modeli, tahmin etkinliğini doğrulamak amacıyla gerçek dünya mobilya satış verisi üzerinde test edilmiştir. Model on bağımsız çalışmada tutarlı bir performans sergilemiş; bu veri seti ve deney protokolü altında ortalama olarak R^2 0,9918, nMAE (%) 0,7321, nRMSE (%) 1,1896 ve MAPE 10,1562 değerlerine ulaşmıştır. R^2 'nin varyansın açıklanan oranını ölçmesi (Chicco vd., 2021) ve nMAE ile nRMSE'nin normalize edilmiş hata büyüklüğünü farklı biçimde yansıtması dikkate alındığında, bu metrik seti tez içindeki konfigürasyon karşılaştırması için uygundur. En iyi performans gösteren çalışmada R^2 0,9927, nMAE 0,6984, nRMSE 1,1205 ve MAPE 9,7073 iken, en düşük performans gösteren yinelemede bile R^2 0,9907, nMAE 0,7772, nRMSE 1,2675 ve MAPE 10,8761 değerleri elde edilmiştir. Test döneminde gerçek satış değerleri ile tahmin değerlerinin zaman serisi üzerindeki karşılaştırması Şekil 4.1’de gösterilmektedir.



Şekil 4.1. MP-LRNet satış tahmin sonuçları

Şekil 4.1’de, en iyi performans gösteren MP-LRNet konfigürasyonu için test kümesindeki gerçek satış değerleri ile model tahminleri zaman eksenini boyunca birlikte sunulmaktadır. Grafik incelendiğinde, modelin hem günlük dalgalanmaları hem de orta vadeli eğilimleri büyük ölçüde doğru yakaladığı görülür. Ani talep artışlarının yaşandığı dönemlerde tahmin eğrisinin gerçek seriyi yakından takip etmesi, çoklu yama mekanizmasının kısa ve orta vadeli örüntüleri birlikte temsil etme kapasitesiyle tutarlıdır. Bazı uç değer içeren günlerde tahmin eğrisinin hafifçe düzleşmesi gözlemlenmektedir. Genel olarak bu görsel, modelin gerçek satış eğrisini yakından izleyebildiğini göstermektedir; ancak operasyonel fayda bu tez kapsamında doğrudan ölçülmemiştir.

Gerçek ile tahmin edilen satış değerlerinin dağılımı (scatter) Şekil 4.2’de verilmektedir.



Şekil 4.2. Gerçek ve tahmin edilen satış değerlerinin dağılımı (scatter)

Şekil 4.2’de, test kümesindeki her bir gözlem için gerçek satış değerleri (yatay eksen) ile model tahminleri (dikey eksen) scatter grafik üzerinde sunulmaktadır. İdeal bir tahmin durumunda noktalar 45° çizgisi üzerinde toplanır. Noktaların büyük kısmının bu çizginin etrafında yoğunlaştığı görülmekte; yalnızca birkaç uç gözlemlerde sapma bulunmaktadır. Bu görünüm, Tablo 4.1’de rapor edilen yüksek R^2 (0,9918) değerinin görsel karşılığıdır ve modelin hem düşük hem de yüksek satış dönemlerinde tutarlı doğruluk sergilediğini desteklemektedir

Önerilen MP-LRNet yapılandırmasının performansını bağlamsallaştırmak için, dört temel bileşeni değiştirerek toplamda 200 farklı karşılaştırmalı model konfigürasyonu oluşturulmuştur: Mevsimsel Momentum Katmanı’nın (Etkin / Etkin Değil) durumu, çoklu yama (Multi-Patch) yapıları (Yok, 7-14, 7-28, 16-32 ve 16-64), tekrarlayan sinir ağı türü (LSTM, BiLSTM, GRU veya BiGRU) ve topluluk öğrenme algoritması (RF, XGBoost, GBM, HGBR veya topluluk bileşeni içermeyen karşılaştırma yapısı). Her konfigürasyon, aynı

koşullar altında on kez çalıştırılmış ve ortalama R^2 , nMAE, nRMSE ve MAPE değerleri ile ortalama eğitim süresi hesaplanmıştır. Tablo 4.1'in ilk satırı, önerilen MP-LRNet ana deneyinin on çalıştırma ortalamasını özetlemektedir; bu satırın altındaki kayıtlar ise 200 karşılaştırmalı konfigürasyondan LSTM tabanlı alt kümenin sonuçlarını sunmaktadır. Tablo 4.2 BiLSTM tabanlı, Tablo 4.3 GRU tabanlı ve Tablo 4.4 BiGRU tabanlı alt kümeleri vermektedir. Tüm bu tablolarda topluluk öğrenme algoritmaları kısaltmalarla gösterilmiştir: RF (RF), XGBoost (XGB), GBM (GBM) ve HGBR

Tablo 4.1. LSTM tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Önerilen MP-LRNet ana deneyi (10 çalıştırma ort.)			0,9918	0,7321	1,1896	10,1562	16,87
Etkin	7, 14	RF	0,9910	0,7518	1,2462	10,2768	17,45
Etkin Değil	7, 28	RF	0,9871	0,9501	1,4907	12,2640	20,02
Etkin	7, 28	RF	0,9869	0,9533	1,5037	12,1854	19,98
Etkin Değil	16, 32	RF	0,9858	1,0158	1,5624	13,1863	21,23
Etkin	16, 32	RF	0,9853	1,0330	1,5916	13,2352	22,02
Etkin Değil	7, 14	XGB	0,9836	1,0422	1,6792	12,4183	16,80
Etkin	7, 14	XGB	0,9820	1,0731	1,7568	12,9476	10,47
Etkin Değil	16, 32	XGB	0,9809	1,1501	1,8115	13,3735	27,10
Etkin Değil	7, 28	XGB	0,9809	1,1356	1,8105	13,0542	19,57
Etkin Değil	None	RF	0,9803	1,2739	1,8422	16,5570	27,43
Etkin	None	RF	0,9791	1,3008	1,8943	16,7029	17,30
Etkin	7, 28	XGB	0,9789	1,1506	1,9011	13,0659	13,30
Etkin Değil	16, 64	RF	0,9785	1,3324	1,9221	16,5861	28,85
Etkin	16, 32	XGB	0,9782	1,1795	1,9342	13,3998	15,17
Etkin	16, 64	RF	0,9773	1,3432	1,9743	16,6076	28,78
Etkin Değil	7, 14	GBM	0,9758	1,2131	2,0394	13,1448	18,48
Etkin Değil	7, 28	GBM	0,9756	1,2162	2,0447	13,4352	22,10
Etkin Değil	None	XGB	0,9746	1,3772	2,0891	16,4470	18,62
Etkin Değil	16, 64	XGB	0,9737	1,3602	2,1213	15,8152	34,78
Etkin Değil	7, 14	HGBR	0,9734	1,2700	2,1370	13,6754	17,17
Etkin	7, 14	HGBR	0,9722	1,2636	2,1805	13,5618	9,78
Etkin	7, 14	GBM	0,9721	1,2563	2,1880	13,4442	11,20
Etkin	None	XGB	0,9721	1,4346	2,1899	16,7620	10,08
Etkin Değil	16, 32	GBM	0,9715	1,3039	2,2035	14,3571	29,20

Tablo 4.1. Devamı

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	16, 32	HGBR	0,9714	1,3222	2,2107	14,5674	26,77
Etkin Değil	7, 28	HGBR	0,9710	1,3159	2,2280	13,9855	20,27
Etkin	7, 28	GBM	0,9707	1,2935	2,2418	13,8779	14,33
Etkin	16, 64	XGB	0,9704	1,3864	2,2521	15,8033	21,68
Etkin	16, 32	GBM	0,9694	1,3439	2,2906	14,6410	16,48
Etkin	7, 28	HGBR	0,9689	1,3411	2,3075	14,1527	12,90
Etkin Değil	None	HGBR	0,9688	1,4826	2,3137	16,9109	16,83
Etkin Değil	None	GBM	0,9687	1,4694	2,3171	16,8484	18,45
Etkin Değil	16, 64	HGBR	0,9671	1,4338	2,3702	16,0135	30,58
Etkin Değil	16, 64	GBM	0,9668	1,4425	2,3794	16,0757	33,18
Etkin	16, 32	HGBR	0,9654	1,4143	2,4354	15,0201	14,95
Etkin	None	GBM	0,9620	1,5512	2,5522	17,1613	11,75
Etkin	16, 64	GBM	0,9615	1,4950	2,5590	16,2681	23,35
Etkin	None	HGBR	0,9602	1,6040	2,6138	17,5737	9,95
Etkin	16, 64	HGBR	0,9547	1,6001	2,7779	17,0471	21,43
Etkin Değil	16, 32	None	0,9385	1,7884	3,1841	13,8754	21,45
Etkin Değil	7, 28	None	0,9324	1,8401	3,3404	13,5798	17,73
Etkin	16, 64	None	0,9292	1,9627	3,3977	15,9646	21,33
Etkin	16, 32	None	0,9282	1,9203	3,4427	14,6882	14,77
Etkin Değil	16, 64	None	0,9263	1,9988	3,4799	15,6603	28,00
Etkin	7, 28	None	0,9122	2,0922	3,8127	14,7268	12,77
Etkin Değil	7, 14	None	0,9010	2,2579	4,0207	15,3736	14,18
Etkin	7, 14	None	0,8975	2,3464	4,0686	16,6610	9,65
Etkin	None	None	0,8860	2,4338	4,1357	18,6236	9,87
Etkin Değil	None	None	0,8168	2,9956	5,2940	21,1228	12,87

