T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KENTSEL RAYLI ULAŞIM SİSTEMLERİNDE ENERJİ TÜKETİMİ VE KARBON AYAK İZİ TAHMİNİ İÇİN MAKİNE ÖĞRENMESİ YAKLAŞIMLARININ KARŞILAŞTIRMALI ANALİZİ

Hazırlayan
Kamber KÜLAHCI

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Yüksek Lisans Tezi

Şubat 2026
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KENTSEL RAYLI ULAŞIM SİSTEMLERİNDE ENERJİ TÜKETİMİ VE KARBON AYAK İZİ TAHMİNİ İÇİN MAKİNE ÖĞRENMESİ YAKLAŞIMLARININ KARŞILAŞTIRMALI ANALİZİ

(Yüksek Lisans Tezi)

Hazırlayan
Kamber KÜLAHCI

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Şubat 2026
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Kamber KÜLAHCI

İmza

“Kentsel Raylı Ulaşım Sistemlerinde Enerji Tüketimi ve Karbon Ayak İzi Tahmini için Makine Öğrenmesi Yaklaşımlarının Karşılaştırmalı Analizi” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan	**Danışman**
Kamber KÜLAHCI	Dr. Öğr. Üyesi Sertaç SAVAŞ
İmza	İmza

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

İmza

TEŞEKKÜR

“Kentsel Raylı Ulaşım Sistemlerinde Enerji Tüketimi ve Karbon Ayak İzi Tahmini için Makine Öğrenmesi Yaklaşımlarının Karşılaştırmalı Analizi” konulu tezin belirlenmesinde, yürütülmesinde ve sonuçlandırılmasında maddi manevi destek ve yardımlarda bulunan değerli danışman hocam Sayın Dr. Öğr. Üyesi Sertaç SAVAŞ’a teşekkür ederim.

Tez çalışması boyunca verdiği maddi, manevi destek ve gösterdiği anlayıştan dolayı eşim Hikmet KÜLAHCI ve çok kıymetli oğlum Lokman Kerem KÜLAHCI’ya, yine her daim yanımda olan emeğini hiçbir zaman esirgemeyen annem ve babama, ayrıca çalışmalarımın her safhasında görüş, öneri ve desteklerini esirgemeyen Arş. Gör. Mehmet Safa BİNGÖL’e teşekkür ederim.

Son olarak bu çalışmada kullanılan verileri sağlamadaki değerli katkılarından dolayı Kayseri Ulaşım A.Ş.’ye teşekkür ederim.

Kamber KÜLAHCI

Şubat 2026, KAYSERİ

KENTSEL RAYLI ULAŞIM SİSTEMLERİNDE ENERJİ TÜKETİMİ VE KARBON AYAK İZİ TAHMİNİ İÇİN MAKİNE ÖĞRENMESİ YAKLAŞIMLARININ KARŞILAŞTIRMALI ANALİZİ

Kamber KÜLAHCI

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Şubat 2026
Danışman: Dr. Öğr. Üyesi Sertaç SAVAŞ

ÖZET

Kentsel raylı ulaşım sistemleri, ulaşıma bağlı emisyonları önemli ölçüde azaltma potansiyeline sahip olmakla birlikte elektrik talebi ve buna eşlik eden karbon ayak izinin isabetli tahmini, operasyonların etkin yönetimi ve karbon bütçesinin planlanması açısından önemli bir gerekliliktir. Bu çalışmada, kentsel raylı ulaşım sistemlerinde enerji tüketimi ve karbon ayak izini tahmin etmek üzere beş makine öğrenmesi yaklaşımı tasarlanmış ve karşılaştırmalı olarak değerlendirilmiştir. Beş trafo merkezine ait on yıllık enerji tüketiminin aylık verileri ile bunlara karşılık gelen toplam karbon ayak izi verileri kullanılmıştır. Tahmin çalışmasında SVR, XGBoost, LSTM, ANFIS ve NAR-NN modelleri kullanılmıştır. Modellerin hiperparametreleri 20 iterasyonluk Rastgele Arama yaklaşımı ile optimize edilmiş ve stokastik modeller optimize edilmiş ayarlar kullanılarak 10 kez çalıştırılmıştır. Model performansları RMSE, MAE, MAPE ve R^2 metrikleri ile değerlendirilmiştir. Tüm trafo merkezlerinde sinir ağı tabanlı modellerin çoğu kez sıfıra yakın veya negatif R^2 ürettiği yüksek varyanslı zorlu durumlarda bile SVR en güvenilir genelleme performansını sağlamıştır ($R^2 \approx 0.896–0.993$). Karbon ayak izi tahmininde de SVR en yüksek doğruluğu elde etmiş ($R^2=0.942$; MAPE=%3.51), XGBoost ise ikinci sırada yer almıştır. Genel olarak bulgular, sınırlı veri içeren aylık zaman serisi koşullarında, iyi düzenlileştirilmiş klasik makine öğrenmesi modellerinin (özellikle SVR) yüksek veri gereksinimli sinir ağlarına kıyasla daha üstün performans gösterebileceğini ve kentsel raylı ulaşım operasyonlarında enerji arzı planlaması, pik yük yönetimi ve karbon bütçelemesi için pratik fayda sağlayabileceğini ortaya koymuştur.

Anahtar Kelimeler: Kentsel raylı ulaşım sistemleri, enerji tüketimi tahmini, karbon ayak izi tahmini, zaman serisi tahmini, makine öğrenmesi.

A COMPARATIVE ANALYSIS OF MACHINE LEARNING APPROACHES FOR ENERGY CONSUMPTION AND CARBON FOOTPRINT FORECASTING IN URBAN RAIL TRANSIT SYSTEMS

Kamber KÜLAHCI

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, February 2026
Supervisor: Assist. Prof. Dr. Sertaç SAVAŞ

ABSTRACT

While urban rail transit systems have the potential to significantly reduce transportation-related emissions, accurate forecasting of electricity demand and its associated carbon footprint is a crucial requirement for efficient operational management and carbon budget planning. This study designes and comparatively evaluates five machine learning approaches to estimate energy consumption and carbon footprint in urban rail transit systems. Ten years of monthly energy consumption data and corresponding total carbon footprint data from five substations are used. SVR, XGBoost, LSTM, ANFIS, and NAR-NN models are employed in the forecasting study. The hyperparameters of the models are optimized with a 20-iteration Random Search approach, and stochastic models are run 10 times using the optimized settings. Model performance is evaluated using RMSE, MAE, MAPE, and R^2 metrics. Even in challenging high-variance situations where neural network-based models often produced near-zero or negative R^2 values in all substations, SVR provides the most reliable generalization performance ($R^2 \approx 0.896–0.993$). In carbon footprint estimation, SVR achieves the highest accuracy ($R^2=0.942$; MAPE=3.51%), while XGBoost ranking second. Overall, the findings suggest that, under conditions of limited monthly time series data, well-regulated classical machine learning models (especially SVR) can outperform data-intensive neural networks and offer practical benefits for energy supply planning, peak load management, and carbon budgeting in urban rail transit operations.

Keywords: Urban rail transit systems, energy consumption forecasting, carbon footprint forecasting, time-series forecasting, machine learning.

İÇİNDEKİLER

KENTSEL RAYLI ULAŞIM SİSTEMLERİNDE ENERJİ TÜKETİMİ VE KARBON AYAK İZİ TAHMİNİ İÇİN MAKİNE ÖĞRENMESİ YAKLAŞIMLARININ KARŞILAŞTIRMALI ANALİZİ

BİLİMSEL ETİĞE UYGUNLUK ii

YÖNERGEYE UYGUNLUK iii

KABUL VE ONAY iv

TEŞEKKÜR v

ÖZET vi

ABSTRACT vii

İÇİNDEKİLER viii

KISALTMALAR x

TABLOLAR LİSTESİ xi

ŞEKİLLER LİSTESİ xii

GİRİŞ 1

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı 3

1.2. Literatür Çalışması 4

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Veri Seti Tanımı ve Ön İşleme 9

2.1.1. Karbon Ayak İzi ($kgCO_2$) Hesaplama Yöntemi 12

2.2. Makine Öğrenmesi Yöntemleri 12

2.2.1. Destek Vektör Regresyonu (Support Vector Regression – SVR) 12

2.2.2. Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBoost) 13

2.2.3. Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM) 13

2.2.4. Uyarlamalı Sinirsel-Bulanık Çıkarım Sistemi Adaptive Neuro-Fuzzy Inference System – ANFIS) 14

2.2.5. Doğrusal Olmayan Otoregresif Sinir Ağı (Nonlinear Autoregressive Neural Network – NAR-NN) 15

2.3. Hiperparametre Ayarı 15

2.4. Performans Metrikleri 16

3. BÖLÜM

TAHMİN ÇALIŞMALARI

3.1. Deneysel Çalışmalar 18

3.2. Isı Haritaları 20

3.3. Zaman Serisi Bazında Tahmin ve Hata Grafikleri 23

3.4. Model Bazında Tahmin ve Dağılım Grafikleri 30

3.4.1. SVR Tahmin ve Dağılım Grafikleri 30

3.4.2. XGBoost Tahmin ve Dağılım Grafikleri 33

3.4.3. LSTM Tahmin ve Dağılım Grafikleri 37

3.4.4. ANFIS Tahmin ve Dağılım Grafikleri 40

3.4.5. NAR-NN Tahmin ve Dağılım Grafikleri 44

4. BÖLÜM

SONUÇ VE ÖNERİLER

KAYNAKÇA 51

EKLER 57

EK 1. 57

ÖZGEÇMİŞ 58

KISALTMALAR

SVR	:	Support Vector Regression – Destek Vektör Regresyonu
XGBoost	:	Extreme Gradient Boosting – Aşırı Gradyan Artırma
LSTM	:	Long Short-Term Memory – Uzun Kısa Süreli Bellek
ANFIS	:	Adaptive Neuro-Fuzzy Inference System – Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
NAR-NN	:	Nonlinear Autoregressive Neural Network – Doğrusal Olmayan Otoregresif Sinir Ağı
RMSE	:	Root Mean Squared Error – Kök Ortalama Kare Hata
MAE	:	Mean Absolute Error – Ortalama Mutlak Hata
MAPE	:	Mean Absolute Percentage Error – Ortalama Mutlak Yüzde Hata
R^2	:	Coefficient of Determination – Belirleme Katsayısı
CO_2	:	Karbondioksit
BEMS	:	Building Energy Management System – Bina Enerji Yönetim Sistemi
GRU	:	Gated Recurrent Unit – Kapılı Tekrarlayan Birim
CNN	:	Convolutional Neural Network – Evrişimsel Sinir Ağı
AutoML	:	Automated Machine Learning – Otomatik Makine Öğrenmesi
TCN	:	Temporal Convolutional Network – Zamansal Evrişimsel Ağ
SWT	:	Stationary Wavelet Transform – Durağan Dalgacık Dönüşümü
FRBPS	:	Fuzzy Rule-Based Prediction Systems – Bulanık Kural Tabanlı Tahmin Sistemleri
GAN	:	Generative Adversarial Network – Üretici Çekişmeli Ağ
NDC	:	Nationally Determined Contributions – Ulusal Katkı Beyanları
PCA	:	Principal Component Analysis – Temel Bileşenler Analizi
BSS	:	Blind Source Separation – Kör Kaynak Ayrıştırma
XAI	:	eXplainable Artificial Intelligence – Açıklanabilir Yapay Zekâ
SHAP	:	SHapley Additive exPlanations – SHapley Eklemeli Açıklamalar
SVM	:	Support Vector Machine – Destek Vektör Makinesi
K-NN	:	K-Nearest Neighbors – K-En Yakın Komşu
kWh	:	Kilovat-saat
EF	:	Emisyon Faktörü
RBF	:	Radial Basis Function – Radyal Tabanlı Fonksiyon

TABLOLAR LİSTESİ

Tablo 2.1. Tahmin modelleri için hiperparametreler ve arama aralığı 16
Tablo 3.1. Model performans metriklerinin karşılaştırılması 19

ŞEKİLLER LİSTESİ

Şekil 2.1. Kentsel raylı ulaşım sisteminde enerji akışı ve karbon ayak izi şeması 9
Şekil 2.2. Beş trafo için aylara göre tüketim dağılımı 10
Şekil 2.3. Beş trafo merkezinin enerji tüketimi ve karbon ayak izi zaman serileri ile eğitim–test ayrımı..... 11
Şekil 3.1. Model ve zaman serisine göre RMSE ısı haritası 20
Şekil 3.2. Model ve zaman serisine göre MAE ısı haritası 21
Şekil 3.3. Model ve zaman serisine göre MAPE ısı haritası..... 21
Şekil 3.4. Model ve zaman serisine göre R^2 ısı haritası..... 22
Şekil 3.5. Trafo-1: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 24
Şekil 3.6. Trafo-2: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 25
Şekil 3.7. Trafo-3: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 26
Şekil 3.8. Trafo-4: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 27
Şekil 3.9. Trafo-5: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 28
Şekil 3.10. Karbon Ayak İzi: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri 29
Şekil 3.11. Trafo-1 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği..... 30
Şekil 3.12. Trafo-2 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği..... 31
Şekil 3.13. Trafo-3 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği..... 31
Şekil 3.14. Trafo-4 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği..... 32
Şekil 3.15. Trafo-5 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği..... 32

Şekil 3.16. Karbon ayak izi için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 33
Şekil 3.17. Trafo-1 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 34
Şekil 3.18. Trafo-2 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 34
Şekil 3.19. Trafo-3 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 35
Şekil 3.20. Trafo-4 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 35
Şekil 3.21. Trafo-5 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 36
Şekil 3.22. Karbon ayak izi için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 36
Şekil 3.23. Trafo-1 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 37
Şekil 3.24. Trafo-2 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 38
Şekil 3.25. Trafo-3 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 38
Şekil 3.26. Trafo-4 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 39
Şekil 3.27. Trafo-5 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 39
Şekil 3.28. Karbon ayak izi için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 40
Şekil 3.29. Trafo-1 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 41
Şekil 3.30. Trafo-2 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 41
Şekil 3.31. Trafo-3 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 42

Şekil 3.32. Trafo-4 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 42
Şekil 3.33. Trafo-5 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 43
Şekil 3.34. Karbon ayak izi için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 43
Şekil 3.35. Trafo-1 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 44
Şekil 3.36. Trafo-2 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 45
Şekil 3.37. Trafo-3 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 45
Şekil 3.38. Trafo-4 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 46
Şekil 3.39. Trafo-5 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 46
Şekil 3.40. Karbon ayak izi için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği 47

GİRİŞ

Ulaştırma sektörü, küresel sera gazı emisyonlarına önemli katkısı nedeniyle iklim değişikliğiyle mücadelede kritik bir konumdadır. Kentsel raylı ulaşım sistemleri karayolu taşımacılığına kıyasla daha düşük emisyon profiline sahip olsa da işletme ölçeği büyüdükçe enerji tüketiminin ve buna bağlı karbon ayak izinin doğru biçimde öngörülmesi; sürdürülebilir kentsel planlama, enerji arz-talep dengesi, işletme maliyetlerinin yönetimi ve karbon dengeleme stratejilerinin tasarımı açısından belirleyici hâle gelmektedir. Bu nedenle, raylı sistemlerde enerji tüketimi ve emisyonların kısa-orta vadeli tahmini yalnızca operasyonel bir gereksinim değil, aynı zamanda çevresel performansın iyileştirilmesine doğrudan hizmet eden bir karar-destek problemidir.

Son yıllarda makine öğrenmesi tabanlı modeller, doğrusal olmayan davranışları ve karmaşık örüntüleri yakalayabilmesi sayesinde enerji ve emisyon tahmininde yaygın biçimde kullanılmaktadır. Ancak, özellikle aylık ölçekte tutulan ve gözlem sayısı sınırlı kalan zaman serilerinde, hangi yöntemlerin daha iyi genelleme yaptığı her zaman açık değildir. Bu tez çalışması, kentsel raylı ulaşım sistemlerinde enerji tüketimi ve karbon ayak izi tahmini için farklı öğrenme yaklaşımlarını aynı çerçevede değerlendirerek bu boşluğu doldurmayı hedeflemektedir.