Tablo 4.2. BiLSTM tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	7, 14	RF	0,9915	0,7363	1,2099	10,1201	26,13
Etkin	7, 14	RF	0,9910	0,7590	1,2462	10,2551	26,53
Etkin Değil	7, 28	RF	0,9870	0,9517	1,4938	12,2128	28,18
Etkin	7, 28	RF	0,9869	0,9516	1,5009	12,1290	27,97
Etkin	16, 32	RF	0,9861	1,0078	1,5472	13,0848	33,93
Etkin Değil	16, 32	RF	0,9860	1,0119	1,5508	13,1689	33,73
Etkin Değil	7, 14	XGB	0,9820	1,0886	1,7582	12,8555	31,70
Etkin	7, 14	XGB	0,9819	1,0653	1,7635	12,6464	16,18
Etkin Değil	None	RF	0,9818	1,2225	1,7702	16,0110	45,62
Etkin	None	RF	0,9807	1,2485	1,8233	16,1430	25,83
Etkin Değil	16, 32	XGB	0,9800	1,1528	1,8502	13,2400	42,10
Etkin	7, 28	XGB	0,9796	1,1463	1,8738	13,0194	19,97
Etkin Değil	7, 28	XGB	0,9795	1,1696	1,8727	13,3653	32,95
Etkin Değil	None	XGB	0,9793	1,2260	1,8864	14,7019	35,77
Etkin Değil	16, 64	RF	0,9782	1,3238	1,9354	16,4241	48,38
Etkin	16, 32	XGB	0,9779	1,1730	1,9406	13,3024	25,85
Etkin	16, 64	RF	0,9779	1,3317	1,9511	16,4174	48,45
Etkin	None	XGB	0,9777	1,2769	1,9577	15,0589	18,47
Etkin Değil	16, 64	XGB	0,9755	1,2953	2,0496	15,0032	57,67
Etkin Değil	7, 14	GBM	0,9740	1,2399	2,1124	13,3403	33,12
Etkin Değil	None	GBM	0,9739	1,3144	2,1183	15,0658	32,82
Etkin Değil	16, 32	GBM	0,9733	1,2708	2,1392	13,9878	35,93
Etkin Değil	7, 14	HGBR	0,9728	1,2745	2,1609	13,7042	27,83
Etkin Değil	None	HGBR	0,9725	1,3542	2,1726	15,4373	30,52
Etkin	16, 64	XGB	0,9723	1,3466	2,1768	15,2838	40,17

Tablo 4.2. Devamı

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R ²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin	7, 14	GBM	0,9708	1,2721	2,2367	13,4393	18,10
Etkin	None	GBM	0,9707	1,3722	2,2418	15,3990	20,52
Etkin	16, 32	GBM	0,9706	1,2871	2,2465	13,8375	27,27
Etkin Değil	16, 32	HGBR	0,9700	1,3355	2,2686	14,3021	44,28
Etkin	None	HGBR	0,9691	1,3946	2,2944	15,4420	19,28
Etkin	7, 14	HGBR	0,9689	1,3267	2,3103	14,0054	16,52
Etkin Değil	7, 28	HGBR	0,9682	1,3888	2,3273	14,8882	39,08
Etkin	16, 32	HGBR	0,9673	1,3436	2,3573	14,2366	26,17
Etkin Değil	16, 64	GBM	0,9655	1,4502	2,4306	16,0293	63,57
Etkin Değil	7, 28	GBM	0,9654	1,4073	2,4365	14,8648	36,47
Etkin	7, 28	HGBR	0,9632	1,4292	2,5113	14,6811	21,48
Etkin	7, 28	GBM	0,9630	1,4089	2,5134	14,5586	21,15
Etkin	16, 64	GBM	0,9608	1,4673	2,5815	15,7171	43,05
Etkin Değil	16, 64	HGBR	0,9567	1,5896	2,7219	17,2107	58,58
Etkin	16, 64	HGBR	0,9566	1,5616	2,7248	16,5747	39,48
Etkin Değil	16, 32	None	0,9550	1,6106	2,6747	14,0981	37,42
Etkin	16, 32	None	0,9429	1,7298	3,0031	14,0916	25,83
Etkin Değil	7, 14	None	0,9403	1,7142	3,0910	12,5957	24,13
Etkin	7, 28	None	0,9335	1,8674	3,2790	14,3474	20,40
Etkin Değil	7, 28	None	0,9328	1,8427	3,3393	13,3064	30,85
Etkin	7, 14	None	0,9246	1,9218	3,4373	13,8245	15,95
Etkin Değil	16, 64	None	0,9246	1,9519	3,4668	14,9501	55,17
Etkin	16, 64	None	0,9125	2,1577	3,7878	16,4407	39,40
Etkin	None	None	0,9030	2,0900	3,6058	17,6011	18,47
Etkin Değil	None	None	0,8469	2,9041	4,8691	21,3886	23,38

Tablo 4.3. GRU tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	7, 14	RF	0,9912	0,7527	1,2322	10,3653	17,73
Etkin	7, 14	RF	0,9902	0,7847	1,2965	10,4694	18,62
Etkin Değil	7, 28	RF	0,9861	0,9836	1,5439	12,4218	20,87
Etkin	7, 28	RF	0,9855	0,9947	1,5781	12,5065	21,55
Etkin Değil	16, 32	RF	0,9847	1,0611	1,6215	13,6505	22,27
Etkin	16, 32	RF	0,9834	1,0876	1,6908	13,6772	23,27
Etkin Değil	7, 14	XGB	0,9820	1,0756	1,7598	12,8185	14,73
Etkin Değil	None	RF	0,9794	1,2948	1,8818	16,7094	25,73
Etkin	7, 14	XGB	0,9790	1,1389	1,8991	13,3091	11,70
Etkin Değil	7, 28	XGB	0,9789	1,1874	1,9014	13,4274	17,95
Etkin Değil	16, 32	XGB	0,9782	1,2099	1,9337	13,7980	20,25
Etkin	None	RF	0,9773	1,3349	1,9769	17,0404	21,33
Etkin Değil	16, 64	RF	0,9763	1,3688	2,0193	16,9637	29,30
Etkin	7, 28	XGB	0,9755	1,2361	2,0507	13,6879	14,68
Etkin Değil	7, 14	GBM	0,9754	1,2268	2,0536	13,4143	15,90
Etkin	16, 64	RF	0,9751	1,3932	2,0703	17,1155	29,52
Etkin	16, 32	XGB	0,9744	1,2860	2,0990	14,4007	16,45
Etkin Değil	7, 14	HGBR	0,9733	1,2784	2,1377	13,7791	15,10
Etkin Değil	None	XGB	0,9714	1,4475	2,2171	16,9054	17,20
Etkin Değil	7, 28	GBM	0,9712	1,3087	2,2231	13,9853	19,58
Etkin Değil	16, 32	GBM	0,9695	1,3637	2,2858	14,8823	22,55
Etkin Değil	16, 32	HGBR	0,9694	1,3783	2,2939	14,8172	20,38
Etkin Değil	7, 28	HGBR	0,9693	1,3622	2,2976	14,4735	16,87
Etkin	7, 14	GBM	0,9690	1,3289	2,3090	14,1481	12,45
Etkin	7, 14	HGBR	0,9685	1,3263	2,3256	14,0131	10,67

Tablo 4.3. Devamı

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	16, 64	XGB	0,9679	1,4615	2,3443	16,5935	27,80
Etkin	None	XGB	0,9637	1,5628	2,4982	17,6496	14,87
Etkin Değil	16, 64	GBM	0,9631	1,5070	2,5126	16,4944	30,35
Etkin	7, 28	GBM	0,9617	1,4590	2,5620	15,1960	15,87
Etkin	16, 64	XGB	0,9617	1,5466	2,5652	17,0916	24,00
Etkin Değil	None	GBM	0,9616	1,6000	2,5686	17,7007	15,80
Etkin	16, 32	HGBR	0,9603	1,5035	2,6065	15,7188	15,72
Etkin	7, 28	HGBR	0,9585	1,5060	2,6688	15,3496	13,95
Etkin	16, 32	GBM	0,9576	1,5336	2,6965	15,9795	17,47
Etkin Değil	None	HGBR	0,9571	1,6716	2,7117	18,2212	13,83
Etkin Değil	16, 64	HGBR	0,9541	1,6562	2,8007	17,7346	27,68
Etkin	16, 64	GBM	0,9493	1,7167	2,9472	18,0598	24,93
Etkin	None	HGBR	0,9491	1,7728	2,9575	18,9327	13,23
Etkin	None	GBM	0,9466	1,7896	3,0282	19,0009	16,43
Etkin	16, 64	HGBR	0,9440	1,7797	3,1015	18,6375	22,43
Etkin Değil	16, 64	None	0,9263	1,9256	3,4619	15,4474	24,23
Etkin Değil	7, 28	None	0,9219	1,9223	3,5152	13,7514	15,42
Etkin Değil	16, 32	None	0,9121	2,1089	3,7553	15,6902	17,90
Etkin Değil	7, 14	None	0,9084	2,1827	3,8851	15,1251	13,35
Etkin	7, 28	None	0,8723	2,5205	4,6508	16,8256	14,17
Etkin	7, 14	None	0,8718	2,5565	4,6122	17,0894	10,82
Etkin	16, 32	None	0,8655	2,6465	4,7060	18,4909	15,17
Etkin	16, 64	None	0,8604	2,6837	4,8459	18,3339	21,68
Etkin	None	None	0,8543	2,6191	4,7203	19,0308	15,00
Etkin Değil	None	None	0,8007	3,0479	5,4754	21,0663	10,63

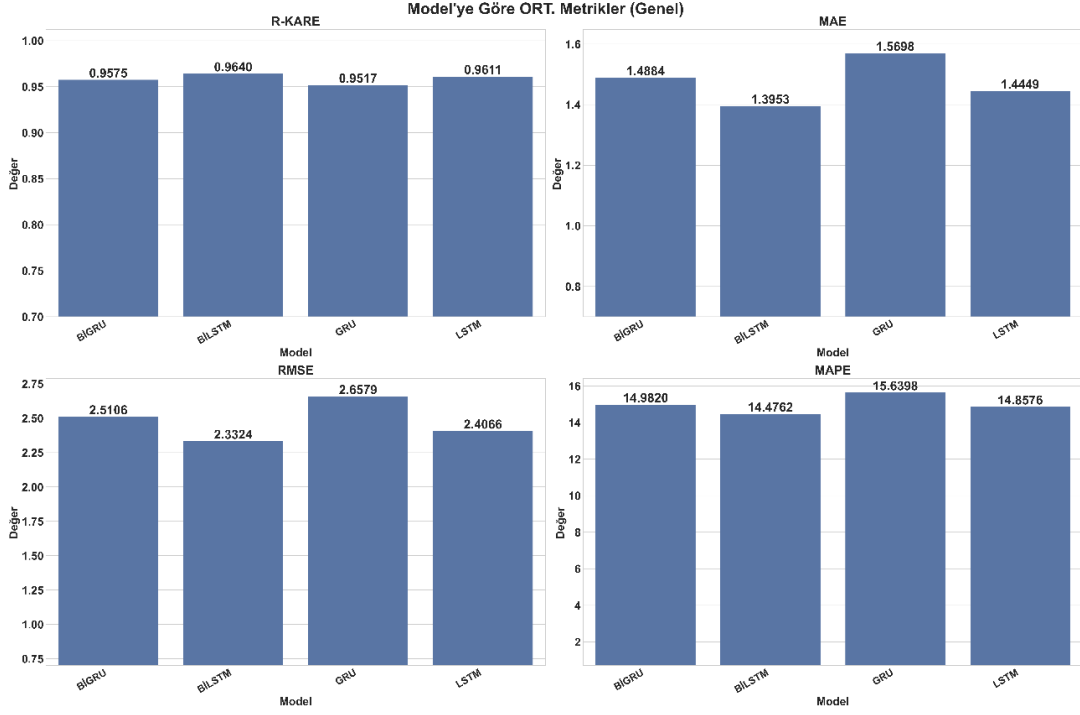
Tablo 4.4. BiGRU tabanlı modellerin sonuçları (10 çalıştırmanın ortalaması)

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	7, 14	RF	0,9910	0,7599	1,2423	10,4166	27,43
Etkin	7, 14	RF	0,9904	0,7753	1,2857	10,4847	27,97
Etkin	7, 28	RF	0,9859	0,9815	1,5538	12,3684	31,70
Etkin Değil	7, 28	RF	0,9859	0,9821	1,5596	12,3203	34,07
Etkin Değil	16, 32	RF	0,9852	1,0368	1,5981	13,1920	36,12
Etkin	16, 32	RF	0,9842	1,0589	1,6511	13,3780	49,93
Etkin Değil	7, 14	XGB	0,9820	1,0788	1,7561	12,7429	23,72
Etkin Değil	None	RF	0,9818	1,2177	1,7695	15,8745	41,62
Etkin	7, 14	XGB	0,9808	1,0872	1,8179	12,7523	17,23
Etkin Değil	16, 32	XGB	0,9801	1,1671	1,8511	13,3194	33,38
Etkin	None	RF	0,9794	1,2802	1,8833	16,4149	31,35
Etkin Değil	7, 28	XGB	0,9787	1,1938	1,9121	13,4547	30,88
Etkin Değil	None	XGB	0,9778	1,2694	1,9518	15,0646	33,85
Etkin	16, 32	XGB	0,9763	1,2164	2,0180	13,6869	28,30
Etkin Değil	16, 64	RF	0,9763	1,3648	2,0190	16,7788	50,37
Etkin Değil	7, 14	GBM	0,9753	1,2122	2,0594	13,1370	25,28
Etkin	16, 64	RF	0,9752	1,3850	2,0646	16,9887	50,62
Etkin	7, 28	XGB	0,9742	1,2679	2,1024	14,0922	24,13
Etkin Değil	16, 32	GBM	0,9739	1,2593	2,1165	13,7511	35,03
Etkin Değil	None	GBM	0,9729	1,3512	2,1544	15,2961	27,02
Etkin Değil	7, 14	HGBR	0,9723	1,2872	2,1810	13,8256	23,18
Etkin	None	XGB	0,9712	1,4169	2,2236	16,2233	25,72
Etkin Değil	16, 64	XGB	0,9711	1,3766	2,2254	15,4562	49,70
Etkin	7, 14	GBM	0,9709	1,2871	2,2343	13,6623	18,47
Etkin Değil	16, 32	HGBR	0,9707	1,3288	2,2425	14,3109	33,25

Tablo 4.4. Devamı

Mevsimsel Momentum Katmanı	Çoklu Yama Boyutu	Topluluk (Ensemble) Alg.	R ²	nMAE (%)	nRMSE (%)	MAPE	Zaman (Dk)
Etkin Değil	None	HGBR	0,9705	1,4058	2,2478	15,7047	25,75
Etkin	7, 14	HGBR	0,9688	1,3146	2,3150	13,7957	16,65
Etkin Değil	7, 28	GBM	0,9685	1,3504	2,3173	14,1757	32,28
Etkin Değil	7, 28	HGBR	0,9666	1,4030	2,3914	14,6787	30,12
Etkin	16, 64	XGB	0,9637	1,5141	2,4900	16,8141	41,98
Etkin Değil	16, 64	GBM	0,9627	1,4737	2,5225	15,7146	53,48
Etkin	16, 32	HGBR	0,9626	1,4359	2,5332	14,9235	27,77
Etkin	7, 28	GBM	0,9615	1,4525	2,5689	14,9297	25,62
Etkin	16, 32	GBM	0,9594	1,4832	2,6375	15,2886	29,80
Etkin	7, 28	HGBR	0,9589	1,5197	2,6557	15,4965	23,57
Etkin Değil	16, 64	HGBR	0,9566	1,5938	2,7260	17,1748	51,02
Etkin	None	GBM	0,9565	1,6201	2,7332	17,4092	26,27
Etkin	None	HGBR	0,9547	1,6458	2,7887	17,4501	22,42
Etkin Değil	16, 32	None	0,9500	1,5565	2,7559	12,9008	31,13
Etkin	16, 64	GBM	0,9490	1,6671	2,9479	17,3675	44,77
Etkin	16, 64	HGBR	0,9461	1,7317	3,0448	18,0224	42,88
Etkin Değil	7, 28	None	0,9443	1,7389	2,9451	13,4015	26,08
Etkin Değil	7, 14	None	0,9369	1,7708	3,1966	12,7699	20,37
Etkin Değil	16, 64	None	0,9293	1,8365	3,4144	13,9044	42,70
Etkin	7, 14	None	0,9119	2,0910	3,8485	14,2307	17,12
Etkin	None	None	0,8855	2,4089	4,1504	18,7872	27,03
Etkin	16, 32	None	0,8756	2,5468	4,4809	17,5874	27,77
Etkin	16, 64	None	0,8675	2,5026	4,6932	16,9684	42,60
Etkin	7, 28	None	0,8609	2,8251	4,7917	19,2136	23,30
Etkin Değil	None	None	0,8432	2,8874	4,8601	21,3977	19,12

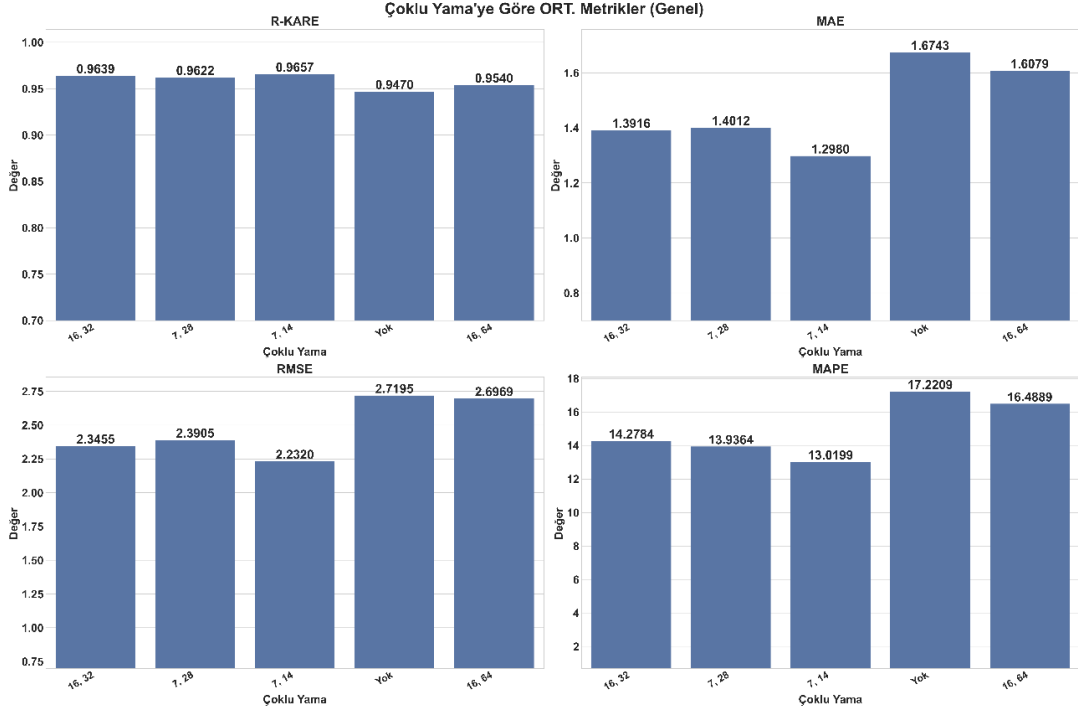
200 model konfigürasyonu arasından tüm model aileleri ve topluluk seçenekleri için ortalama R², nMAE, nRMSE ve MAPE değerlerinin genel karşılaştırması Şekil 4.3'te özetlenmektedir.



Şekil 4.3. Modellerin ortalama performans metrikleri (R^2 , nMAE, nRMSE, MAPE) genel karşılaştırması

Şekil 4.3'te, dört temel tekrarlayan model türüne (LSTM, BiLSTM, GRU, BiGRU) göre ortalama R^2 , nMAE, nRMSE ve MAPE değerleri karşılaştırılmaktadır. Ortalama sonuçlarda BiLSTM ailesi bazı metriklerde sınırlı bir üstünlük gösterirken, LSTM ailesi de çok yakın değerlerle onu izlemektedir. En iyi tekil konfigürasyonun LSTM tabanlı yapıdan geldiği dikkate alındığında, iki mimari arasındaki farkın sınırlı olduğu görülmektedir. GRU ve BiGRU ise biraz daha yüksek hata ve daha düşük R^2 ile sonuçlanmaktadır. Topluluk (ensemble) algoritması ve çoklu yama konfigürasyonlarının etkisi sırasıyla Şekil 4.8 ve Şekil 4.4'te ayrıca gösterilmektedir.