Bu kapsamda, beş farklı trafo merkezi için uzun dönemli (aylık) enerji tüketimi verileri ve bunlara karşılık gelen toplam karbon ayak izi verileri kullanılarak beş tahmin modeli karşılaştırılmıştır: Destek Vektör Regresyonu (Support Vector Regression – SVR), Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBoost), Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM), Uyarlamalı Sinirsel-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System – ANFIS) ve Doğrusal Olmayan Otoregresif Sinir Ağı (Nonlinear Autoregressive Neural Network – NAR-NN). Model hiperparametreleri sınırlı sayıda iterasyonla Rastgele Arama (Random Search) yaklaşımı ile optimize edilmiş; rastgelelik içeren (stokastik) modellerin sonuç kararlılığını görmek

amacıyla çoklu tekrar koşuları yürütülmüştür. Performans değerlendirmesi ise Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE), Ortalama Mutlak Hata (Mean Absolute Error, MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE) ve Belirlilik Katsayısı (Coefficient of Determination, R^2) metrikleri ile yapılmıştır. Elde edilen sonuçlar, sınırlı veri koşullarında geleneksel/deterministik yaklaşımların (özellikle SVR'nin) daha yüksek doğruluk ve daha tutarlı genelleme sağlayabildiğini; buna karşın veri gereksinimi daha yüksek olan sinir ağı tabanlı yöntemlerin bazı serilerde genellemede zorlanabildiğini göstermektedir. Bu bulgu, küçük ve orta ölçekli zaman serisi tahmin problemlerinde yöntem seçiminin veri miktarı ve veri yapısı ile birlikte ele alınması gerektiğine işaret etmektedir.

Tez çalışması 4 bölümden oluşmaktadır. 1. bölümde tezin amacı, problem tanımı ve kentsel raylı ulaşımda enerji tüketimi ile karbon ayak izi tahminine ilişkin literatür özeti sunulmuştur. "Yöntem ve Materyal" başlıklı 2. bölümde; incelenen sistemin genel çerçevesi, veri setinin kapsamı ve hazırlanması, ön işleme adımları (eksik veri ele alma, eğitim-test ayrımı), kullanılan makine öğrenmesi yöntemleri ve hiperparametre optimizasyon yaklaşımı ayrıntılı biçimde açıklanmıştır. 3. bölümde, tahmin modellerinin deneysel çalışmaları yürütülmüş; sonuçlar hata metrikleri ve karşılaştırmalı performans analizleri üzerinden raporlanıp tartışılmıştır. 4. bölümde ise elde edilen bulgular özetlenmiş, uygulamaya dönük çıkarımlar verilmiş ve gelecekte yapılabilecek geliştirmelere yönelik öneriler sunulmuştur.

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı

Günümüzde ulaştırma ve endüstriyel faaliyetler nedeniyle atmosfere salınan karbondioksit (CO_2) miktarı hızla artmaktadır. Bu durum; iklim değişikliği, küresel ısınma ve doğal dengenin bozulması gibi olumsuz sonuçlara yol açmaktadır. Bu olumsuz etkilerin temel göstergelerinden biri karbon ayak izidir. Karbon ayak izi; bireylerin, kurumların veya ülkelerin faaliyetleri sonucunda atmosfere yayılan toplam karbondioksit miktarını ifade eder. Karbon ayak izinin azaltılması, çevresel zararın en aza indirilmesi açısından kritik önemdedir. Enerji verimli cihazların kullanılması, yenilenebilir enerji kaynaklarına yönelim, toplu taşımanın tercih edilmesi ve bilinçli tüketim alışkanlıklarının benimsenmesi karbon ayak izini azaltmanın başlıca yolları arasındadır. Bu önlemler sayesinde fosil yakıt tüketimi azalır ve atmosfere salınan CO_2 miktarı belirgin biçimde düşer.

Karbon ayak izini azaltmaya ek olarak ağaçlandırma çalışmaları, daha önce atmosfere salınmış karbondioksitin dengelenmesinde önemli bir rol oynar. Ağaçlar fotosentez yoluyla karbondioksiti soğurup oksijen üreterek doğal bir karbon yutağı görevi görür. Karbon ayak izi hesaplamalarından elde edilen emisyon miktarına bağlı olarak belirli sayıda ağaç dikilmesi, çevresel etkinin telafi edilmesine katkı sağlayabilir.

Bu yaklaşımların etkin biçimde planlanabilmesi için enerji tüketiminin ve buna bağlı emisyonların güvenilir şekilde tahmin edilmesi gerekmektedir. Dolayısıyla küresel iklim değişikliğiyle mücadele ve sürdürülebilir kalkınma hedefleri doğrultusunda, enerji tüketimi ile karbon emisyonlarının doğru tahmini kritik bir önem taşır. Ulaştırma sektörü, küresel CO_2 emisyonlarının başlıca kaynaklarından biridir ve bu emisyonların önemli bir bölümü karayolu araçlarından kaynaklanmaktadır. Kentsel raylı ulaşım sistemleri

karayolu taşımacılığına kıyasla çok daha düşük bir karbon ayak izine sahip olsa da sürdürülebilir kentsel gelişim için bu sistemlerin enerji tüketiminin optimize edilmesi gereklidir. Bununla birlikte, makine öğrenmesi ve yapay zekâ teknolojilerindeki son gelişmeler enerji tüketimi ve karbon emisyonu tahmininde önemli ilerlemeler sağlamıştır. Bu algoritmalar, geleneksel istatistiksel yöntemlerin yakalamakta zorlandığı karmaşık ve doğrusal olmayan ilişkileri modelleme kapasitesine sahiptir.

Bu çalışmada, bir raylı ulaşım sistemine ait 10 yıllık enerji tüketimi verileri kullanılarak beş farklı makine öğrenmesi algoritmasının (SVR, XGBoost, LSTM, ANFIS ve NAR-NN) tahmin performansları karşılaştırılmıştır. Beş trafo merkezinin enerji tüketimi ve toplam karbon ayak izi için ayrı modeller geliştirilmiştir. Hiperparametre optimizasyonu Rastgele Arama yöntemiyle gerçekleştirilmiş ve farklı metrikler kullanılarak kapsamlı bir performans değerlendirmesi yapılmıştır. Çalışma, küçük ve orta ölçekli zaman serisi veri kümelerinde geleneksel makine öğrenmesi yöntemlerinin avantajlarını vurgulamaktadır.

1.2. Literatür Çalışması

Enerji yönetimi ile bina/konut elektrik tüketimi tahmini literatürü, genellikle zaman serisi verileri kullanarak kısa ve orta vadeli talep kestirimine odaklanmaktadır. Qureshi ve ark. [1], Bina Enerji Yönetim Sistemleri (Building Energy Management Systems – BEMS) kapsamında bir hastane ortamını incelemiş, LSTM tabanlı tahminleme kullanmış ve optimizasyon adımlarının performansı artırabileceğini belirtmişlerdir. Elhabyb ve ark. [2], eğitim binaları için makine öğrenmesi ve derin öğrenme tabanlı tahmincileri karşılaştırmış; bina-özel tüketim örüntülerine göre model uyarlamasının kritik olduğunu vurgulamışlardır. Morcillo-Jimenez ve ark. [3], gerçek ofis binası sensör verileriyle derin öğrenme zaman serisi modellerini değerlendirmiş; bellek temelli mimarilerin durumsuz yaklaşımlara kıyasla daha iyi sonuç verebildiğini, ancak sınırlı veri koşullarının daha gelişmiş paradigmaları kısıtladığını raporlamışlardır. Mahjoub ve ark. [4], Fransa'daki şehirlerden elde edilen gerçek veriler üzerinde kısa vadeli güç tahmini için LSTM, Kapılı Tekrarlayan Birim (Gated Recurrent Unit – GRU) ve Drop-GRU modellerini karşılaştırmış; LSTM'nin genel olarak daha düşük hata ürettiğini ve proaktif yük yönetimini destekleyebileceğini bildirmişlerdir. Ramos ve ark. [5], konut yük tahmini için çeşitli derin öğrenme mimarilerini kıyaslamış ve doğruluğu artırmak amacıyla Oylama Topluluk (Voting Ensemble) yaklaşımını da incelemişlerdir. Chan ve Yeo [6], yük

tahmini için seyrek Transformer yaklaşımı önermiş; Attention (dikkat) tabanlı dizi modellemenin daha hızlı çıkarım ile benzer doğruluk sağlayabileceğini savunmuşlardır. Chung ve Jang [7], çok değişkenli elektrik tüketimi tahmini için Evrişimli Sinir Ağı (Convolutional Neural Network – CNN) ile LSTM'yi birleştiren hibrit bir yaklaşım sunmuş; özellik çıkarımını ve bölgesel tahmin performansını iyileştirmeyi hedeflemişlerdir. Maleki ve ark. [8], akıllı sayaç verileri üzerinde birden fazla yaklaşımı kıyaslamış; derin öğrenmenin rekabetçi olabileceğini, daha fazla veri mevcut olduğunda ise Otomatik Makine Öğrenmesi'nin (Automated Machine Learning – AutoML) genellemeyi artırabildiğini raporlamıştır.

İkinci bir araştırma yaklaşımı, tahminin dayanıklılığını artırmak amacıyla sinyal işleme, dikkat mekanizmaları veya uzun dönem bağımlılık modelleme bileşenlerini tahmin sürecine entegre etmektedir. Deng ve ark. [9], Zamansal Evrişimsel Ağ'ı (Temporal Convolutional Network – TCN) bir Attention mekanizması ile birleştirmiş ve özellik indirgeme adımlarının tahmin kalitesini daha da yükseltebileceğini bildirmişlerdir. Frikha ve ark. [10], derin öğrenme tabanlı tahmin öncesinde durağan dalgacık dönüşümünü (Stationary Wavelet Transform – SWT) gürültü giderme adımı olarak kullanmış ve yalnızca derin öğrenme kullanımına kıyasla daha yüksek doğruluk elde edildiğini raporlamışlardır. Bazı çalışmalar ise özellikle binalarda karar destek amaçları doğrultusunda doğrulukla birlikte şeffaflık ve yorumlanabilirliği önceliklendirmektedir. Gorzałczany ve Rudziński [11], konut enerji tüketimi için Bulanık Kural Tabanlı Tahmin Sistemleri (Fuzzy Rule-Based Prediction Systems – FRBPS) önermiş ve evrimsel optimizasyon ile doğruluk–yorumlanabilirlik dengesini iyileştirerek artan şeffaflığa dikkat çekmişlerdir. Akıllı şehir bağlamında, operasyonel güvenilirliği artırmak amacıyla tahminleme sıklıkla anomali veya kaçak/tüketim hırsızlığı tespiti ile birlikte ele alınmaktadır. Chahardoli ve ark. [12], tüketim tahmini ve kaçak tespitini birleştiren hibrit bir derin öğrenme çerçevesi önermiş; veri dengeleme ve optimizasyon adımlarının katkısını vurgulayarak, veri dengeleme için Üretici Çekişmeli Ağ'ın (Generative Adversarial Network – GAN) kullanımını raporlamışlardır.

Karbon emisyonu tahmini literatürü ise günlük emisyon öngörüleri, ulusal emisyon eğilimleri ve politika uyumu değerlendirmelerini kapsamaktadır. Ajala ve ark. [13], günlük CO_2 emisyonları için istatistiksel, makine öğrenmesi ve derin öğrenme modellerini karşılaştırmış ve topluluk (ensemble) yöntemlerin pratik değerini öne

çıkarmışlardır. Begum ve Mobin [14], büyük emisyon kaynakları için 2030'a kadar CO_2 eğilimlerini projekte etmiş ve Ulusal Katkı Beyanları (Nationally Determined Contributions – NDC) ile uyumu tartışmışlardır. Xia ve ark. [15], endüstriyel emisyon tahmininde derin öğrenmeyi faktör-odaklı analizle birleştirerek senaryo tabanlı karar vermeyi desteklemeyi amaçlamışlardır. Meng ve ark. [16], SVR kullanarak Çin'in enerji tüketimini öngörmüş ve yapısal evrimi Markov Zinciri ile analiz etmişlerdir. Li ve ark. [17], sınırlı veri koşullarında endüstriyel CO_2 tahmininde aşırı uyumu azaltmak için meta-öğrenme tabanlı bir transfer yaklaşımı önermişlerdir. Ghorbal ve ark. [18], derin tekrarlayan modellemeyi meta-sezgisel optimizasyonla birleştirmiş; veri arıtımı için Temel Bileşenler Analizi (Principal Component Analysis – PCA) ve Kör Kaynak Ayrıştırma'yı (Blind Source Separation – BSS) kullanmışlardır. Taşımacılık gibi sektöre özgü emisyon çalışmaları ise çoğunlukla yorumlanabilirlik boyutunu güçlendirerek, tahminleri eyleme dönük faktörlerle ilişkilendirmektedir. Alam ve ark. [19], araç CO_2 emisyonlarını derin öğrenme ile tahmin etmiş ve Açıklanabilir Yapay Zekâ'yı (eXplainable Artificial Intelligence – XAI) entegre ederek, özellik önemini atfetmek amacıyla SHapley Eklemeli Açıklamalar (SHapley Additive exPlanations – SHAP) yöntemini kullanmışlardır.

Kentsel raylı ulaşım sistemleri; zaman çizelgesi (sefer tarifesi) tasarımı, yolcu talep örüntüleri, ağ yapısı, tren seti performansı ve rejeneratif frenleme mekanizmaları gibi kendine özgü işletim özelliklerine sahiptir. Bu alanda, Lee ve ark. [20] akıllı kart verilerine dayanarak yolcu tercih davranışlarını dikkate alan bir durak atlamalı (skip-stop) strateji geliştirmişlerdir. Zhu ve ark. [21] ise karbon emisyonlarını gözeterek esnek tren kompozisyonu ile tren planı optimizasyonu önermiştir.

Yine enerji tüketimi tahmini için makine öğrenmesi ve yapay zekâ tabanlı çalışmalardan birinde Han ve ark. [22], kentsel raylı ulaşımda enerji ve maliyet azaltımı için hat-bazlı enerji katkılarını inceleyen kapsamlı bir makine öğrenmesi çerçevesi önermişlerdir. Hat-bazlı işletim ve tren hareketi değişkenleriyle enerji–tren hareketi, yolculuk talebi ve hava koşulları ilişkilerini daha iyi açıklayan ve Boston ağında saatlik düzeyde hat katkısı analizi yapılmasını sağlayan bir model göstermişlerdir. Tang ve ark. [23], kentsel raylı sistemlerde toplam tüketim, cer gücü ve istasyon soğutma gibi alt kalemleri kapsayacak şekilde elektrik tüketimini tahmin etmek için iki farklı regresyon tabanlı model geliştirmişlerdir. Ayrıca, çekirdek tabanlı yaklaşımın daha başarılı olduğunu ve özellikle

iklimlendirme tüketiminde dış sıcaklık ile işletme göstergeleri dışındaki etmenlerin de kritik olduğunu vurgulamışlardır. Chen ve Lin [24], Çin kentsel raylı sistem işletmelerinde enerji tüketimi etmenlerini cer ve cer-dışı bileşenlere ayıran, aşağıdan-yukarı bir çerçeveyle ölçeğe göre gösterge seçimi yapıp tahmin modelleri kurmuşlardır. Ayrıca, seçilen plan göstergeleri ile enerji tüketimi arasında belirgin bir doğrusal ilişki kurulduğunu ve yaklaşımın doğru tahmin, kaynak tahsisi ve karbon muhasebesi çalışmalarını desteklediğini belirtmişlerdir. Wang ve Rakha [25], anlık rejeneratif frenleme verimini dikkate alan bir elektrikli tren enerji tüketimi modelleme çerçevesi geliştirmişlerdir. Ayrıca, rejeneratif frenleme veriminin yavaşlama düzeyine bağlı değiştiğini ve yaklaşımın proje düzeyinde araç–hat–işletim koşullarına bağlı tüketim farklarını yakalayabildiğini Portland ve Chicago verileriyle göstermişlerdir. Ma ve ark. [26], elektrikli demiryollarında çok kısa vadeli cer yükünü tahmin etmek için dalgacık temelli ayrıştırma ile derin zaman serisi modeli ve çekirdek tabanlı regresyonu birleştiren karma bir kestirim yaklaşımı önermişlerdir. Hou ve ark. [27], kentsel raylı ulaşımda kısa vadeli yolcu akışını tahmin etmek için birleşik bir derin öğrenme modeli önermişlerdir.