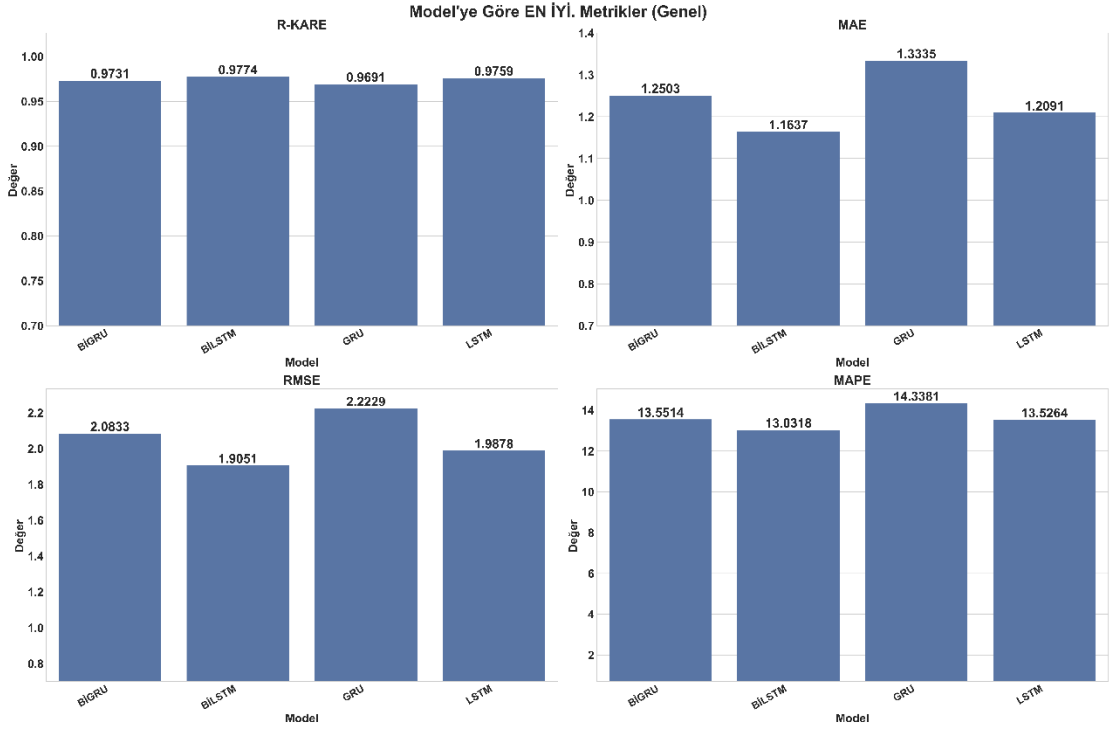
Farklı yama yapılandırmalarının (Yok, 7-14, 7-28, 16-32, 16-64) ortalama R^2 , nMAE, nRMSE ve MAPE üzerindeki etkisi Şekil 4.4'te gösterilmektedir.



Şekil 4.4. Çoklu yama konfigürasyonlarına göre ortalama performans metrikleri

Şekil 4.4'te, (7, 14) yama kombinasyonunun tüm model ailelerinde en yüksek R^2 ve en düşük hata değerlerine karşılık geldiği görülmektedir. Yama kullanılmayan ("Yok") konfigürasyonlar ile (16, 64) gibi büyük pencere yapıları ise daha düşük doğruluk ve daha yüksek hata ile sonuçlanmaktadır. Bu görsel, çoklu yama mekanizmasının mobilya satış verisinde katkı sağlayabildiğini ve (7, 14) seçiminin bu veri seti altında duyarlılık ile genelleme arasında uygun bir denge sunduğunu göstermektedir.

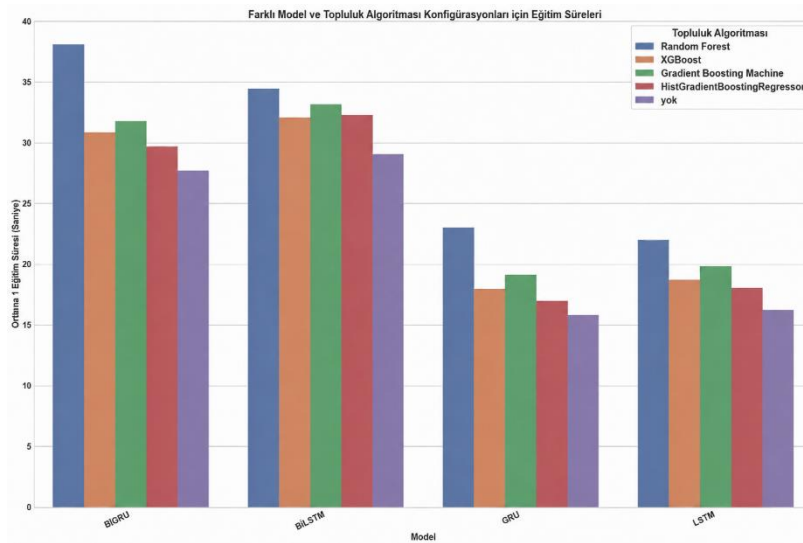
En iyi performans gösteren konfigürasyonların R^2 , nMAE, nRMSE ve MAPE açısından karşılaştırması Şekil 4.5'te sunulmaktadır.



Şekil 4.5. En iyi performans gösteren konfigürasyonların metrik karşılaştırması

Şekil 4.5'te, en iyi performans gösteren konfigürasyonların metrik karşılaştırması yer almaktadır. Hangi konfigürasyonun hangi çubuğa karşılık geldiği ve sayısal değerler Tablolar 4.1-4.4'te verilmektedir; bu tablolara göre LSTM ve BiLSTM tabanlı, (7, 14) yama ve RF kullanan yapılar en yüksek R^2 ve en düşük hata değerleriyle öne çıkmaktadır.

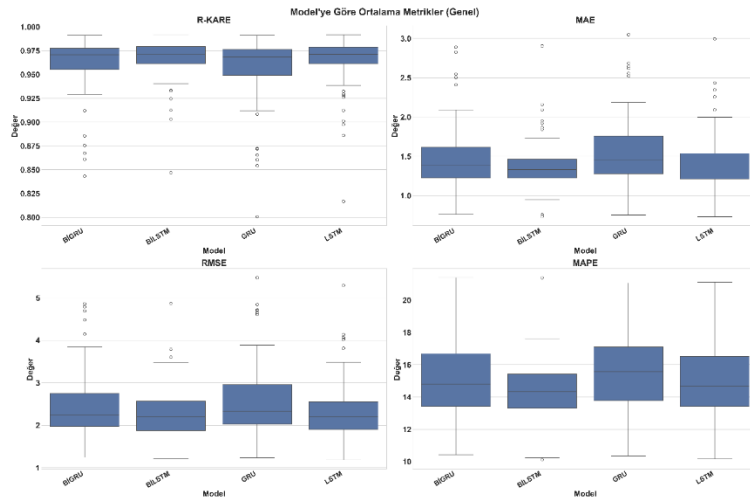
Farklı yama ve topluluk (ensemble) kombinasyonları için ortalama eğitim süreleri (dakika) Şekil 4.6'da gösterilmektedir.



Şekil 4.6. Tekrarlayan sinir ağı ve topluluk öğrenme bileşenlerine göre ortalama eğitim süreleri (dakika)

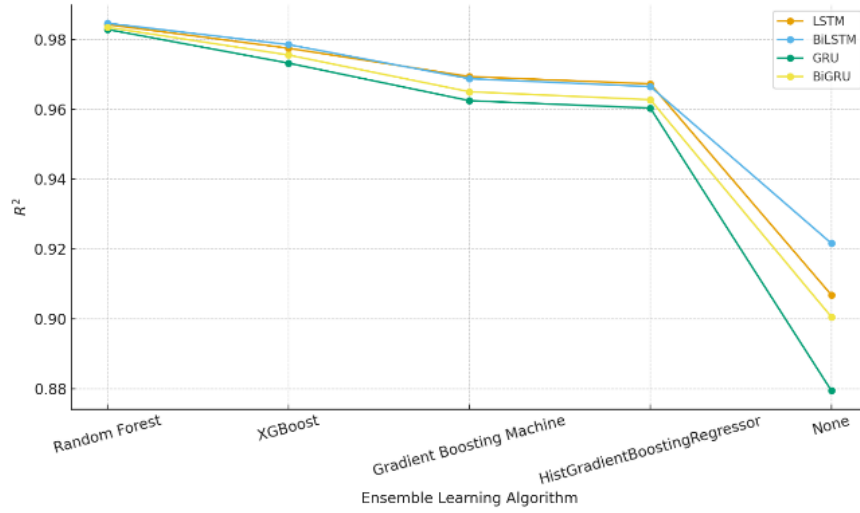
Şekil 4.6’da, tekrarlayan sinir ağı türü ile topluluk öğrenme bileşenlerinin birlikte oluşturduğu konfigürasyonlara göre ortalama eğitim süreleri görülmektedir. Çift yönlü yapılar (BiLSTM, BiGRU) genel olarak tek yönlü LSTM ve GRU’ya kıyasla daha uzun eğitim süresi gerektirmektedir. Ancak bu süreler, yalnızca aynı dizüstü bilgisayar ve aynı yazılım ortamı altında elde edildiği için görece karşılaştırma olarak yorumlanmalıdır. Doğruluk ile süre dengesine ilişkin sayısal detaylar Tablolar 4.1-4.4 ve Şekil 4.5 ile birlikte değerlendirilebilir.

Konfigürasyonların R^2 , nMAE, nRMSE ve MAPE açısından dağılımı (medyan, çeyrekler arası aralık, aykırı değerler) Şekil 4.7’de kutu grafikleriyle sunulmaktadır.



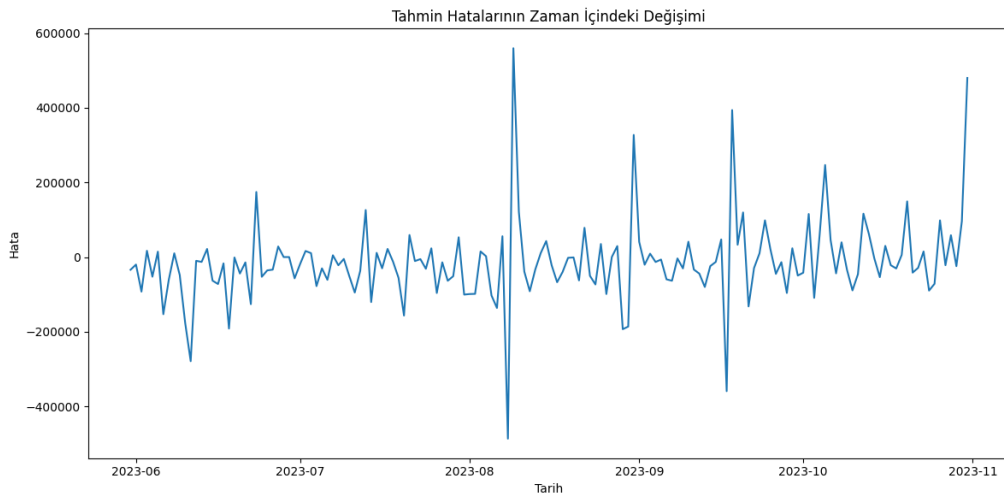
Şekil 4.7. Modellerin ortalama metriklerinin kutu grafiği (medyan, çeyrekler arası aralık, aykırı değerler)

Şekil 4.7’de, dört temel model türüne (LSTM, BiLSTM, GRU, BiGRU) göre metrik dağılımları (medyan, çeyrekler arası aralık, aykırı değerler) kutu grafikleriyle sunulmaktadır. Ortalama değerlerin yanı sıra IQR ve aykırı değerler de görülebilir; dağılımı daha dar olan model türleri on tekrar boyunca daha kararlı performans göstermiştir. Topluluk ve yama ayırımına göre dağılımlar Şekil 4.4 ve 4.8 ile birlikte incelenebilir.