Enerji tüketimi tahmininin yanı sıra, sefer planı optimizasyonu yoluyla enerji verimliliğinin artırılması ve karbon emisyonlarının azaltılması da literatürde yaygın olarak ele alınan konular arasındadır. Wu ve ark. [28], rüzgâr enerjisi tüketimini de dikkate alarak kentsel demiryolu sistemlerinde işletim kaynaklı karbon emisyonlarını azaltmayı hedefleyen bir zaman çizelgesi optimizasyon çerçevesi önermişlerdir. Deng ve ark. [29], yolcu talebi ve işletim planı kısıtları altında çekiş enerjisini azaltma ve rejeneratif fren enerjisini eşzamanlı değerlendirme odaklı bütünleşik bir zaman çizelgesi optimizasyon çerçevesi önermişlerdir. Ayrıca, Guangzhou Metro Hat 8 örneğinde optimize çizelgenin rejeneratif enerjinin kullanımını artırıp toplam enerji tüketimini düşürebildiğini göstermişlerdir. Zhong ve ark. [30], talep dalgalanmalarına duyarlı ve esnek tren dizilimi modunu içeren bir zaman çizelgesi optimizasyonu ile yolcu bekleme süresi ve enerji tüketimini birlikte azaltmayı hedefleyen bir yaklaşım sunmuşlardır. Li ve ark. [31], özellikle uzun ve dik eğimlere sahip dağlık demiryolu hatlarında cer gücü dalgalanmalarını bastırmaya yönelik tren zaman çizelgesi optimizasyonunu ele almışlardır. He ve ark. [32], çoklu sinyal önceliği stratejileri altında tramvay sistemleri için enerji-etkin tren zaman çizelgesi optimizasyonunu incelemişlerdir.

Ayrıca derin pekiştirmeli öğrenme gibi gelişmiş yapay zekâ teknikleri, tren hız profillerinin optimizasyonu, çoklu tren koordinasyonu ve enerji tasarruflu operasyon stratejilerinin geliştirilmesinde de uygulanmaktadır. Wang ve ark. [33], kentsel raylı sistemlerde enerji tasarruflu işletim için hız profilini optimize eden ve enerji tüketimi ile konfor–dakiklik–güvenlik hedeflerini birlikte dengeleyen pekiştirmeli öğrenme tabanlı bir yaklaşım önermişlerdir. Dong ve ark. [34], kentsel raylı ulaşımda çoklu tren için enerji tasarruflu kontrolü hedefleyen işbirlikçi bir optimizasyon yöntemini ele almışlardır.

Raylı ulaşım sistemlerinde enerji verimliliği ve yapay zekâ uygulamalarına ilişkin kapsamlı derleme çalışmaları, bu alandaki mevcut durumu ve gelecek yönelimleri ortaya koymaktadır. Aroso ve Bugarín [35], demiryolu hatlarında enerji verimliliğinin iyileştirilmesine yönelik yaklaşımları genel bir bakışla özetlemişlerdir. Pappaterra ve ark. [36], demiryolu uygulamaları için yapay zekâya yönelik açık veri kümelerini sistematik biçimde derlemişlerdir.

Bu çalışmalar bir bütün olarak değerlendirildiğinde, enerji tüketimi ve karbon emisyonu tahminlerinde hem bina içi hem de kentsel/ulaşım bağlamında veri odaklı ve derin öğrenme temelli yaklaşımların giderek ön plana çıktığı, ayrıca topluluk (ensemble) ve meta-öğrenme yöntemlerinin sınırlı veri koşullarında tahmin performansını iyileştirebildiği görülmektedir. Model seçiminde veri miktarı, öznitelik çeşitliliği, tahmin periyodu ve uygulama alanı gibi faktörlerin kritik rol oynadığı literatürde sıkça vurgulanmaktadır.

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Veri Seti Tanımı ve Ön İşleme

Bu çalışmada kullanılan veri seti, Türkiye'nin Kayseri ilinde faaliyet gösteren Kayseri Ulaşım A.Ş.'den temin edilmiştir. Veri seti, beş dağıtım trafo merkezine ait aylık enerji tüketimi değerlerinden oluşmaktadır. Söz konusu dağıtım merkezleri, raylı sistem trafo merkezlerini beslemekte ve tramvay hatlarına enerji sağlamaktadır. Veri seti, Ocak 2016–Kasım 2025 dönemini kapsayan 10 yıllık bir zaman aralığında toplam 119 aylık gözlem içermektedir. Ayrıca, bu beş trafo merkezine ait toplam karbon ayak izi verileri Ocak 2019–Kasım 2025 döneminde 83 ay boyunca elde edilmiştir. Son yıllarda şehirde güneş panelleri ve rüzgâr türbinleri gibi yenilenebilir enerji kaynaklarının entegrasyonu, raylı ulaşım için enerji tedarikinde kayda değer ilerlemeler sağlamıştır. Şekil 2.1, kentsel raylı ulaşım sistemindeki enerji akışını ve karbon ayak izi hesaplama sürecini şematik olarak göstermektedir. Bu şema, dağıtım merkezlerinden raylı sistem trafo merkezlerine ve buradan tramvaylara aktarılan enerji akışını ve buna bağlı olarak oluşan karbon emisyonlarını görselleştirmektedir.

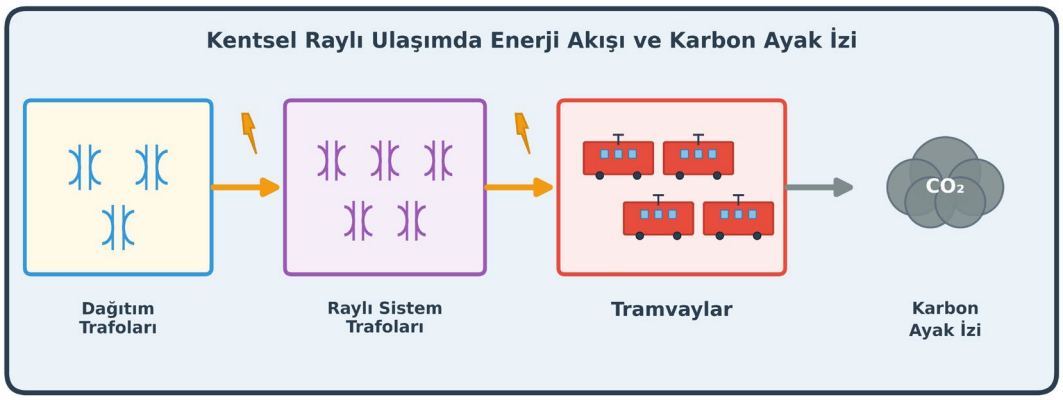

Şekil 2.1. Kentsel raylı ulaşım sisteminde enerji akışı ve karbon ayak izi şeması

Veri setinde, kesinti (arıza/bakım) dönemlerinden kaynaklanan eksik değerler bulunmaktadır. Bu eksik değerlerin tamamlanması için Seasonal K-NN (Mevsimsel K-En Yakın Komşu) yöntemi kullanılmıştır [37, 38]. K-NN tabanlı tamamlama algoritması, eksik değere sahip bir gözlem için en yakın k komşuyu belirler ve eksik girdiyi bu komşulara ait karşılık gelen değerlerin ortalamasıyla tahmin eder. Öklid uzaklığı kullanılarak iki gözlem arasındaki mesafe Denklem 2.1'de verildiği şekilde hesaplanır.

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^{p} (x_{ik} - x_{jk})^2} \tag{2.1}$$

Burada x_{ik} ve x_{jk}, sırasıyla x_i ve x_j örneklerinin k. özelliğini; p ise özellik sayısını ifade etmektedir. Seasonal K-NN yönteminde, komşuluk hesabında yalnızca aynı mevsime veya aynı aya ait gözlemler dikkate alınır. Bu sayede enerji tüketimindeki mevsimsel örüntüler korunur. Şekil 2.2'de beş trafo için aylara göre enerji tüketim dağılımı görülmektedir. Çalışma yapıldığı sırada 2025 Aralık verileri henüz olmadığı için Şekil 2.2'deki grafiğin son barı 9 yılın (2025 Aralık dahil değil) toplamlarından oluşmaktadır.

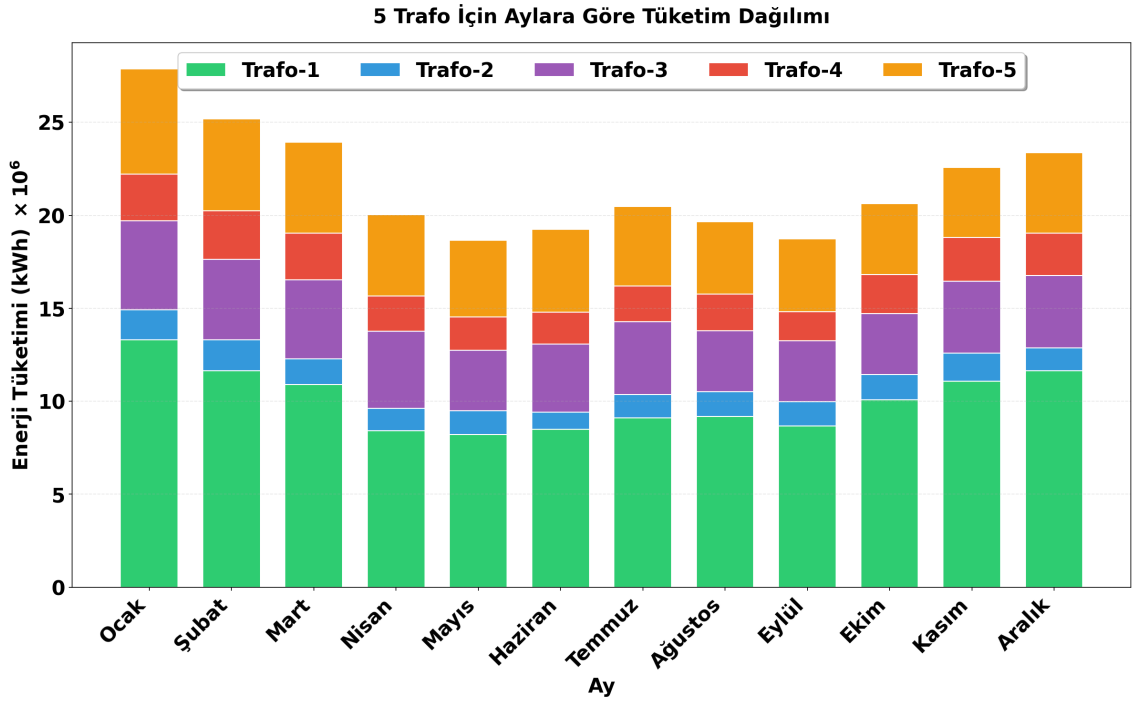

Şekil 2.2. Beş trafo için aylara göre tüketim dağılımı

Şekil 2.3'te de beş trafo merkezinin enerji tüketimi ve karbon ayak izi zaman serileri ile eğitim–test ayrımı görülmektedir. Veri seti zaman sırası bozulmadan kronolojik olarak %80 eğitim ve %20 test olacak şekilde ayrılmıştır.

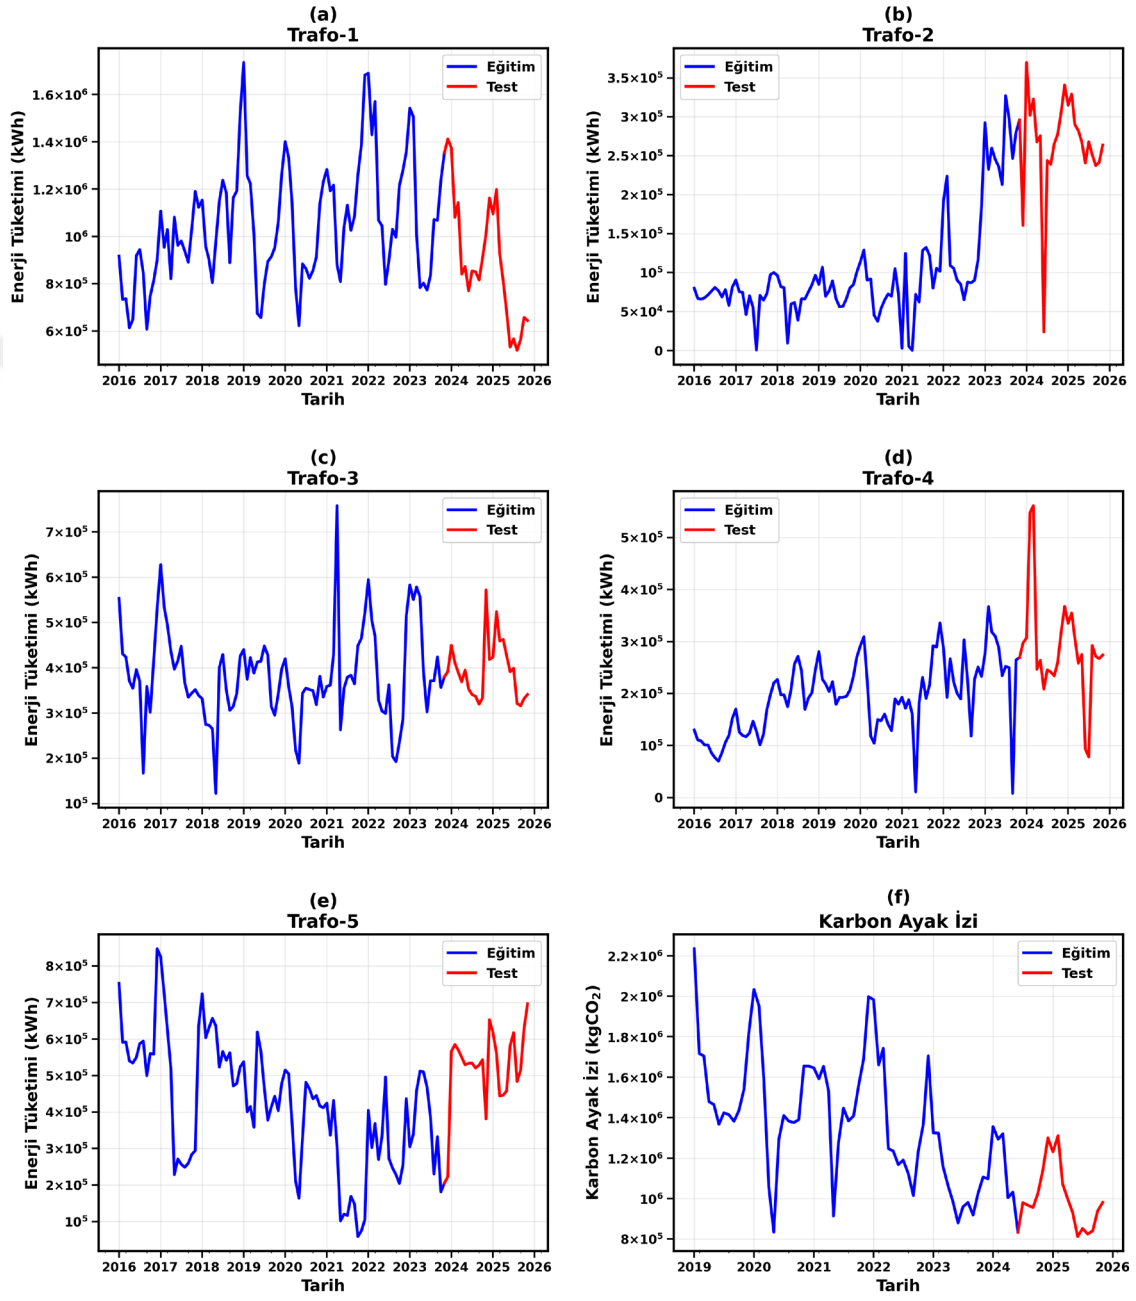

Şekil 2.3. Beş trafo merkezinin enerji tüketimi ve karbon ayak izi zaman serileri ile eğitim–test ayrımı

Şekil 2.3'te görüldüğü üzere, tüm trafo merkezlerinde belirgin mevsimsel desenler gözlenmektedir. Karbon ayak izi verileri ise, beş trafo merkezinin toplam enerji tüketiminin emisyon faktörü ile çarpılması yoluyla hesaplanmıştır.

2.1.1. Karbon Ayak İzi ($kgCO_2$) Hesaplama Yöntemi

Bu çalışmada kentsel raylı ulaşım sisteminin karbon ayak izi, elektrik enerjisi tüketimine bağlı olarak hesaplanmıştır. Karbon ayak izi değerlendirmesinde, sistemin elektrik tüketimi sonucu atmosfere salınan karbondioksit miktarını ifade eden toplam karbon emisyonu ($kgCO_2$) metriği kullanılmıştır. Yolcu sayısı ve yolcu-kilometre verilerinin mevcut olmaması nedeniyle, emisyon değerleri birim taşımaya normalize edilmemiştir.

Karbon ayak izi hesabında, elektrik şebekesine ait emisyon faktörü kullanılmıştır. Emisyon faktörü, elektrik enerjisinin üretimi sırasında birim enerji başına atmosfere salınan ortalama karbondioksit miktarını temsil etmekte olup $kgCO_2/kWh$ birimi ile ifade edilmektedir. Bu kapsamda, toplam karbondioksit salımı, tüketilen elektrik enerjisi ile emisyon faktörünün çarpılması yoluyla ($CO_{2toplam} = E \times EF$) hesaplanmıştır. Burada; $CO_{2toplam}$, toplam karbon dioksit salımı ($kgCO_2$), E toplam elektrik enerjisi tüketimi (kWh) ve EF Elektrik şebekesine ait emisyon faktörünü ($kgCO_2/kWh$) ifade etmektedir. Bu yaklaşım sayesinde, enerji tüketimi tahminleri kullanılarak farklı makine öğrenmesi modellerinin karbon ayak izi öngörü performansları karşılaştırılabilmiştir.

2.2. Makine Öğrenmesi Yöntemleri

2.2.1. Destek Vektör Regresyonu (Support Vector Regression – SVR)

SVR, Vapnik tarafından geliştirilen ve yapısal risk minimizasyonu ilkesine dayanan bir regresyon yöntemidir [39]. SVR, ε-duyarsız kayıp fonksiyonunu kullanır; yani belirli bir tolerans aralığı içinde kalan tahmin hataları cezalandırılmaz. SVR'nin temel amacı, Denklem 2.2'de verilen en uygun fonksiyonu elde etmektir.

$$f(x) = w^{\top}\varphi(x) + b \tag{2.2}$$

Burada w ağırlık vektörünü, $\varphi(x)$ girdi uzayını yüksek boyutlu bir özellik uzayına dönüştüren eşleme fonksiyonunu ve b ise sapma (*bias*) terimini ifade eder. SVR için optimizasyon problemi Denklem 2.3'te verilmiştir.

$$min\left\{\frac{1}{2}\|w\|^2 + C\sum_{i=1}^{N}(\xi_i + \xi_i^*)\right\} \quad (2.3)$$

Burada C düzenlileştirme (regularizasyon) parametresi, N eğitim örneği sayısı, ξ_i ve ξ_i^* ise gevşeklik (*slack*) değişkenleridir. Bu çalışmada, Denklem 2.4'te tanımlanan Radyal Tabanlı Fonksiyon (Radial Basis Function – RBF) çekirdeği kullanılmıştır.

$$K(x_i, x_j) = exp\left(-\gamma\|x_i - x_j\|^2\right) \quad (2.4)$$

Burada γ çekirdek genişliği parametresini ifade etmektedir.

2.2.2. Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBoost)

XGBoost, Chen ve Guestrin tarafından geliştirilen bir topluluk (ensemble) öğrenme algoritmasıdır [40]. Algoritma, zayıf öğrenicileri (karar ağaçlarını) ardışıl olarak birleştirir; her yeni ağaç, önceki modelin yaptığı hataları azaltacak şekilde eğitilerek toplam tahmin performansı iyileştirilir. Amaç fonksiyonu Denklem 2.5'te verilmiştir.

$$L(\phi) = \sum_{i=1}^{N} l(y_i, \hat{y}_i) + \sum_{k=1}^{K} \Omega(f_k) \quad (2.5)$$

Burada $l(\mathrm{y}_i, \hat{y}_i)$ kayıp (*loss*) fonksiyonunu, N eğitim örneği sayısını, K ağaç sayısını ve $\Omega(f_k)$ ise düzenlileştirme terimini ifade eder. Düzenlileştirme terimi Denklem 2.6'da tanımlanmıştır.

$$\Omega(f) = \gamma T + \frac{1}{2}\lambda\sum_{j=1}^{T} w_j^2 \quad (2.6)$$

Burada T yaprak düğüm sayısını, w_j yaprak ağırlıklarını; γ ve λ ise düzenlileştirme parametrelerini göstermektedir.

2.2.3. Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM)

LSTM, kaybolan gradyan problemini gidermek amacıyla Hochreiter ve Schmidhuber tarafından geliştirilen özel bir tekrarlayan sinir ağı mimarisidir [41]. Bir LSTM hücresi

üç kapıdan oluşur: unutma kapısı (f_t), giriş kapısı (i_t) ve çıkış kapısı (o_t). Kapı denklemleri Denklem 2.7-2.9'da verilmiştir.

$$f_t = \sigma\big(W_f \cdot [h_{t-1}, x_t] + b_f\big) \tag{2.7}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2.8}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{2.9}$$

Burada σ sigmoid fonksiyonunu, W ağırlık matrislerini, h gizli durumu, x girdi vektörünü ve b ise sapma (*bias*) vektörlerini ifade eder. Hücre durumu ve gizli durum güncellemeleri Denklem 2.10 ve 2.11'de verildiği gibidir.

$$C_t = f_t \odot C_{t-1} + i_t \odot tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{2.10}$$

$$h_t = o_t \odot tanh(C_t) \tag{2.11}$$

Burada $\odot$, Hadamard (eleman bazlı) çarpımı göstermektedir. Bu çalışmada, dropout düzenlileştirmesi içeren iki katmanlı bir LSTM mimarisi kullanılmıştır [42].

2.2.4. Uyarlamalı Sinirsel-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System – ANFIS)

ANFIS, yapay sinir ağları ile bulanık mantık sistemlerini birleştiren ve Jang tarafından önerilen hibrit bir modeldir [43]. ANFIS, Takagi–Sugeno tipinde bir bulanık çıkarım sistemi kullanır ve beş katmandan oluşur. Üyelik fonksiyonu Denklem 2.12'de verilmiştir.

$$\mu_i(x) = \frac{1}{1 + \left|\frac{x - c_i}{a_i}\right|^{2b_i}} \tag{2.12}$$

Burada c_i merkez, a_i genişlik ve b_i ise eğim parametresidir. Normalize edilmiş ateşleme şiddeti ile nihai çıktı Denklem 2.13 ve 2.14'te verildiği gibidir.

$$\overline{w}_i = \frac{w_i}{\sum_{j=1}^{M} w_j} \tag{2.13}$$

$$f = \sum_{i=1}^{M} \overline{w}_i \left(\sum_{k=1}^{d} p_{ik}\, x_k + r_i \right) \tag{2.14}$$

2.2.5. Doğrusal Olmayan Otoregresif Sinir Ağı (Nonlinear Autoregressive Neural Network – NAR-NN)

NAR-NN, zaman serisi tahmini için kullanılan ileri beslemeli bir sinir ağı mimarisidir [44]. Model, geçmiş gözlemleri kullanarak gelecekteki değerleri öngörür ve matematiksel gösterimi Denklem 2.15'te verilmiştir:

$$y_t = F(y_{t-1}, y_{t-2}, \ldots, y_{t-d}) + \varepsilon_t \tag{2.15}$$

Burada d gecikme sayısını (lookback), $F(\cdot)$ doğrusal olmayan eşleme fonksiyonunu ve ε_t hata terimini ifade eder. Bu çalışmada, Adam optimizasyon algoritması [45] ile erken durdurma (*early stopping*) stratejisi kullanılmıştır.

2.3. Hiperparametre Ayarı

Her bir model için hiperparametre optimizasyonu Rastgele Arama (Random Search) algoritması kullanılarak gerçekleştirilmiştir. Rastgele Arama, en uygun yapılandırmayı belirlemek amacıyla hiperparametre uzayını rastgele örnekler çekerek tarar. Bergstra ve Bengio [46], bu yaklaşımın Izgara Arama'ya (Grid Search) kıyasla daha verimli olabileceğini göstermiştir. Bu çalışmada, her bir model–seri çifti için 20 iterasyon yürütülmüş ve en iyi hiperparametreler doğrulama kümesi üzerindeki RMSE değerine göre seçilmiştir. Tablo 2.1'de, beş model için kullanılan hiperparametreler ve arama uzayları ile karbon ayak izi veri seti için seçilen en uygun değerler sunulmuştur. Altı zaman serisi (beş trafo ve karbon ayak izi) için hazırlanan tüm modellerin optimize edilmiş hiperparametreleri de tablo olarak Ek 1'de verilmiştir.

Tablo 2.1 incelendiğinde, SVR modeli için dört hiperparametrenin (C, ε, γ, *kernel*) optimize edildiği görülmektedir. XGBoost için dokuz hiperparametre optimize edilmiştir; boosting ağaç sayısının 91 ve maksimum ağaç derinliğinin 3 olması, görece sığ ağaçların tercih edildiğine işaret etmektedir. LSTM modelinde birinci LSTM katmanındaki nöron sayısı 17, ikinci LSTM katmanındaki nöron sayısı 4 olarak belirlenmiş; dropout oranı 0.4486 ve lookback (girdi dizi uzunluğu) değeri 4 ay seçilmiştir. ANFIS için en uygun

üyelik fonksiyonu sayısı 3 olarak bulunmuştur. NAR-NN için ise 17 gizli katman nöronu, tek gizli katman ve *tanh* aktivasyon fonksiyonu en iyi performansı sağlamıştır.

Tablo 2.1. Tahmin modelleri için hiperparametreler ve arama aralığı

Model	Parametre	Arama Aralığı	Seçilen	Açıklama
SVR	C	[0.1, 100]	1.9762	Düzenlileştirme parametresi
	ε (epsilon)	[0.01, 0.5]	0.0312	Epsilon-tüp genişliği
	γ (gamma)	[0.001, 1.0]	0.0685	Çekirdek katsayısı
	kernel	{rbf, poly, sigmoid}	rbf	Çekirdek fonksiyonu türü
XGBoost	n_estimators	[30, 200]	91	Güçlendirme ağaç sayısı
	max_depth	[2, 5]	3	Maksimum ağaç derinliği
	learning_rate	[0.05, 0.3]	0.1857	Güçlendirme öğrenme oranı
	subsample	[0.7, 1.0]	0.7423	Satır örnekleme oranı
	colsample_bytree	[0.7, 1.0]	0.9407	Sütun örnekleme oranı
	min_child_weight	[3, 10]	4	Minimum çocuk ağırlığı
	gamma	[0.1, 0.5]	0.4948	Minimum kayıp azalımı
	reg_alpha	[0.1, 1]	0.7950	L1 düzenlileştirme
	reg_lambda	[0.1, 1]	0.2788	L2 düzenlileştirme
LSTM	units_1	[8, 32]	17	1. LSTM katman nöronları
	units_2	[0, 16]	4	2. LSTM katman nöronları
	dropout	[0.2, 0.5]	0.4486	Dropout (Seyreltme) oranı
	learning_rate	[0.001, 0.01]	0.00227	Adam öğrenme oranı
	batch_size	[8, 16]	8	Eğitim batch (yığın) boyutu
	lookback	[2, 6]	4	Girdi dizisi uzunluğu (ay)
ANFIS	n_mfs	[2, 4]	3	Üyelik fonksiyonu sayısı
	learning_rate	[0.01, 0.1]	0.0196	Eğitim öğrenme oranı
	lookback	[2, 6]	4	Girdi dizisi uzunluğu (ay)
NAR-NN	hidden_units	[5, 20]	17	Gizli katman nöron sayısı
	n_layers	[1, 2]	1	Gizli katman sayısı
	activation	{relu, tanh, sigmoid}	tanh	Aktivasyon fonksiyonu
	learning_rate	[0.01, 0.1]	0.0391	Eğitim öğrenme oranı
	lookback	[2, 6]	2	Girdi dizisi uzunluğu (ay)

2.4. Performans Metrikleri

Bu çalışmada kullanılan performans metrikleri; ortalama karesel hatanın karekökü olan RMSE (Root Mean Squared Error), mutlak hataların ortalamasını veren MAE (Mean Absolute Error), ortalama mutlak yüzde sapmayı raporlayan MAPE (Mean Absolute Percentage Error) ve tahminlerin açıkladığı varyans oranını gösteren R^2 (Coefficient of Determination)'dir. Bu metriklerin matematiksel tanımları Denklem 2.16-2.19'da verilmiştir.

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\|\mathrm{e}_i\|^2} \tag{2.16}$$

$$\mathrm{MAE} = \frac{1}{N}\sum_{i=1}^{N}\|\mathrm{e}_i\| \tag{2.17}$$

$$\mathrm{MAPE} = \frac{100}{N}\sum_{i=1}^{N}\left\|\frac{\mathrm{e}_i}{\mathrm{r}_i}\right\| \tag{2.18}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N}\|y_i - r_i\|^2}{\sum_{i=1}^{N}\|r_i - \bar{r}\|^2} \tag{2.19}$$

Denklemlerde N örnek sayısını, $e_i = r_i - y_i$ $i.$ örnekteki hatayı, r_i referans değeri, y_i tahmin edilen değeri ve $\bar{r}$ referans değerlerin ortalamasını ifade eder. $\|\cdot\|$ Öklid normunu göstermektedir.

3. BÖLÜM

TAHMİN ÇALIŞMALARI

3.1. Deneysel Çalışmalar

Tez çalışmasında, beş farklı makine öğrenmesi modeli tasarlanmış ve beş trafo merkezinin enerji tüketimi ile toplam karbon ayak izi için ileriye dönük tahmin performansları değerlendirilmiştir. Tahmin deneyleri, hiperparametre ayarı sonucunda elde edilen en uygun parametreler kullanılarak gerçekleştirilmiştir. SVR ve XGBoost gibi deterministik modeller için tek bir çalıştırma yapılırken, stokastik davranışı daha iyi karakterize etmek amacıyla sinir ağı tabanlı modeller (LSTM, ANFIS ve NAR-NN) için 10 bağımsız çalıştırma gerçekleştirilmiştir. Tablo 3.1'de tüm modellerin performans metrikleri (RMSE, MAE, MAPE ve R^2) sunulmaktadır. Stokastik modeller için metrikler ortalama $\pm$ standart sapma biçiminde raporlanmış; köşeli parantez içinde $[min, max]$ değerleri ayrıca verilmiştir. Çalışmada kullanılan kod Python ile yazılmış olup, Windows 10 (64-bit) işletim sistemi, Intel Core i7-7700HQ CPU @ 2.80GHz işlemci ve 16 GB RAM'e sahip bir bilgisayarda yürütülmüştür.

Tablo 3.1'deki sonuçlar incelendiğinde, SVR modelinin tüm veri setlerinde en yüksek performansı sergilediği görülmektedir. Beş trafo veri setinin tamamında SVR, her istasyonda en yüksek R^2 değerlerine ulaşarak (0.896–0.993 aralığında) tutarlı bir üstünlük göstermiştir. XGBoost, Trafo-1 ($R^2 = 0.925$) ve Trafo-5 ($R^2 = 0.825$) için iyi performans sergilese de Trafo-2 ($R^2 = 0.254$) ve Trafo-4 ($R^2 = 0.499$) için görece düşük kalmıştır. Sinir ağı tabanlı modellerin performansı ise çoğu istasyonda zayıftır; özellikle Trafo-2 ve Trafo-5 için LSTM, ANFIS ve NAR-NN modelleri negatif R^2 değerleri üretmiş, bu da söz konusu modellerin referans ortalaması yaklaşımından daha kötü sonuç verdiğini göstermektedir. En iyi tahminlerin, mevsimsellik desenleri daha

düzenli olan Trafo-1 ve Trafo-3'te elde edildiği; en zor tahminlerin ise varyansı yüksek olan Trafo-2'de ortaya çıktığı gözlenmiştir.