Şekil 4.8. Topluluk (Ensemble) algoritmalarının R^2 skoru üzerindeki etkisi

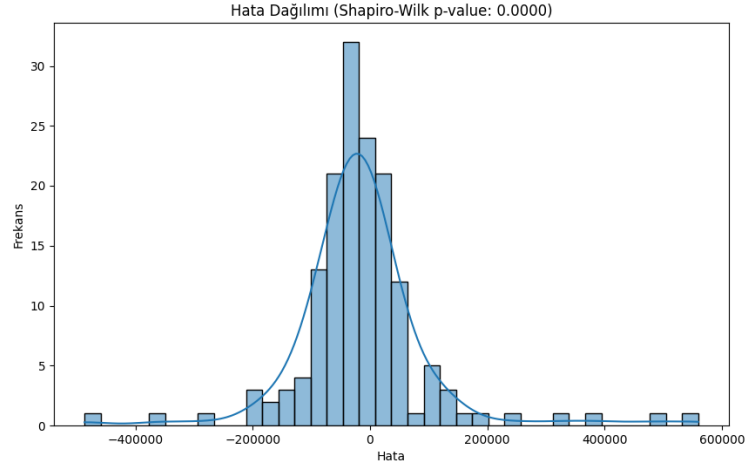
Test döneminde tahmin hatasının (gerçek – tahmin) zaman içindeki değişimi Şekil 4.9’da gösterilmektedir.



Şekil 4.9. Test döneminde tahmin hatasının (gerçek - tahmin) zaman içindeki değişimi

Şekil 4.9’da, MP-LRNet modelinin test kümesi boyunca ürettiği tahmin hatalarının (gerçek değer eksi tahmin) zaman eksenindeki seyri görülmektedir. Hataların belirli bir dönemde sürekli olarak büyümediği, genel olarak dar bir bant içinde kaldığı ve belirgin bir trend sergilemediği görülmektedir. Bu durum, modelin sistematik bir zaman bazlı sapma üretmediğini ve farklı zaman dilimlerinde benzer doğruluk seviyesini koruduğunu göstermektedir.

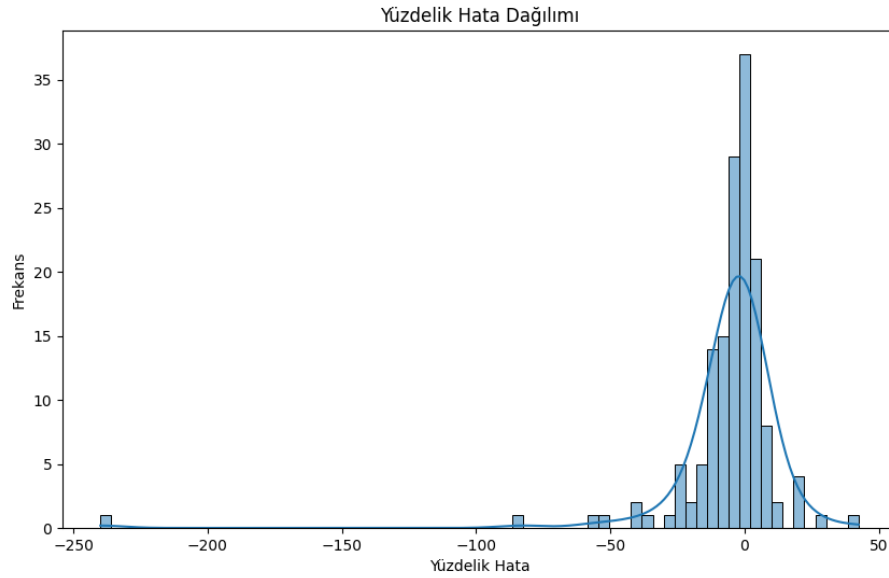
MP-LRNet test hatalarının dağılımı (histogram ve normallik) Şekil 4.10’da sunulmaktadır.



Şekil 4.10. MP-LRNet test hatalarının dağılımı (histogram ve normallik)

Şekil 4.10’da, MP-LRNet’in test kümesi üzerindeki tahmin hatalarının histogramı görülmektedir. Hata dağılımı büyük ölçüde sıfır etrafında yoğunlaşmakta ve yaklaşık simetrik bir görünüm sergilemektedir. Aşırı pozitif ve negatif hataların sayısı sınırlı olup, bu durum modelin sistematik bir yanlılık (bias) üretmediğini ve hem yüksek hem de düşük satış dönemlerinde benzer doğruluk seviyelerine ulaştığını göstermektedir.

İşaretili yüzdeler hata dağılımı Şekil 4.11’de gösterilmektedir.




Şekil 4.11. İşaretili yüzdeler hata dağılımı

Şekil 4.11’de, test gözlemleri için hesaplanan işaretili yüzdeler hata değerlerinin

dağılımı görülmektedir. Bu hata ölçütü, $(\text{gerçek} - \text{tahmin}) / \text{gerçek} \times 100$ biçiminde tanımlandığı için negatif değerler modelin ilgili gözlemlerde yüksek tahmin ürettiğini, pozitif değerler ise düşük tahmin ürettiğini göstermektedir. Dağılımın sıfır çevresinde ve özellikle negatif bölgede yoğunlaşması, test döneminde sınırlı bir aşırı tahmin eğiliminin bulunduğu; ancak sapmaların büyük bölümünün belirli bir bant içinde kaldığına işaret etmektedir. Bu nedenle şekil MAPE dağılımı olarak değil, işaretli yüzdelik hata dağılımı olarak yorumlanmalıdır; MAPE değeri ayrı olarak mutlak yüzdelik hataların ortalaması biçiminde raporlanmaktadır.

Tahmin artıklarının (residual'ların) teorik normal dağılımla karşılaştırıldığı QQ grafiği Şekil 4.12'de sunulmaktadır.



Şekil 4.12. Artık değerlerin normal dağılımla karşılaştırması (QQ grafiği)

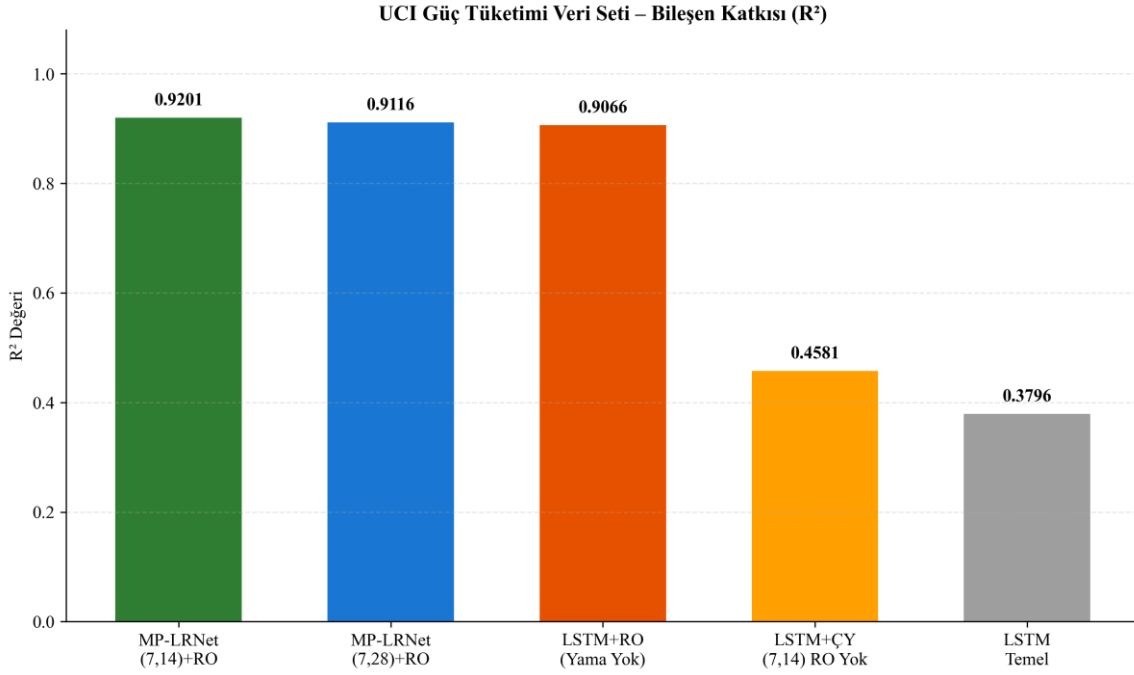
QQ grafiđi incelendiđinde, artıkların orta blgede teorik normal dađılım izgisini byk lde takip ettiđi; buna karřılık kuyruklarda belirgin sapmalar oluřtuđu grlmektedir. Bu durum, modelin ođu gn iin hataları dengeli biimde rettiđini; ancak kampanya, ani talep sıraması veya sıra dıřı satıř gnlerinde daha byk artıkların ortaya ıkabildiđini dřndrmektedir. Dolayısıyla artıklar tam anlamıyla normal dađılmasa da, modelin hata yapısı mobilya satıř verisinin u gzlemler ieren dođasıyla uyumlu grnmektedir.

4.6. Halka Aık Veri Seti zerindeki Sonular

nerilen MP-LRNet modelinin farklı bir alan zerindeki performansını deđerlendirmek amacıyla UCI Household Electric Power Consumption veri setinde beř model konfigrasyonu test edilmiřtir. Her konfigrasyon on bađımsız alıřma ile deđerlendirilmiř ve ortalama sonular raporlanmıřtır.

UCI veri seti zerinde MP-LRNet 0,9201 R^2 , 0,0628 MAE, 0,0872 RMSE ve %6,95 MAPE deđerleri ile en yksek performansı sergilemiřtir. LSTM+RF konfigrasyonu 0,9066 R^2 ile ikinci sırada yer alırken, yalnızca LSTM modeli 0,3796 R^2 ile en dřk performansı gstermiřtir. LSTM+MP konfigrasyonu ise 0,4581 R^2 ile oklu yama mekanizmasının tek bařına topluluk đrenme olmadan sınırlı katkı sađladıđını ortaya koymuřtur. MP-LRNet'in (7,28) konfigrasyonu da 0,9116 R^2 ile yakın performans sergilemiřtir; bu sonu, yama boyutu seiminin alandan bađımsız robustluk gsterdiđini teyit etmektedir.

Bu sonular, mobilya satıř verisinde gzlemlenen performans sıralamasının farklı bir alandan gelen halka aık veri setinde de korunduđunu gstermektedir. oklu yama mekanizmasının R^2 deđerine katkısı mobilya verisinde +0,0115, UCI verisinde ise +0,0135 olarak llmř; bu tutarlılık mimari tasarının alandan bađımsız bir fayda sađladıđına iřaret etmektedir.