Tablo 3.1. Model performans metriklerinin karşılaştırılması

Zaman Serisi	Model	RMSE	MAE	MAPE	R^2
Trafo-1	**SVR**	**21599.48**	**17662.95**	**2.33**	**0.9925**
	XGBoost	68299.08	50895.30	7.25	0.9254
	LSTM	155191.60 ± 11436.16 [138025.37, 170070.82]	135673.58 ± 11586.49 [114312.54, 149836.81]	18.18 ± 1.77 [15.00, 20.33]	0.6126 ± 0.0567 [0.5372, 0.6952]
	ANFIS	209438.81 ± 63972.16 [157263.01, 310265.45]	176343.84 ± 56124.21 [133731.33, 264501.84]	24.46 ± 8.00 [17.94, 37.08]	0.2327 ± 0.4840 [-0.5402, 0.6043]
	NAR-NN	157985.13 ± 28459.15 [116653.59, 202780.03]	135148.81 ± 24940.76 [98305.49, 173593.29]	17.80 ± 3.98 [11.98, 23.97]	0.5877 ± 0.1463 [0.3421, 0.7823]
Trafo-2	**SVR**	**16865.56**	**11560.38**	**14.30**	**0.9339**
	XGBoost	56641.67	35641.17	44.93	0.2543
	LSTM	79534.98 ± 875.60 [78241.21, 80977.70]	52568.16 ± 1237.46 [50675.46, 54225.54]	61.91 ± 2.54 [58.49, 65.29]	-0.4706 ± 0.0324 [-0.5242, -0.4229]
	ANFIS	98435.09 ± 38844.81 [73507.97, 176563.45]	78505.43 ± 46488.22 [44804.84, 170444.80]	60.08 ± 6.56 [55.63, 73.25]	-1.6030 ± 2.2854 [-6.2463, -0.2560]
	NAR-NN	91594.20 ± 8872.72 [78487.76, 105433.78]	75760.94 ± 14072.37 [50409.93, 96917.79]	59.75 ± 1.59 [57.12, 62.56]	-0.9684 ± 0.3815 [-1.5839, -0.4319]
Trafo-3	**SVR**	**8262.74**	**6178.73**	**1.46**	**0.9835**
	XGBoost	31913.56	22434.98	5.43	0.7533
	LSTM	58542.59 ± 1122.29 [57410.18, 60551.14]	37234.43 ± 318.04 [36550.83, 37588.60]	8.66 ± 0.18 [8.36, 8.87]	0.1694 ± 0.0321 [0.1118, 0.2015]
	ANFIS	65135.65 ± 6644.51 [58414.13, 82150.90]	46170.16 ± 7842.64 [35946.46, 56964.77]	10.95 ± 1.97 [8.27, 12.92]	-0.0385 ± 0.2249 [-0.6350, 0.1734]
	NAR-NN	69564.57 ± 12615.23 [58477.52, 102970.07]	51671.38 ± 15398.50 [40400.17, 96979.43]	12.66 ± 4.59 [9.28, 26.26]	-0.2109 ± 0.4925 [-1.5687, 0.1716]
Trafo-4	**SVR**	**33346.45**	**22771.74**	**9.43**	**0.8963**
	XGBoost	73261.88	42046.45	14.92	0.4993
	LSTM	100030.24 ± 3147.34 [96440.70, 106937.19]	76155.37 ± 3888.11 [72626.71, 84118.12]	31.31 ± 0.80 [30.43, 32.95]	0.0655 ± 0.0598 [-0.0669, 0.1323]
	ANFIS	136129.45 ± 10809.75 [117779.85, 154636.97]	106819.06 ± 13769.74 [82376.38, 129388.28]	39.57 ± 3.52 [33.48, 45.44]	-0.7398 ± 0.2747 [-1.2310, -0.2942]
	NAR-NN	97974.43 ± 7127.85 [90328.29, 113004.48]	72900.80 ± 10556.17 [61336.33, 92456.26]	30.52 ± 2.03 [28.33, 34.31]	0.0997 ± 0.1344 [-0.1914, 0.2388]
Trafo-5	**SVR**	**19454.83**	**14990.49**	**2.67**	**0.9579**
	XGBoost	39697.80	30124.83	5.79	0.8249
	LSTM	114885.11 ± 4519.64 [105424.16, 121603.17]	88280.44 ± 5563.59 [75818.18, 95184.05]	16.22 ± 0.91 [14.19, 17.36]	-0.4688 ± 0.1140 [-0.6430, -0.2349]
	ANFIS	118577.12 ± 22955.94 [94469.65, 171229.28]	88801.44 ± 26098.44 [62359.06, 144884.41]	16.17 ± 4.46 [11.87, 25.74]	-0.6208 ± 0.6756 [-2.2577, 0.0084]
	NAR-NN	126552.50 ± 25121.28 [95403.72, 175977.97]	105205.63 ± 28547.49 [69915.27, 161802.63]	19.80 ± 4.90 [14.08, 30.23]	-0.8496 ± 0.7394 [-2.4409, -0.0113]
Karbon Ayak İzi	**SVR**	**36453.30**	**32957.69**	**3.51**	**0.9420**
	XGBoost	89872.04	63528.38	6.71	0.6478
	LSTM	155814.77 ± 11389.00 [136773.98, 179909.05]	135883.70 ± 10731.47 [118432.45, 159547.63]	14.45 ± 1.18 [12.51, 17.01]	-0.0644 ± 0.1568 [-0.4115, 0.1842]
	ANFIS	211620.99 ± 87646.75 [131336.01, 376235.93]	189984.87 ± 82757.54 [114000.12, 344417.14]	20.22 ± 8.96 [11.84, 36.94]	-1.2880 ± 1.9896 [-5.1732, 0.2478]
	NAR-NN	130322.23 ± 24819.48 [103474.85, 169522.05]	112519.97 ± 23610.53 [86281.51, 149907.69]	11.73 ± 2.68 [8.70, 15.95]	0.2325 ± 0.2961 [-0.2533, 0.5331]

Karbon ayak izi tahmininde de SVR, RMSE = 36453.30, MAE = 32957.69, MAPE = %3.51 ve $R^2 = 0.942$ ile en iyi sonuçları sağlamıştır. XGBoost ikinci sırada yer alırken ($R^2 = 0.648$), LSTM ($R^2 = -0.064$), ANFIS ($R^2 = -1.288$) ve NAR-NN ($R^2 = 0.232$) modellerinin performansı yetersiz kalmıştır.

3.2. Isı Haritaları

Şekil 3.1-3.4'te sırasıyla RMSE, MAE, MAPE ve R^2 ısı haritaları verilerek model performansları görsel olarak karşılaştırılmıştır.

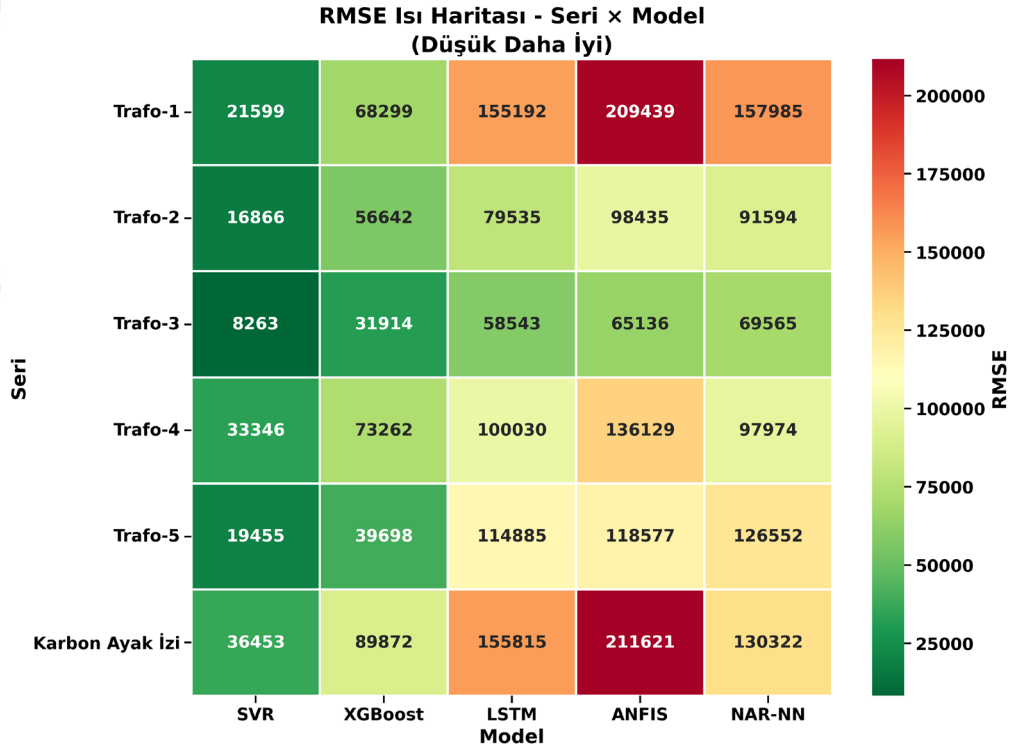

Şekil 3.1. Model ve zaman serisine göre RMSE ısı haritası

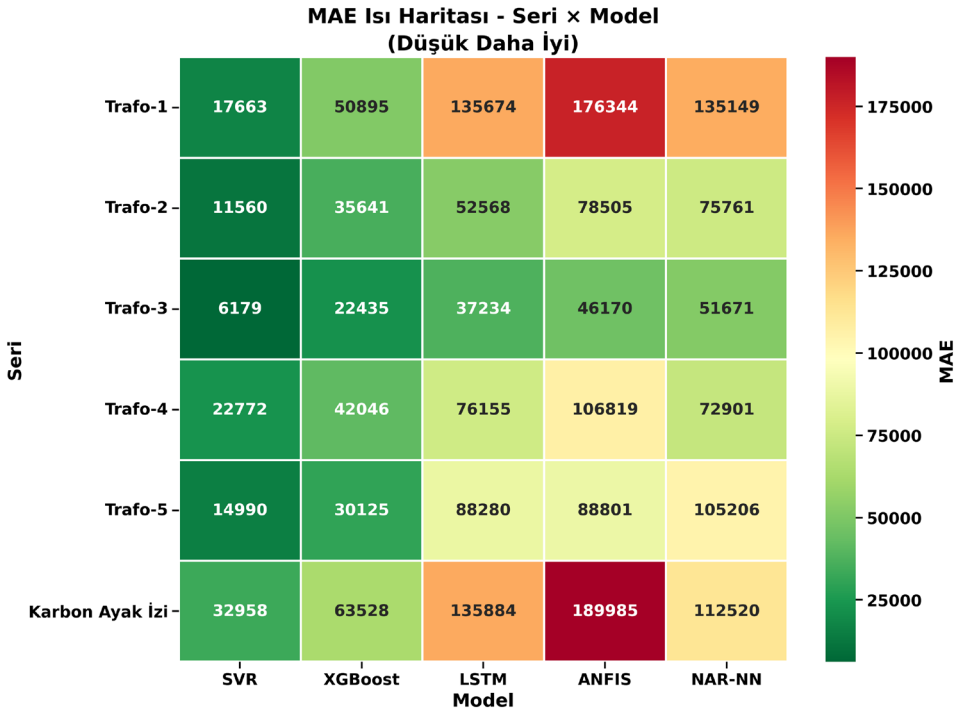

Şekil 3.2. Model ve zaman serisine göre MAE ısı haritası

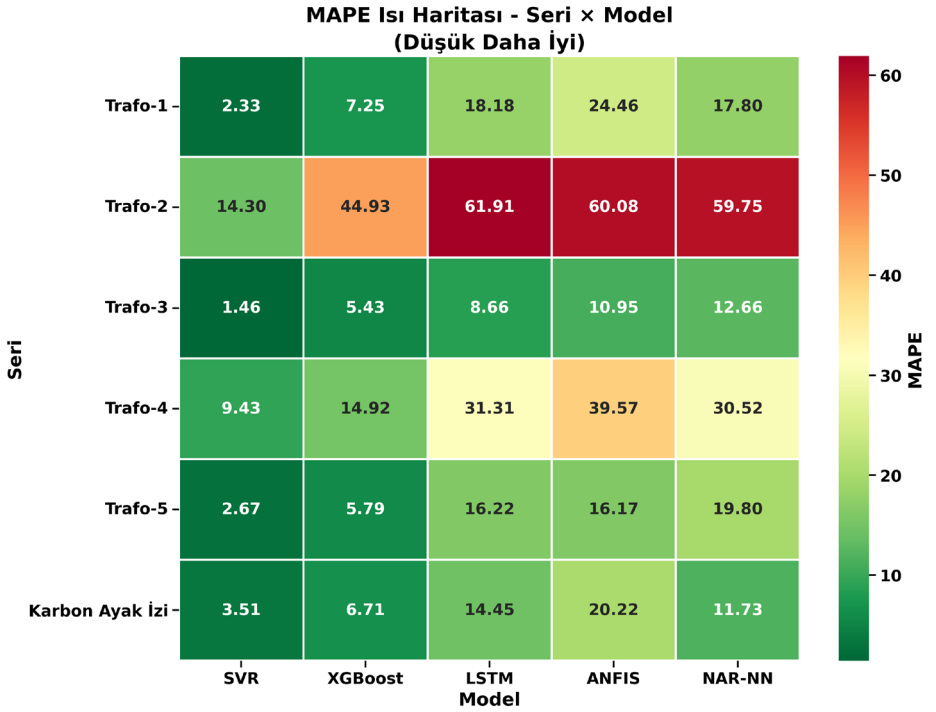

Şekil 3.3. Model ve zaman serisine göre MAPE ısı haritası

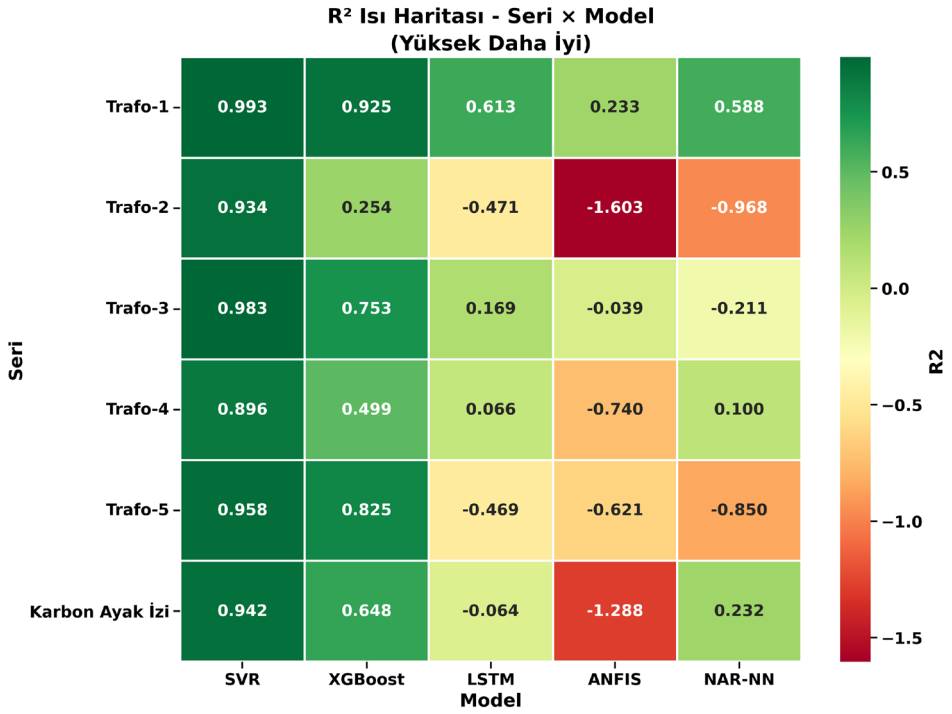

Şekil 3.4. Model ve zaman serisine göre R^2 ısı haritası.

Şekil 3.1'deki RMSE ısı haritası incelendiğinde, SVR modelinin tüm seriler için en düşük RMSE değerlerini verdiği görülmektedir. Bu ısı haritasında RMSE değerinin düşük olması daha yüksek performansa karşılık gelmektedir. Yeşil tonlar düşük hatayı, kırmızı tonlar ise yüksek hatayı temsil etmekte olup, SVR sütunu tüm seriler boyunca tutarlı biçimde koyu yeşil kalmaktadır. XGBoost sütunu yeşilden açık yeşile doğru geçiş göstermekte; bu durum orta düzey hata seviyelerine işaret etmektedir. LSTM, ANFIS ve NAR-NN sütunlarının ise ağırlıklı olarak turuncu ve kırmızı tonlarda yoğunlaşması, bu modellerin tahmin hatalarının yüksek olduğunu görsel olarak ortaya koymaktadır. Karbon ayak izi satırında da benzer biçimde SVR ve XGBoost yeşil tonlarda kalırken, diğer üç model kırmızı bölgede yer almaktadır.

Şekil 3.2'de yer alan MAE ısı haritası incelendiğinde, SVR modelinin tüm seriler için en düşük ortalama mutlak hata değerlerini verdiği görülmektedir. Bu durum, SVR modelinin tahminlerinin gözlemlenen değerlere olan mutlak sapmasının diğer modellere kıyasla daha az olduğunu göstermektedir. XGBoost modeli, SVR'den sonra en iyi performansı sergilemekte olup, yeşil tonlardan açık yeşil tonlara doğru hafif bir geçiş göstermektedir; bu da orta seviyede bir tahmin hatasına işaret etmektedir. LSTM, ANFIS ve NAR-NN modelleri ise ağırlıklı olarak açık yeşil, sarı ve turuncu tonlarda yer almakta, dolayısıyla

bu modellerin mutlak hata değerlerinin daha yüksek olduğu görsel olarak ortaya konmaktadır. Karbon ayak izi serisinde de benzer bir durum söz konusu olup, SVR ve XGBoost modelleri düşük MAE değerleriyle öne çıkarken diğer modeller nispeten yüksek hatalar göstermektedir.

Şekil 3.3'teki MAPE ısı haritası ise modellerin göreceli tahmin başarısını yüzdelik hata oranlarıyla ortaya koymaktadır. SVR modeli, tüm serilerde en düşük MAPE değerleriyle yüksek bir göreceli doğruluk sergilemektedir ve genellikle koyu yeşil tonlarla temsil edilmektedir. XGBoost modeli ise bazı serilerde SVR'ye yakın performans gösterse de özellikle Trafo-2 serisinde daha yüksek yüzde hata oranlarıyla turuncu tonlarda görünmektedir. LSTM, ANFIS ve NAR-NN modellerinin ise genel olarak yüksek MAPE değerleri nedeniyle açık yeşil, sarı ve kırmızı tonlarda yoğunlaştığı, dolayısıyla göreceli tahmin hatalarının önemli ölçüde daha fazla olduğu dikkat çekmektedir. Bu durum, özellikle sınırlı veri setiyle gerçekleştirilen tahminlerde, deterministik modellerin (SVR ve XGBoost) sinir ağı tabanlı stokastik modellere göre daha güvenilir olduğunu desteklemektedir.

Şekil 3.4'teki R^2 ısı haritası, model performanslarının seri bazında değişimini daha net göstermektedir. R^2 değerinin 1'e yaklaşması yüksek performansı ifade eder. SVR modeli tüm serilerde 0.896–0.993 aralığında R^2 değerleri elde ederek koyu yeşil tonlarla üstün bir performans sergilemiştir. XGBoost, Trafo-1 ($R^2 = 0.925$) ve Trafo-5 ($R^2 = 0.825$) için yeşil tonlarda görünürken, Trafo-2 ve Trafo-4'te daha açık yeşil bölgeye kaymaktadır. Sinir ağı tabanlı modeller için ısı haritası çarpıcı bir tablo sunmaktadır: LSTM, ANFIS ve NAR-NN sütunları çoğunlukla turuncu, kırmızı ve koyu kırmızı tonlardadır; bu durum sıfıra yakın ya da negatif R^2 değerlerini yansıtmaktadır. Isı haritasında negatif R^2 değerleri daha koyu kırmızı tonlarla temsil edilmiştir. Bu görsel karşılaştırma, 119 aylık gözlemden oluşan sınırlı veri setinde deterministik modellerin (SVR ve XGBoost), sinir ağı tabanlı stokastik modellere kıyasla daha iyi performans gösterdiğini ortaya koymaktadır.

3.3. Zaman Serisi Bazında Tahmin ve Hata Grafikleri

Şekil 3.5–3.10'da her bir trafo ve karbon ayak izinin test verisi için gerçek değerler ile model tahminlerinin karşılaştırmaları ve ayrıca tahmin hatalarının zaman serisi grafikleri sunulmuştur.

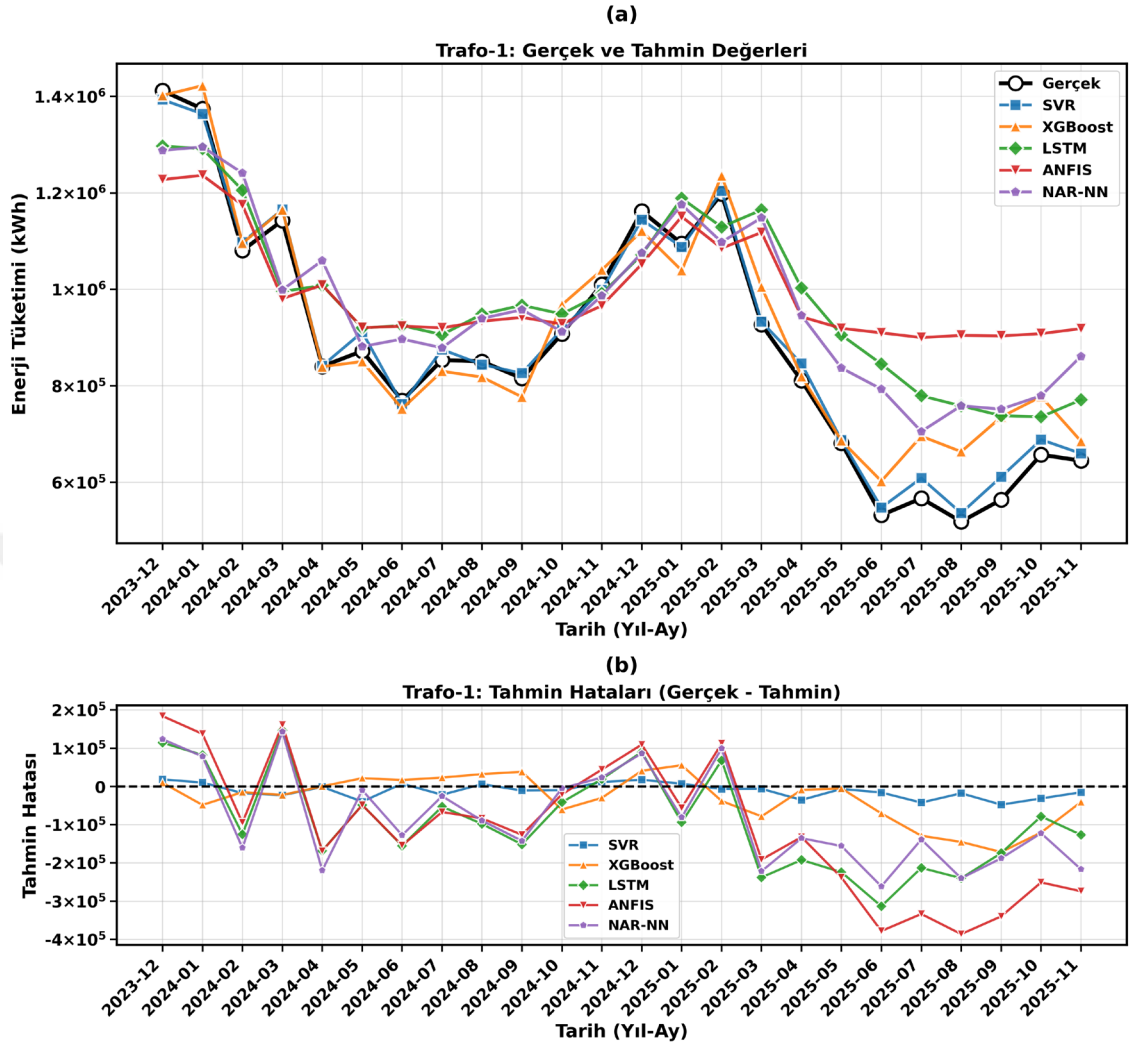

Şekil 3.5. Trafo-1: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.5 (Trafo-1) incelendiğinde, SVR tahminlerinin gerçek değerleri yakından takip ettiği görülmektedir. Bu istasyonda mevsimsellik düzenli olduğundan, XGBoost tahminleri de kabul edilebilir düzeyde kalmaktadır. LSTM ve NAR-NN genel eğilimi yakalasa da tepe noktalarda sapma göstermektedir. Buna karşılık ANFIS'in performansı zamanla belirgin biçimde düşmekte, özellikle 2025 ilkbaharı sonrasında sapmalar artmaktadır. Hata grafiğinde SVR hataları ±50.000 kWh bandının oldukça altında kalırken, ANFIS hatalarının 400.000 kWh seviyelerine kadar çıktığı görülmektedir.

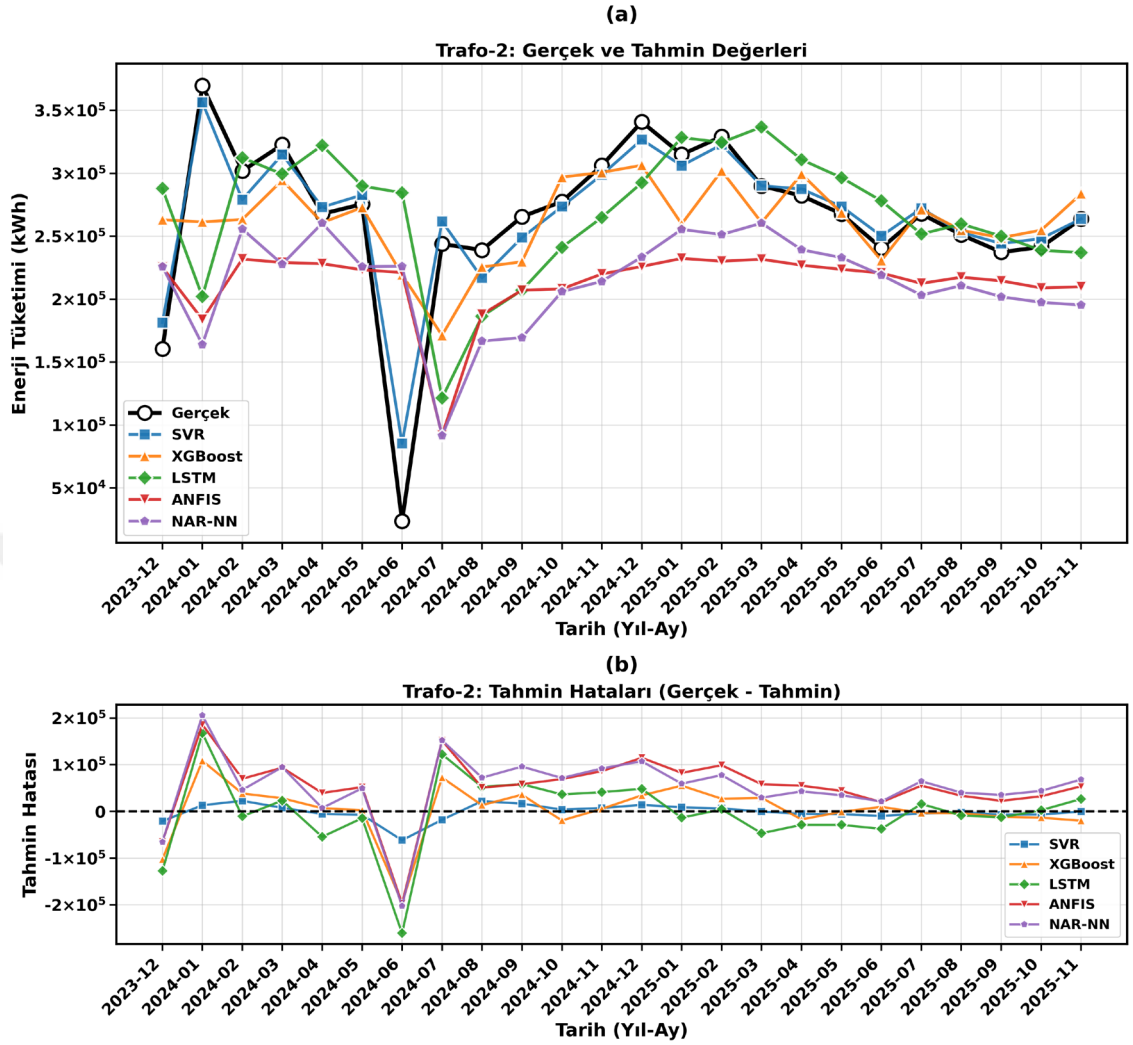

Şekil 3.6. Trafo-2: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.6 (Trafo-2), en zor tahmin senaryosunu temsil etmektedir. Yüksek varyans ve düzensiz tüketim örüntüleri nedeniyle yalnızca SVR modeli gerçek değerleri yeterli doğrulukla izleyebilmektedir. XGBoost bazı dönemlerde kabul edilebilir performans gösterse de ani dalgalanmaları yakalamakta yetersiz kalmaktadır. LSTM, ANFIS ve NAR-NN ise gerçek değerlerden belirgin biçimde ayrışmaktadır; özellikle ANFIS ve NAR-NN için 2024 sonbaharı sonrasında tahminlerin neredeyse yataylaştığı dikkat çekmektedir. Hata grafiğinde sinir ağı tabanlı modeller, ±150.000 kWh bandını aşan sistematik hatalar üretmektedir.

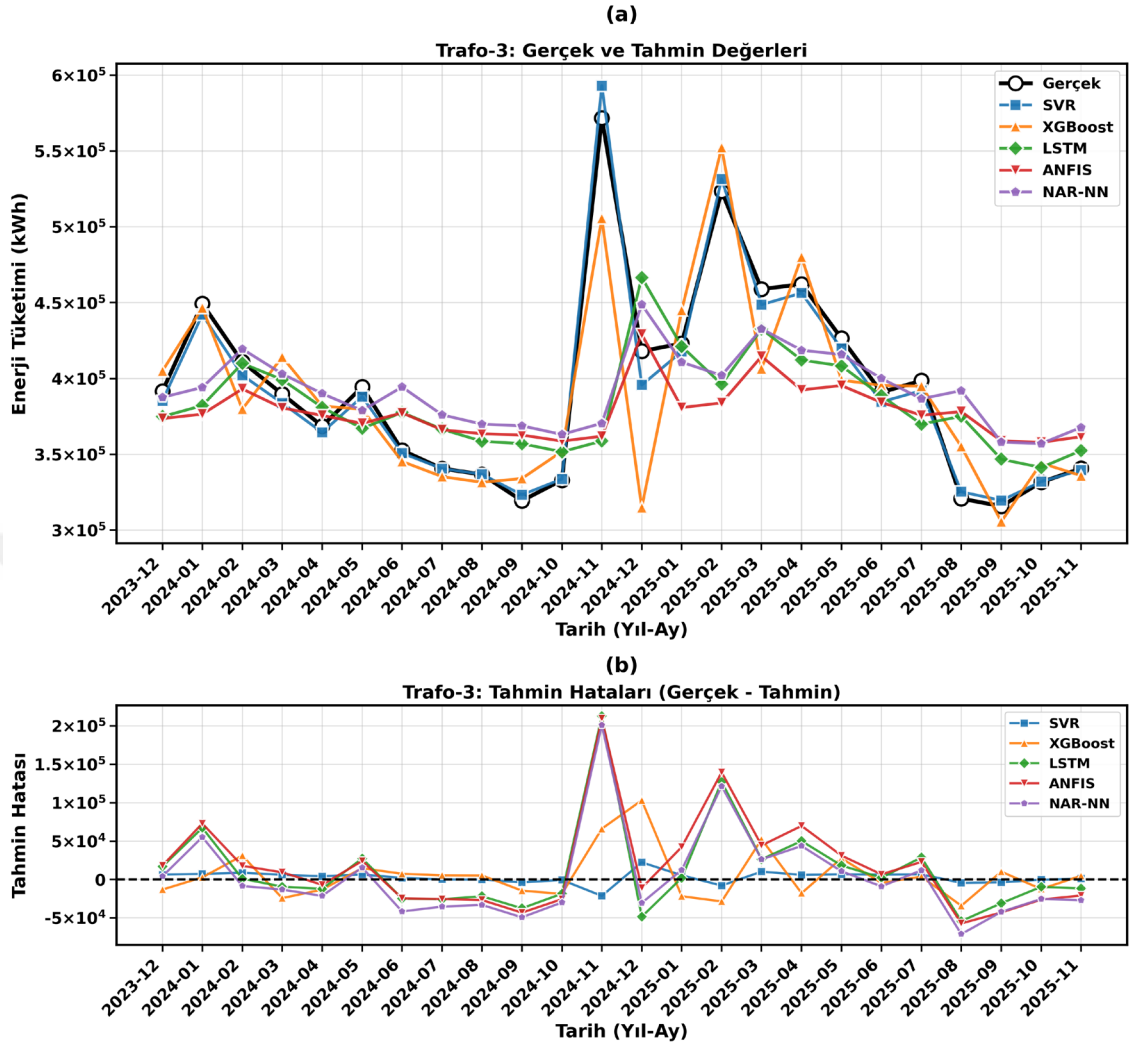

Şekil 3.7. Trafo-3: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.7'de (Trafo-3) SVR modeli bu istasyonda en düşük MAPE değerine ulaşmakta (%1.46) ve tahmin eğrisi neredeyse gerçek değerlerle çakışmaktadır. XGBoost mevsimsel paterni yakalamakla birlikte genliği düşük tahmin ederek dalgalanmanın büyüklüğünü küçümsemektedir. LSTM genel eğilimi izlese de tepe dönemlerinde düşük kalmakta; ANFIS ve NAR-NN ise özellikle yüksek tüketim aralıklarında belirgin sapmalar göstermektedir. Hata grafiğinde SVR hataları dar bir bantta kalırken, diğer modellerin hataları 200.000 kWh seviyelerine kadar çıkabilmektedir.