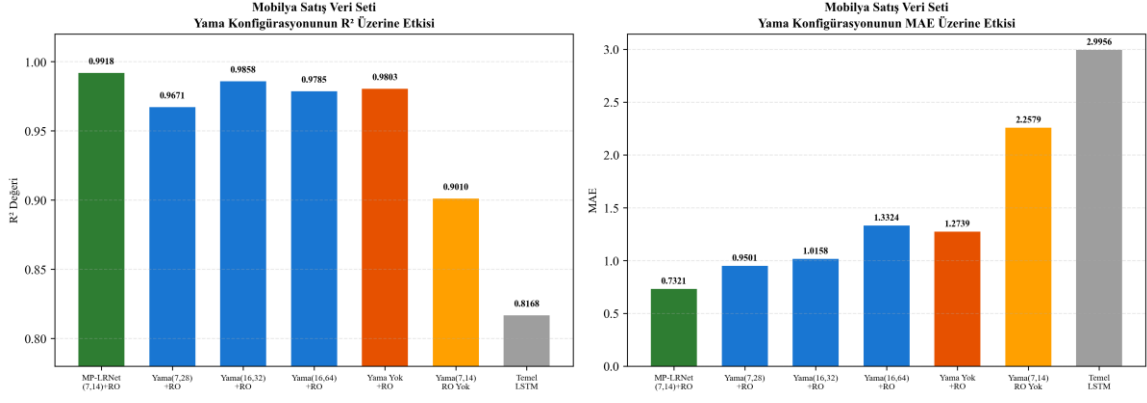


Şekil 4.13. UCI güç tüketimi veri setinde model bileşenlerinin R² katkısı

4.7. Bileşen Katkı Analizi ve Ablasyon Çalışması


MP-LRNet mimarisindeki her bir bileşenin tahmin performansına olan bireysel katkısını ölçmek amacıyla sistematik bir ablasyon çalışması gerçekleştirilmiştir. Temel LSTM modelinden başlayarak bileşenler kademeli olarak eklenmiş ve her aşamadaki performans değişimi kaydedilmiştir.

Ablasyon sonuçlarına göre, yalnızca LSTM kullanıldığında R² değeri 0,8168 olarak ölçülmüştür. Çoklu yama mekanizmasının eklenmesiyle bu değer 0,9010'a yükselmiş (+0,0842 artış); bu durum çoklu ölçekli zamansal temsillerin tahmin doğruluğuna önemli bir katkı sağladığını göstermektedir. İkinci aşamada Rastgele Orman topluluk regresörünün entegre edilmesi R² değerini 0,9803'e çıkarmış (+0,0793 artış) ve topluluk öğrenmenin derin öğrenme çıktılarına iyileştirmedeki kritik rolünü ortaya koymuştur. Son olarak, tam entegre MP-LRNet modeli 0,9918 R² değerine ulaşmış (+0,0115 artış); bu nihai iyileşme tüm bileşenlerin birlikte çalışmasından kaynaklanan sinerjik etkiyi yansıtmaktadır. Bileşen katkıları Şekil 4.13'te, farklı yama konfigürasyonlarının doğruluk ve hata üzerindeki etkisi Şekil 4.14'te ve çoklu yama bileşenlerinin özellik önemi katkıları Şekil 4.15'te görselleştirilmektedir.



Şekil 4.14. Farklı yama konfigürasyonlarının R² ve MAE üzerindeki etkisi

Çoklu yama mekanizmasının zamansal katkısı incelendiğinde, Rastgele Orman'ın özellik önemi analizi 7 günlük yamanın model kararlarına %54,4, 14 günlük yamanın ise %45,6 oranında katkı sağladığını ortaya koymuştur. Bu denge, kısa vadeli haftalık dinamikler ile orta vadeli iki haftalık eğilimlerin birlikte değerlendirilmesinin tahmin performansını optimize ettiğini göstermektedir.



Şekil 4.15. Çoklu yama bileşenlerinin özellik önemi katkı oranları

4.8. İstatistiksel Anlamlılık ve Hesaplama Verimliliği

MP-LRNet'in temel LSTM modeline kıyasla istatistiksel olarak anlamlı bir iyileşme sağlayıp sağlamadığını doğrulamak amacıyla parametrik olmayan Wilcoxon İşaretli Sıralar

testi uygulanmıştır. On bağımsız çalışmadan elde edilen R^2 değerleri karşılaştırıldığında $p=0,00195$ ($p<0,01$) sonucu elde edilmiş; bu değer MP-LRNet'in üstünlüğünün istatistiksel olarak anlamlı olduğunu doğrulamaktadır. MP-LRNet'in R^2 değerleri 0,9907 ile 0,9927 arasında dar bir aralıkta kümelenmiş olup on tekrar boyunca yalnızca 0,0020'lik dar bir aralık gözlemlenmiştir.

Hesaplama verimliliği açısından, MP-LRNet modelinin ortalama eğitim süresi 16,87 dakika olarak ölçülmüştür. Tek yamalı konfigürasyonlar 17-27 dakika arasında eğitim süresi gerektirirken, çoklu yama mekanizmasının ek hesaplama yükü ihmal edilebilir düzeyde kalmıştır. Tüm deneyler 11. nesil Intel Core i7 işlemci ve 16 GB RAM donanımında GPU hızlandırması olmaksızın gerçekleştirilmiştir; bu durum modelin standart donanım üzerinde pratik olarak uygulanabilir olduğunu göstermektedir.

5. TARTIŞMA

Deneyisel analizler, önerilen MP-LRNet modelinin bu veri seti ve deney protokolü altında yüksek tahmin doğruluğu ürettiğini göstermektedir. Önerilen model on bağımsız çalışmada ortalama 0,9918 R^2 üretmiş, en iyi yinelemede 0,9927 R^2 değerine ulaşmıştır. Ancak veri setinin tek kuruma ait olması, sıfır satış günlerinin seriye dahil edilmesi ve dış baz modellerin bu tez kapsamında değerlendirilmemiş olması nedeniyle, sonuçların alan geneline doğrudan üstünlük iddiası olarak yorumlanmaması gerekir. Bu nedenle Tablo 5.1, Tablo 2.1’de özetlenen geniş literatürün tekrarı olarak değil; sayısal metrikleri açık biçimde raporlanan 2024 sonrası seçili çalışmalarla yapılan bağlamsal bir karşılaştırma olarak okunmalıdır. Veri setleri ve uygulama alanlarındaki farklılıklar nedeniyle doğrudan üstünlük karşılaştırması mümkün değildir; buna karşın MP-LRNet’in ürettiği sonuçlar bu tezde kullanılan veri seti ve deney protokolü altında umut verici görünmektedir.

Tablo 5.1. Son dönem hibrit ve derin öğrenme tabanlı zaman serisi tahmin çalışmalarının karşılaştırılması

Yazar(lar)	Yıl	Kullanılan Veri Seti	Model/Teknik	Başarı Ölçütleri ve Değerleri
(Sherly vd., 2025)	2025	Edge computing uygulamaları için simüle edilmiş ve gerçek dünya veri setleri	ARIMA ve Prophet hibrit modeli	RMSE ve MAE değerlerinde iyileşme.
(Mahmoud & Mohammed, 2024)	2024	Traffic Volume ve Air Quality veri setleri	TCN-BiLSTM hibrit modeli	Traffic Volume için $R^2 = 0.976$, Air Quality için $R^2 = 0.94$.
(Xu vd., 2025)	2025	9 farklı gerçek dünya veri seti	Multi-scale Patch Mixer (MPMixer)	9 zorlu gerçek dünya veri setinde son teknoloji performans.
(Balusani vd., 2025)	2025	Kaggle perakende veri seti (hava durumu ve ürün bilgileriyle zenginleştirilmiş)	XGBoost, hibrit CNN-LSTM-XGBoost	XGBoost için $R^2 = 0.953$, hibrit CNN-LSTM-XGBoost için $R^2 = 0.945$.
Alsalem (Alsalem, 2025)	2025	Tetouan, Fas'taki güç tüketimi verileri (52,417 kayıt)	Bulanık kümeleme ile makine öğrenimi tabanlı zaman serisi tahmin modelleri (RF, SVM, KNN, XGBoost, MLP)	MLP için RMSE = 355.42, MAE = 246.43, $R^2 = 0.9889$.

Tablo 5.1’de yer verilen güncel çalışmalar, MP-LRNet yaklaşımını alanlar arası literatür içinde yöntemsel olarak konumlandırmak amacıyla sunulmaktadır. (Sherly vd., 2025), hibrit ARIMA-Prophet modellerinin çeşitli trafik veri setlerinde %5,2 MAPE ve %8

daha düşük RMSE elde ettiğini bildirmiştir. (Xu vd., 2025), Multi-scale Patch Mixer modellerini 36 bağımsız deneyde değerlendirmiş ve çoğunda en iyi MSE ve MAE sonuçlarını elde etmiştir. Benzer şekilde, (Mahmoud & Mohammed, 2024), trafik hacmi tahmini için 0,976 ve hava kalitesi tahmini için 0,94 R² elde etmiş; (Guo vd., 2025) güç yükü tahmininde CNN-LSTM tabanlı hibrit modellerle, (Wen vd., 2024) kısa vadeli yük tahmininde derin öğrenme tabanlı hibrit modellerle yüksek doğruluk bildirmiş; (Alsalem, 2025) ise enerji tüketimi tahmini için 0,9889 R² rapor etmiştir. Bu çalışmalar farklı veri setleri ve uygulama alanlarına ait olduğundan, burada yapılan değerlendirme doğrudan üstünlük karşılaştırması değil, bağlamsal bir yöntem konumlandırması olarak yorumlanmalıdır. Bu çerçevede MP-LRNet'in 0,9918 R² değeri, bu tezde kullanılan veri seti ve deney protokolü altında güçlü bir sonuç olarak değerlendirilebilir.

Perakende talep ve satış tahmini bağlamında, CNN-LSTM-XGBoost hibrit yapısının Kaggle perakende veri setinde R² = 0,945 (Balusani vd., 2025) ile raporlandığı; LSTM ve RF'ı birleştiren hibrit modellerin ise hem sınıflandırma hem de regresyon görevlerinde tek bileşenli modellere göre belirgin iyileşme sağladığı literatürde vurgulanmaktadır (Abumohsen vd., 2024; Djballah vd., 2024). MP-LRNet, LSTM + RF + çoklu yama kombinasyonu ile satış tahmini odaklı bu çalışmalarla kavramsal bir yakınlık taşımakta; mobilya sektörüne özel gerçek veri seti ve 200 konfigürasyonlu iç karşılaştırma ile uygulama odaklı bir katkı sunmaktadır. Mobilya sektörüne özgü hibrit zaman serisi tahmin çalışmalarının sınırlı olması, kampanya dönemleri, konut piyasasıyla ilişkili talep dalgalanmaları ve dayanıklı tüketim davranışları gibi sektör dinamiklerinin ayrıca tartışılmasını gerekli kılmaktadır.