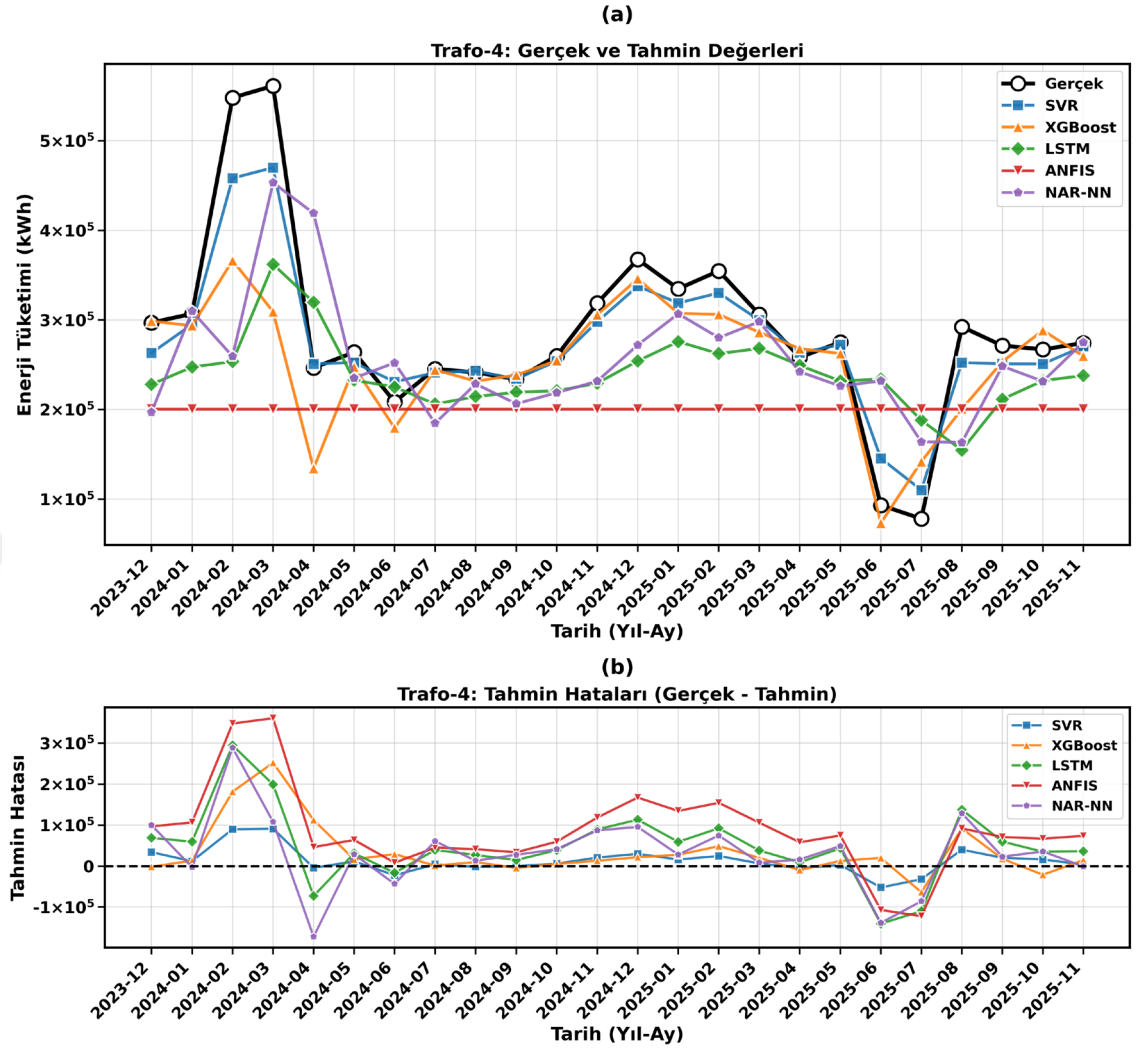

Şekil 3.8. Trafo-4: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.8 (Trafo-4) incelendiğinde, SVR hem ani artışları hem de ani düşüşleri başarılı biçimde yakalamaktadır. XGBoost genel eğilimi izlese de uç (ekstrem) değerlerde yetersiz kalmaktadır. Bu istasyonda NAR-NN'nin LSTM'ye kıyasla görece daha iyi performans verdiği görülse de her iki model de tepe noktalarında belirgin sapmalar göstermektedir. ANFIS tahminleri ise gerçek değerlerin oldukça altında kalmakta ve mevsimsel dalgalanmaları yakalayamamaktadır. Hata grafiğinde ANFIS'in 300.000 kWh seviyelerine ulaşan hatalarla oldukça zayıf performans sergilediği görülmektedir.

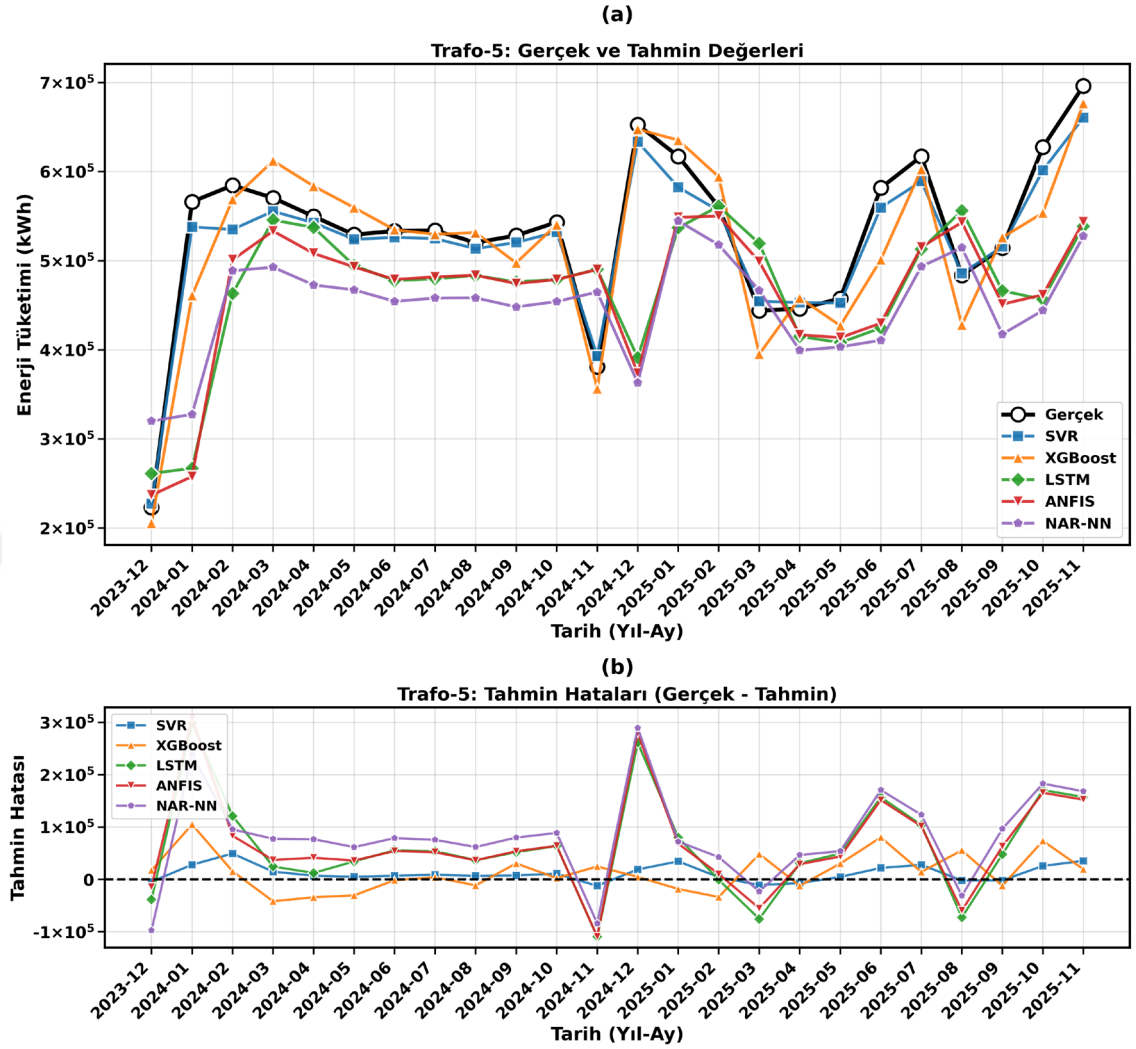

Şekil 3.9. Trafo-5: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.9'da (Trafo-5) SVR ve XGBoost modelleri mevsimsel paterni başarıyla yakalamaktadır. SVR tahminleri tüm dönem boyunca gerçek değerlere yakın seyrederken, XGBoost özellikle 2025 yılındaki tepe noktalarında küçük sapmalar göstermektedir. Buna karşılık LSTM, ANFIS ve NAR-NN bu istasyonda başarısız kalmakta; tahminler gerçek değerlerin belirgin biçimde altında seyretmektedir. Bu durum, negatif R^2 değerleriyle doğrudan uyumludur (LSTM: -0.469, ANFIS: -0.621, NAR-NN: -0.850). Hata grafiği, sinir ağı tabanlı modellerin sistematik olarak eksik tahmin (underestimation) yaptığını göstermektedir.

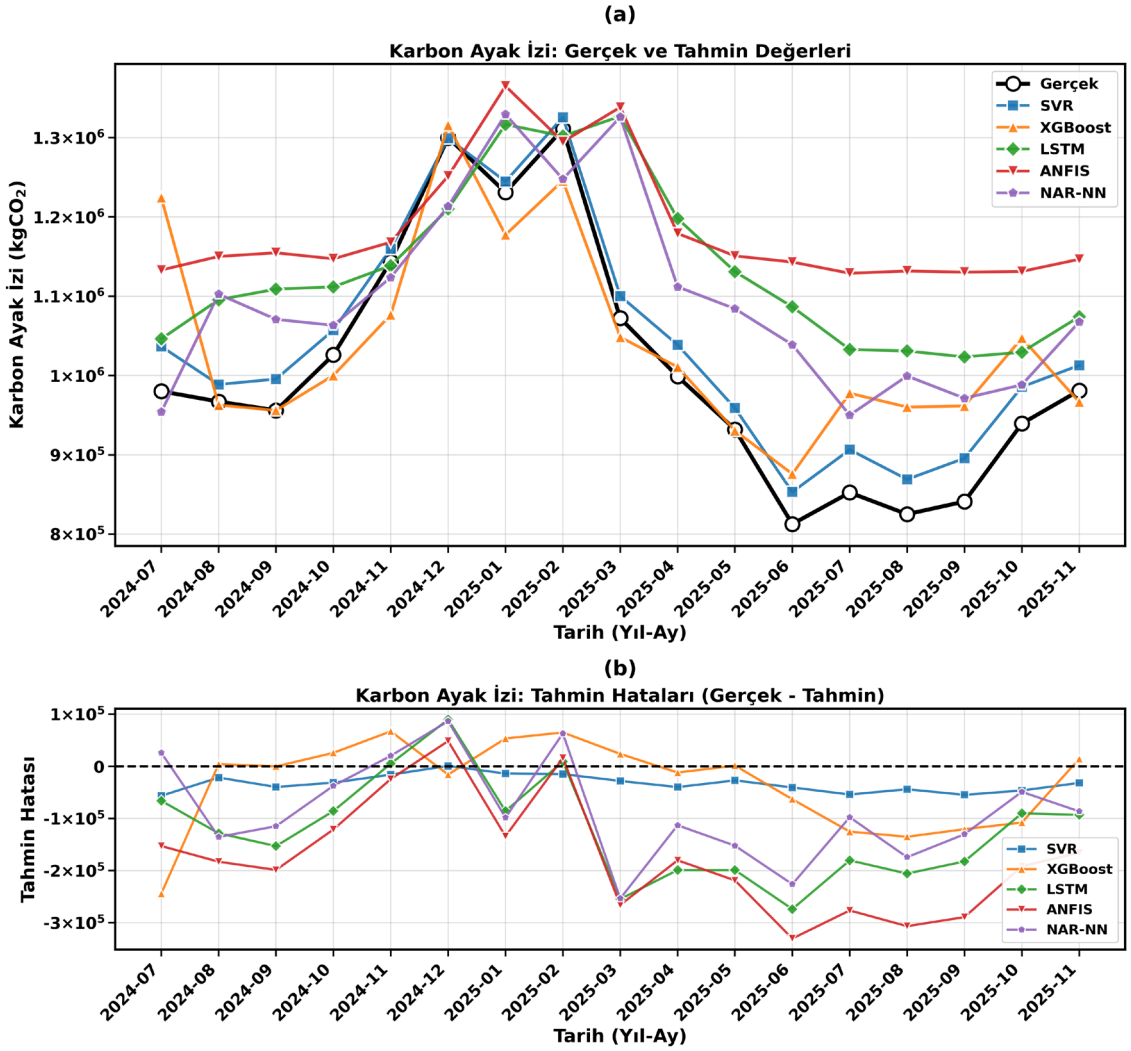

Şekil 3.10. Karbon Ayak İzi: (a) Gerçek zaman serisi ve tahmin grafikleri, (b) Tahmin hata grafikleri

Şekil 3.10, beş trafonun toplam enerji tüketiminden hesaplanan karbon ayak izi tahminlerini göstermektedir. SVR modeli toplam karbon ayak izindeki mevsimsel dalgalanmaları başarılı biçimde tahmin etmekte ve MAPE değeri %3.51 düzeyinde kalmaktadır. XGBoost genel eğilimi yakalasa da tahminleri daha dalgalı olup bazı aralıklarda aşırı tahmin, bazı aralıklarda eksik tahmin üretebilmektedir. NAR-NN sınırlı bir başarı gösterirken ($R^2 = 0.232$), LSTM ve özellikle ANFIS en zayıf performansı sergilemekte; tahminler gerçek değerlerden belirgin biçimde uzaklaşmaktadır. Hata grafiğinde SVR hataları 100.000 $kgCO_2$'nin oldukça altında kalırken, ANFIS hatalarının 300.000 $kgCO_2$ seviyelerine çıktığı ve ciddi sapmalar oluştuğu görülmektedir.

Genel olarak tüm şekiller birlikte değerlendirildiğinde, SVR tahminleri gerçek değerlere en yakın sonuçları üretmiş, XGBoost çoğu seri için genel olarak kabul edilebilir düzeyde kalmış, sinir ağı tabanlı LSTM, ANFIS ve NAR-NN modelleri ise özellikle ani değişimlerde ve mevsimsel tepe noktalarında büyük sapmalar göstermiştir. Tahmin hatası grafiklerinde SVR hataları çoğunlukla sıfır çizgisi etrafında daha simetrik ve düşük genlikte seyrederken, sinir ağı tabanlı modellerin daha büyük genlikli ve süreğen hatalar ürettiği anlaşılmaktadır.

3.4. Model Bazında Tahmin ve Dağılım Grafikleri

3.4.1. SVR Tahmin ve Dağılım Grafikleri

Şekil 3.11-3.16'da her bir trafo ve karbon ayak izi için gerçek enerji tüketimi değerleri ile SVR modelinin tahmin değerlerinin karşılaştırılması ve tahminlerin dağılım grafikleri (scatter plot) sunulmuştur.