5.1. Modelin Güçlü Yönleri, Sınırlılıkları ve Uygulama Anlamı

DeneySEL sonuçlar, MP-LRNet'in gerçek dünya tahmin görevlerine uygulanabilirliğini desteklemektedir. Modüler yapısı, tekrarlayan ve topluluk (ensemble) bileşenlerin esnek biçimde bir araya getirilebildiğini göstermektedir. Bununla birlikte, sonuçlar bütün bileşenlerin aynı ölçüde katkı sağlamadığını da ortaya koymuştur: Mevsimsel Momentum Katmanı bu veri setinde belirgin bir iyileşme üretmemiş, buna karşılık çoklu yama yapısı ile LSTM + RF birleşimi daha olumlu sonuçlar vermiştir. Özellikle önerilen LSTM + RF + (7,14) yapılandırması, bu veri seti ve deney protokolü altında doğruluk ile eğitim süresi arasında dengeli bir sonuç sunmuştur. Bu nedenle MP-LRNet, doğrudan genellenmiş bir üstünlük iddiasından çok, belirli bir veri seti ve deney protokolü altında uygulanabilir bir hibrit tahmin çerçevesi olarak değerlendirilmelidir.

Uygulama perspektifi: Bu çalışmada kullanılan veri setinin kaynağı olan mobilya perakendecisi açısından, MP-LRNet'in sağladığı yüksek R^2 ve düşük MAPE değerleri, günlük veya haftalık satış tahminlerinin stok planlaması, sipariş yönetimi ve kapasite kullanımı kararlarını potansiyel olarak destekleyebileceğini düşündürmektedir (Theodorou vd., 2025). Modelin (7, 14) yama yapısı ile haftalık ve iki haftalık dinamikleri birlikte yakalaması, kısa vadeli talep dalgalanmalarına ve orta vadeli mevsimsel etkilere duyarlı tahminler üretmesine olanak tanımaktadır. Özellikle önerilen yapılandırmada gözlenen eğitim süreleri, mevcut işletme altyapısıyla periyodik model güncellemelerinin uygulanabilir olabileceğine işaret etmektedir. Bununla birlikte, model tek bir firma ve tek bir ürün/hacim serisi üzerinde değerlendirildiği için, farklı mobilya kanallarına veya bölgelere genelleme performansı ileride çoklu seri veya çoklu mağaza verisi ile test edilmelidir.

Öte yandan, sonuçların tek bir kuruma ait günlük net satış tutarı serisi üzerinde elde edilmiş olması dış geçerlik açısından önemli bir sınırlılıktır. Mobilya sektörüne özgü kampanya takvimi, teslimat ve üretim planları ile konut ve yenileme talebine bağlı dönemsel hareketler model performansını etkilemiş olabilir. Farklı mağaza yapıları, ürün grupları ve mevsimsellik desenleri içeren veri setlerinde benzer performansın korunup korunmadığı ayrıca doğrulanmalıdır.

Yüksek R^2 değerinin (0,9918) aşırı uyum riski taşıyıp taşımadığı da ayrıca değerlendirilmiştir. Modelde uygulanan çok katmanlı düzenleme stratejisi bu riski kontrol altında tutmaktadır: LSTM katmanlarında %20 dropout ve %20 tekrarlayan dropout uygulanmakta, Rastgele Orman topluluk regresörü bootstrap örnekleme yoluyla doğal bir aşırı uyum direnci sağlamak ve eğitim 20 epoch ile sınırlandırılarak kayıp fonksiyonunun yakınsaması izlenmektedir. Ayrıca kronolojik %80-%20 veri bölme stratejisi, gelecek verilerin eğitim sürecine sızmasını engellemektedir. On bağımsız çalışmada gözlemlenen 0,0020'lik dar R^2 aralığı, modelin farklı rastgele başlatmalar altında kararlı performans sergilediğini ve aşırı uyum belirtisi göstermediğini doğrulamaktadır.

UCI Household Electric Power Consumption veri seti üzerindeki çapraz alan doğrulaması, önerilen mimarinin genellenebilirliği açısından önemli kanıtlar sunmaktadır. Mobilya satış verisinde gözlemlenen model performans sıralaması (MP-LRNet > LSTM+RF > LSTM+MP > LSTM) enerji tüketimi verisinde de birebir korunmuştur. Çoklu yama mekanizmasının katkısı her iki veri setinde de tutarlı biçimde ölçülmüş olup (mobilya: +0,0115, UCI: +0,0135 R^2 artışı) bu tutarlılık mimari tasarımın belirli bir veri setine özgü

olmadığını, haftalık periyodiklik içeren farklı zaman serilerinde sistematik bir fayda sağladığını göstermektedir. Bu çapraz alan tutarlılığı, MP-LRNet'in haftalık periyodik yapı içeren farklı zaman serisi problemlerine uyarlanma potansiyeli taşıdığına dair sınırlı ama anlamlı bir işaret sunmaktadır.

6. SONUÇLAR VE ÖNERİLER

Mobilya satışlarında doğru zaman serisi tahmini, veri temelli stok, sipariş ve kapasite kararlarını desteklemek açısından önemlidir. Bu çalışmada, günlük net satış tutarının tahmin doğruluğunu ve kararlılığını artırmak amacıyla yeni bir hibrit derin öğrenme modeli olan MP-LRNet önerilmiştir. Model, kısa ve orta vadeli zamansal bağımlılıkları yakalamak üzere tasarlanmış modüler çoklu yama mimarisi içinde tekrarlayan sinir ağlarını topluluk (ensemble) öğrenme algoritmalarıyla birleştirir.

Gerçek dünya mobilya satış verisi kullanılarak yapılan deneylerde, MP-LRNet on bağımsız çalışmada ortalama 0,9918 R^2 değeri elde etmiş; en iyi yinelemede 0,9927 R^2 değerine ulaşmıştır. Deneysel sonuçlar, çoklu yama mekanizmasının modelin farklı zaman aralıklarındaki zamansal özellikleri öğrenmesine yardımcı olduğunu, LSTM + RF birleşiminin ise doğruluk ile eğitim süresi arasında dengeli bir sonuç sunduğunu göstermektedir. Buna karşılık, Mevsimsel Momentum Katmanı'nın katkısı sınırlı kalmış ve bu bileşenin etkisi karşılaştırmalı mimari bulgular ışığında daha temkinli yorumlanmıştır. Çalışmada dış baz modeller değerlendirilmediği için, bu sonuçlar alan geneli üstünlük iddiasından çok önerilen yapı ile 200 konfigürasyonlu iç karşılaştırmanın bulguları olarak yorumlanmalıdır. Bu çerçevede, tekrarlayan ağlar ile topluluk öğrenme yöntemlerinin birlikte kullanımının, özellikle bu veri seti altında, tahmin performansını destekleyebildiği söylenebilir.

Bu çalışma, modelin mobilya satış tahmini bağlamında bu veri seti ve deney protokolü altında güçlü sonuçlar üretebildiğini göstermektedir. Aşağıda gelecek çalışmalar için somut öneriler özetlenmektedir:

- Dikkat mekanizmaları ve transformer tabanlı genişletmeler: Mevcut LSTM/GRU tabanlı yapıya öz-dikkat (self-attention) veya transformer blokları eklenerek uzun vadeli bağımlılıkların daha açık biçimde modellenmesi ve literatürdeki yama tabanlı evrensel modeller (ör. MPMixer, MOIRAI) ile karşılaştırmalı deneyler yapılabilir.
- Farklı sektör ve veri setleri: MP-LRNet'in aynı mimari ile farklı perakende kanallarına (çoklu mağaza, çoklu ürün kategorisi) veya trafik, lojistik gibi farklı zaman serisi alanlarına uyarlanması ve genelleme performansının raporlanması, modelin taşınabilirliğini güçlendirecektir.
- Yorumlanabilirlik ve karar destek: Tahmin çıktılarının hangi zaman pencereleri

veya özellikler tarafından daha çok yönlendirildiğinin açıklanması (örneğin öznitelik önemleri, dikkat ağırlıkları veya kısmi bağımlılık grafikleri) ile modelin operasyonel ekipler tarafından güvenle kullanılması kolaylaştırılabilir. Zaman serisi tahmininde açıklanabilir yapay zeka (XAI) ve öznitelik önem analizlerinin karar destek amacıyla kullanımı güncel çalışmalarda vurgulanmaktadır (Zhang vd., 2024).

Çapraz alan doğrulaması (UCI güç tüketimi verisi), Wilcoxon testiyle doğrulanan istatistiksel anlamlılık ($p=0,00195$) ve ablasyon çalışmasının ortaya koyduğu bileşen katkı hiyerarşisi, önerilen hibrit mimarinin geçerliliğini ve haftalık periyodiklik içeren farklı zaman serilerine uyarlanma potansiyelini desteklemektedir.

Genel olarak, önerilen model, zaman serisi tahmininde hibrit sinir ağıları mimarilerine ilişkin gelecekteki araştırmalar için yararlı bir başlangıç çerçevesi sunmaktadır.

Bu tez kapsamındaki bulguların uluslararası hakemli bir dergide makale versiyonu yayımlanmıştır (Şahin & Çubukçu, 2026).

KAYNAKÇA

- Abumohsen, M., Owda, A. Y., Owda, M., & Abumihsan, A. (2024). Hybrid machine learning model combining of CNN-LSTM-RF for time series forecasting of Solar Power Generation. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 9, 100636. <https://doi.org/10.1016/J.PRIME.2024.100636>
- Alsalem, K. (2025). A hybrid time series forecasting approach integrating fuzzy clustering and machine learning for enhanced power consumption prediction. *Scientific Reports*, 15(1), 1-16. <https://doi.org/10.1038/S41598-025-91123-8>
- Alsoussi, A., & Tahboub, K. (2025). Inventory Management Practices and Challenges: An Exploratory Study. *An-Najah University Journal for Research - A (Natural Sciences)*, 40(1), 43-58. <https://doi.org/10.35552/ANUJR.A.40.1.2381>
- Balusani, A., Jai Ram Chowdary, P., & Paruchuri, B. V. N. P. (2025). *Enhancing Retail Demand Forecasting with Xgboost: A Comparative Study with Machine Learning and Deep Learning Models*. <https://doi.org/10.2139/SSRN.5274510>
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192-213. <https://doi.org/10.1016/j.ins.2011.12.028>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?-Arguments against avoiding RMSE in the literature. *Geosci. Model Dev*, 7, 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-August-2016*, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chicco, D., Warrens, M. J., & 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. <https://doi.org/10.7717/PEERJ-CS.623>
- Cho, K., Van Merriënboer, B., Gulçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*, 1724-1734. <https://doi.org/10.3115/v1/D14-1179>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*. <https://arxiv.org/abs/1412.3555v1>
- de Myttenaere, A., Golden, B., Le Grand, B., & Rossi, F. (2016). Mean Absolute Percentage Error for regression models. *Neurocomputing*, 192, 38-48. <https://doi.org/10.1016/j.neucom.2015.12.114>
- Djaballah, S., Saidi, L., Meftah, K., Hechifa, A., Bajaj, M., & Zaitsev, I. (2024). A hybrid LSTM random forest model with grey wolf optimization for enhanced detection of multiple bearing faults. *Scientific Reports 2024 14:1*, 14(1), 1-18. <https://doi.org/10.1038/s41598-024-75174-x>
- Fan, Y., Tang, Q., Guo, Y., & Wei, Y. (2024). BiLSTM-MLAM: A Multi-Scale Time Series Prediction Model for Sensor Data Based on Bi-LSTM and Local Attention Mechanisms. *Sensors 2024, Vol. 24, Page 3962*, 24(12), 3962. <https://doi.org/10.3390/S24123962>
- Ferdowsy, F. (2024). *Deep Learning-Based Time Series Prediction Techniques*.
- Fildes, R., Ma, S., & Kolassa, S. (2022). Retail forecasting: Research and practice. *International Journal of Forecasting*, 38(4), 1283-1318. <https://doi.org/10.1016/J.IJFORECAST.2019.06.004>

- Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367-378. [https://doi.org/10.1016/S0167-9473\(01\)00065-2](https://doi.org/10.1016/S0167-9473(01)00065-2)
- Guo, W., Liu, S., Weng, L., & Liang, X. (2025). Power Grid Load Forecasting Using a CNN-LSTM Network Based on a Multi-Modal Attention Mechanism. *Applied Sciences (Switzerland)*, 15(5), 2435. <https://doi.org/10.3390/APP15052435>
- Gupta, A., & Agarwal, P. (2024). Enhancing Sales Forecasting Accuracy through Integrated Enterprise Resource Planning and Customer Relationship Management using Artificial Intelligence. *2024 3rd International Conference on Artificial Intelligence for Internet of Things, AIIoT 2024*. <https://doi.org/10.1109/AIIOT58432.2024.10574785>
- Hassan, D. O., & Hassan, B. A. (2024). A comprehensive systematic review of machine learning in the retail industry: classifications, limitations, opportunities, and challenges. *Neural Computing and Applications 2024* 37:4, 37(4), 2035-2070. <https://doi.org/10.1007/s00521-024-10869-w>
- He, Z., Guo, Q., Wang, Z., & Li, X. (2025). A Hybrid Wavelet-Based Deep Learning Model for Accurate Prediction of Daily Surface PM2.5 Concentrations in Guangzhou City. *Toxics*, 13(4), 254. <https://doi.org/10.3390/TOXICS13040254>
- Hebrail, G., & Berard, A. (2012). Individual household electric power consumption data set. *UCI Machine Learning Repository*. <https://doi.org/10.24432/C58K54>
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388-427. <https://doi.org/10.1016/J.IJFORECAST.2020.06.008>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/NECO.1997.9.8.1735>
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5-10. <https://doi.org/10.1016/J.IJFORECAST.2003.09.015>
- Jiang, K., Huang, Z., Zhou, X., Tong, C., Zhu, M., & Wang, H. (2023). Deep belief improved bidirectional LSTM for multivariate time series forecasting. *MBE*, 20(9), 16596-16627. <https://doi.org/10.3934/mbe.2023739>
- Kabir, M. R., Bhadra, D., Ridoy, M., & Milanova, M. (2025). LSTM-Transformer-Based Robust Hybrid Deep Learning Model for Financial Time Series Forecasting. *Sci 2025, Vol. 7, Page 7*, 7(1), 7. <https://doi.org/10.3390/SCI7010007>
- Kingma, D. P., & Ba, J. L. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <https://arxiv.org/pdf/1412.6980>
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194). <https://doi.org/10.1098/RSTA.2020.0209>
- Louis Eyo-Udo, N., Toromade, A., Tosin Adewale, T., Stephen Toromade, A., & Ngochindo Igwe, A. (2024). *Optimizing food and FMCG supply chains: A dual approach leveraging behavioral finance insights and big data analytics for strategic decision-making*. <https://doi.org/10.57219/crrj.2024.2.1.0028>
- Ma, C., Hu, Y., & Xu, X. (2024). Hybrid deep learning model with VMD-BiLSTM-GRU networks for short-term traffic flow prediction. *Data Science and Management*. <https://doi.org/10.1016/J.DSM.2024.10.004>
- Madas, M. A., Pasupuleti, V., Thuraka, B., Kodete, C. S., & Malisetty, S. (2024). Enhancing Supply Chain Agility and Sustainability through Machine Learning: Optimization Techniques for Logistics and Inventory Management. *Logistics 2024, Vol. 8, Page 73*, 8(3), 73. <https://doi.org/10.3390/LOGISTICS8030073>
- Mahmoud, A., & Mohammed, A. (2024). Leveraging Hybrid Deep Learning Models for

- Enhanced Multivariate Time Series Forecasting. *Neural Processing Letters*, 56(5), 1-25. <https://doi.org/10.1007/S11063-024-11656-3>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74. <https://doi.org/10.1016/J.IJFORECAST.2019.04.014>
- Mariappan, Y., Ramasamy, K., & Velusamy, D. (2025). An optimized deep learning based hybrid model for prediction of daily average global solar irradiance using CNN SLSTM architecture. *Scientific Reports*, 15(1), 1-19. <https://doi.org/10.1038/S41598-025-95118-3>
- Moritz, S., & Bartz-Beielstein, T. (2017). *imputeTS: Time Series Missing Value Imputation in R*. *The R Journal*, 9(1), 207-218. <https://doi.org/10.32614/RJ-2017-009>
- Naghashi, V., Boukadoum, M., & Diallo, A. B. (2025). A multiscale model for multivariate time series forecasting. *Scientific Reports 2024 15:1*, 15(1), 1565-. <https://doi.org/10.1038/s41598-024-82417-4>
- Olaleye, I. A., Mokogwu, C., Olufemi-Phillips, A. Q., & Adewale, T. T. (2024). Transforming supply chain resilience: Frameworks and advancements in predictive analytics and data-driven strategies. *Open Access Research Journal of Multidisciplinary Studies*, 8(2), 085-093. <https://doi.org/10.53022/OARJMS.2024.8.2.0065>
- Punia, S., Nikolopoulos, K., Singh, S. P., Madaan, J. K., & Litsiou, K. (2020). Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail. *International Journal of Production Research*, 58(16), 4964-4979. <https://doi.org/10.1080/00207543.2020.1735666>
- Salman, D., Direkoglu, C., Altanneh, N., & Ahmed, A. (2024). Hybrid Wavelet-LSTM-Transformer Model for Fault Forecasting in Power Grids. *SSRG International Journal of Electrical and Electronics Engineering*, 11(12), 314-326. <https://doi.org/10.14445/23488379/IJEEE-V11I12P130>
- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69-79. <https://doi.org/10.58496/BJML/2024/007>
- Sapankevych, N., & Sankar, R. (2009). Time series prediction using support vector machines: A survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38. <https://doi.org/10.1109/MCI.2009.932254>
- Sherly, A., Christo, M. S., & Elizabeth, J. V. (2025). A hybrid approach to time series forecasting: Integrating ARIMA and prophet for improved accuracy. *Results in Engineering*, 27, 105703. <https://doi.org/10.1016/J.RINENG.2025.105703>
- Shi, J., Wang, S., Qu, P., & Shao, J. (2024). Time series prediction model using LSTM-Transformer neural network for mine water inflow. *Scientific Reports*, 14(1), 1-16. <https://doi.org/10.1038/S41598-024-69418-Z>
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75-85. <https://doi.org/10.1016/J.IJFORECAST.2019.03.017>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929-1958.
- Şahin, O., & Çubukçu, B. (2024). Mobilya sektöründe satış tahmini: Yinelemeli sınır ağı modellerinin karşılaştırmalı analizi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 12(4), 686-706. <https://doi.org/10.21923/jesd.1433624>
- Şahin, O., & Çubukçu, B. (2026). A hybrid time series forecasting model combining recurrent neural networks and ensemble learning for furniture sales prediction. *Ain Shams Engineering Journal*, 17(7), 104219. <https://doi.org/10.1016/j.asej.2026.104219>
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2025). Forecast accuracy and inventory

- performance: Insights on their relationship from the M5 competition data. *European Journal of Operational Research*, 322(2), 414-426.
<https://doi.org/10.1016/j.ejor.2024.12.033>
- Wen, X., Liao, J., Niu, Q., Shen, N., & Bao, Y. (2024). Deep learning-driven hybrid model for short-term load forecasting and smart grid information management. *Scientific Reports*, 14(1), 1-16. <https://doi.org/10.1038/S41598-024-63262-X>
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3), 324-342. <https://doi.org/10.1287/MNSC.6.3.324>
- Woo, G., Liu, C., Kumar, A., Xiong, C., Savarese, S., & Sahoo, D. (2024). Unified training of universal time series forecasting transformers. *Proceedings of the 41st International Conference on Machine Learning (ICML 2024)*, Vienna, Austria, 235.
https://ink.library.smu.edu.sg/sis_research/9906
- Xu, Y., Zhang, W., Lai, H., Zhang, S., & Xiao, R. (2025). MPMixer: Multi-scale Patch Mixer for long-term time series forecasting. *Neurocomputing*, 646, 130398.
<https://doi.org/10.1016/J.NEUCOM.2025.130398>
- Zhang, J., & Yan, L. (2025). GRU-Enhanced Attention Mechanism for LSTM in Hybrid CNN-LSTM Models for Stock Prediction. *Journal of Global Trends in Social Science*, 2(3). <https://doi.org/10.70731/RZVS8J53>
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Zhang, Y., Sun, Q., Qi, D., Liu, J., Ma, R., & Petrosian, O. (2024). ShapTime: A General XAI Approach for Explainable Time Series Forecasting. *Lecture Notes in Networks and Systems*, 822, 659-673. https://doi.org/10.1007/978-3-031-47721-8_45