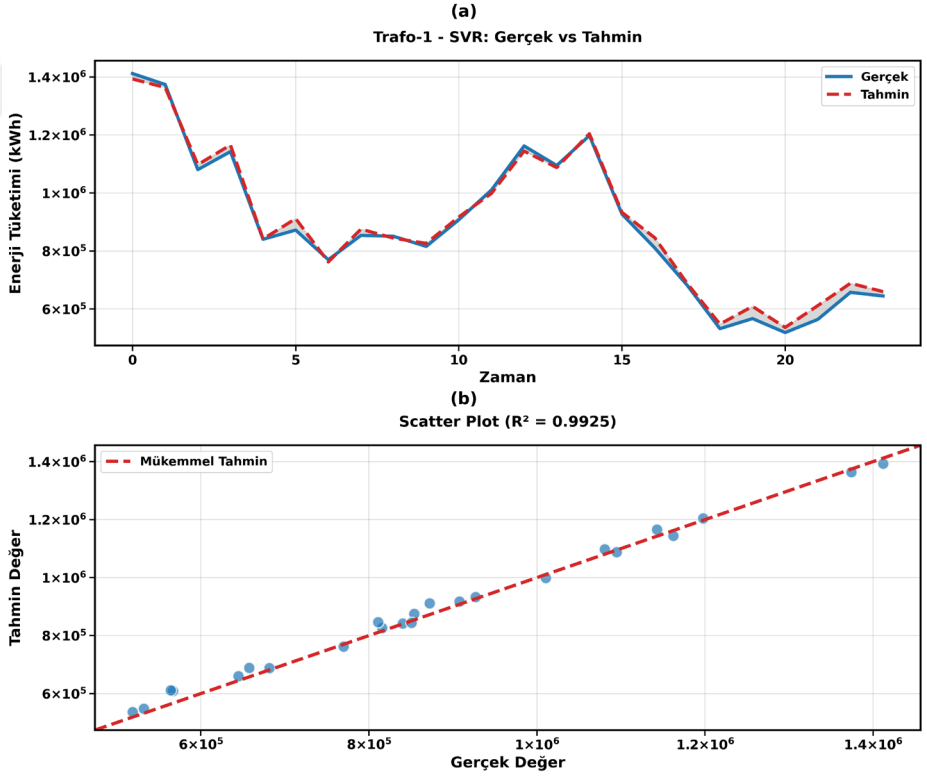

Şekil 3.11. Trafo-1 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

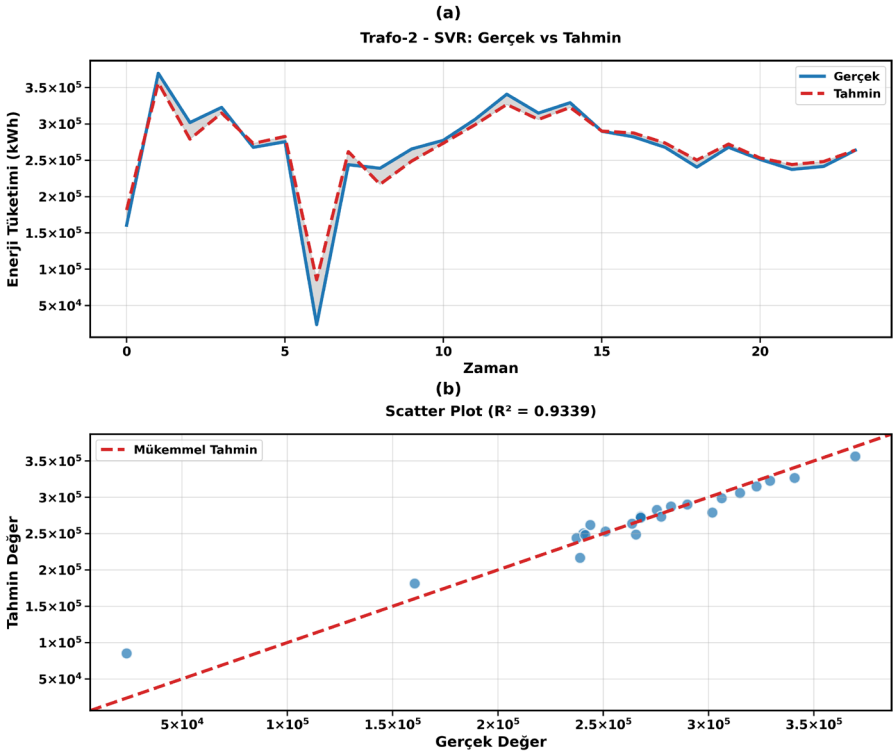

Şekil 3.12. Trafo-2 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

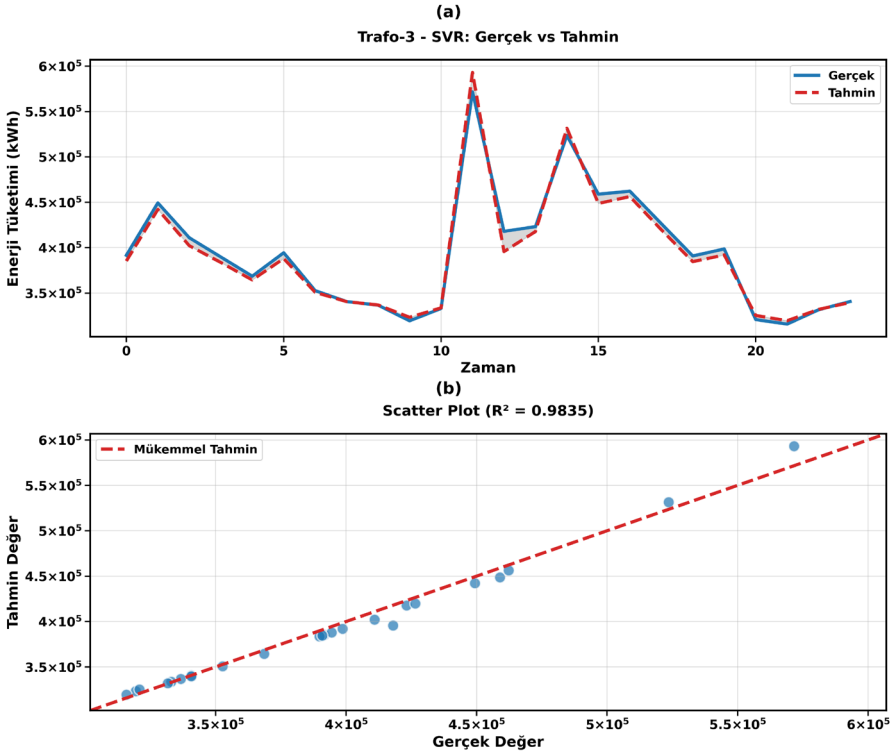

Şekil 3.13. Trafo-3 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

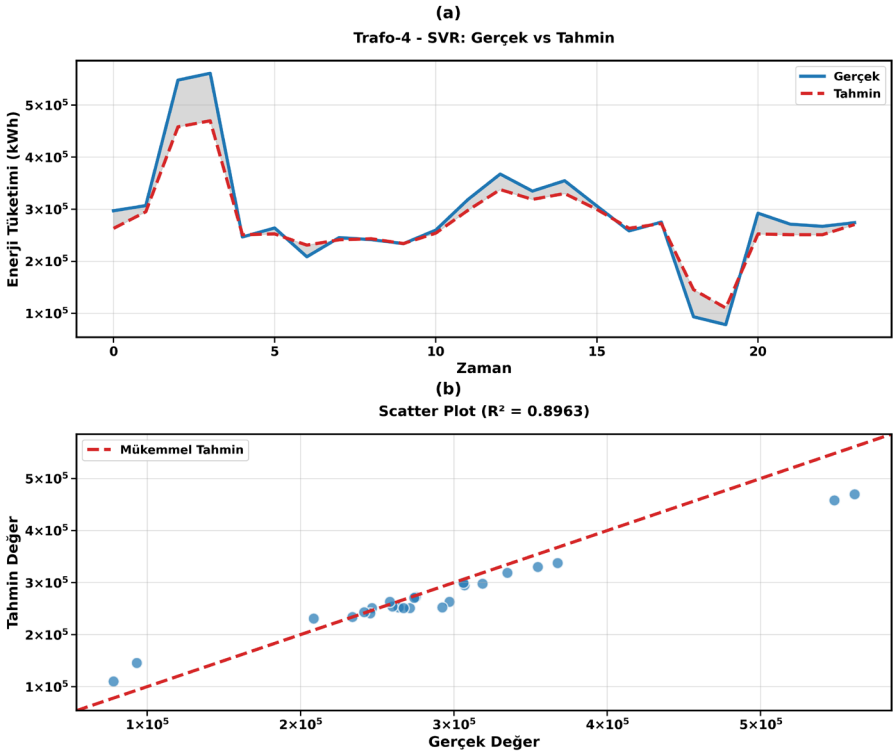

Şekil 3.14. Trafo-4 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

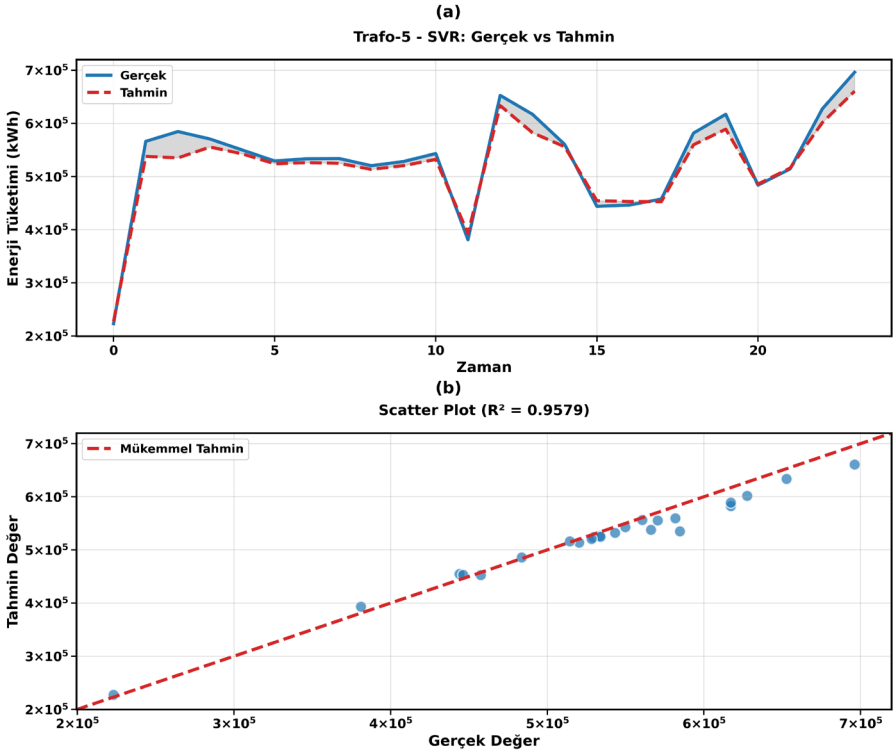

Şekil 3.15. Trafo-5 için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

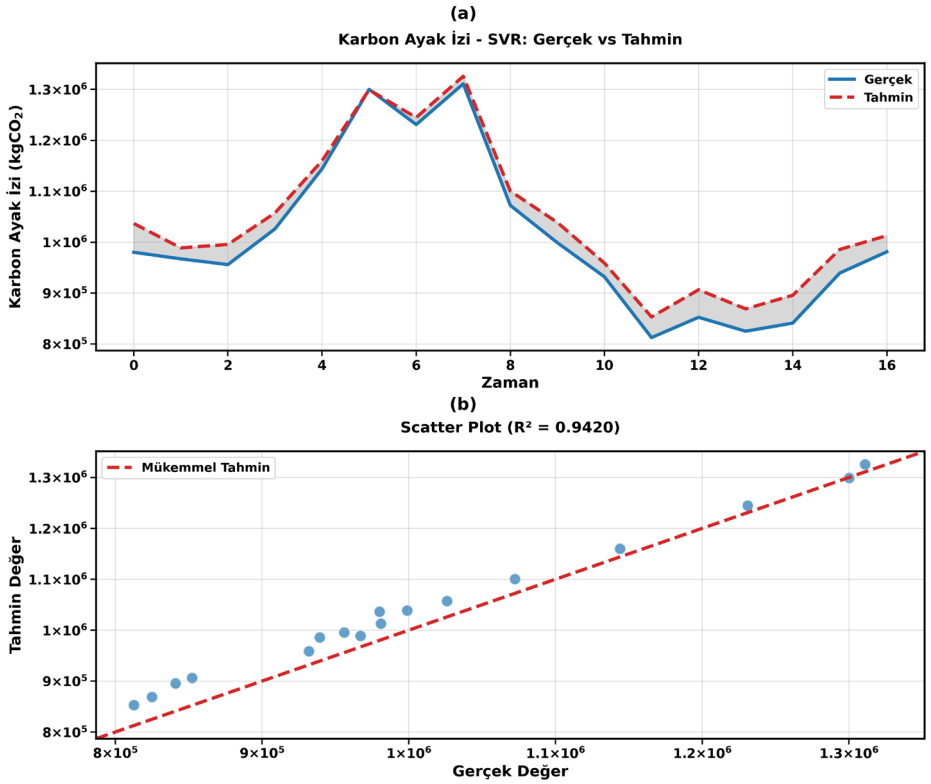

Şekil 3.16. Karbon ayak izi için SVR modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

Grafikler, SVR modelinin tahminlerinin gerçek değerlere oldukça yakın olduğunu, grafikler arasında oluşan taralı alanların oldukça dar olduğunu ve yüksek R^2 değerleri ile güçlü bir uyum sağladığını göstermektedir. Bu sonuçlar, SVR modelinin veri setindeki trendleri ve değişimleri başarıyla yakalayarak güvenilir tahminler ürettiğini doğrulamaktadır.

3.4.2. XGBoost Tahmin ve Dağılım Grafikleri

Şekil 3.17-3.22'de XGBoost modelinin enerji tüketimi tahminleri gerçek verilerle karşılaştırılmış ve dağılım grafikleri ile birlikte sunulmuştur.

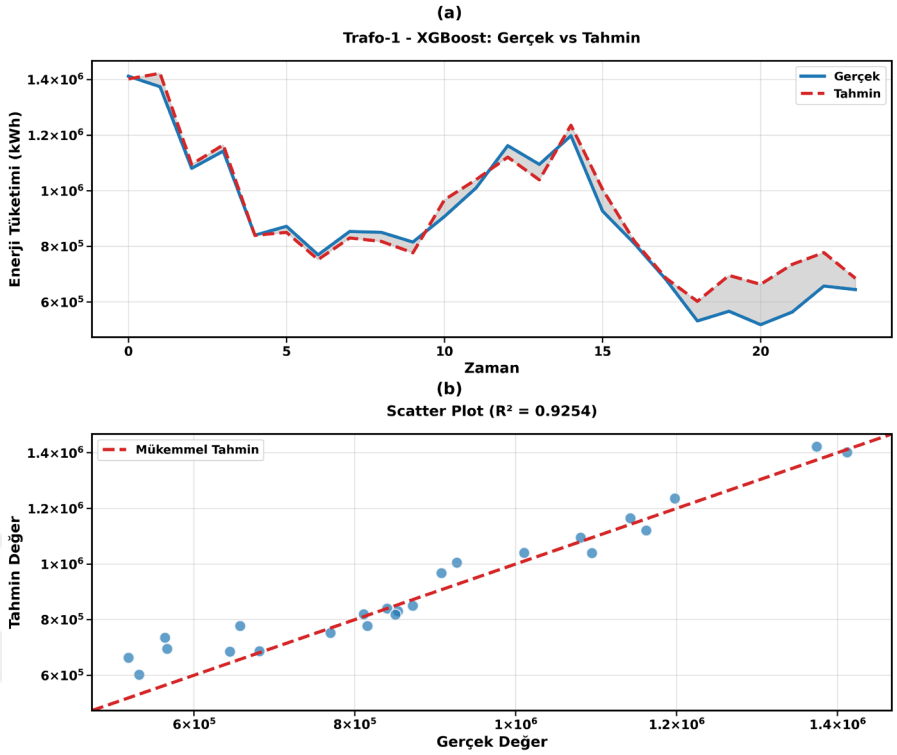

Şekil 3.17. Trafo-1 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

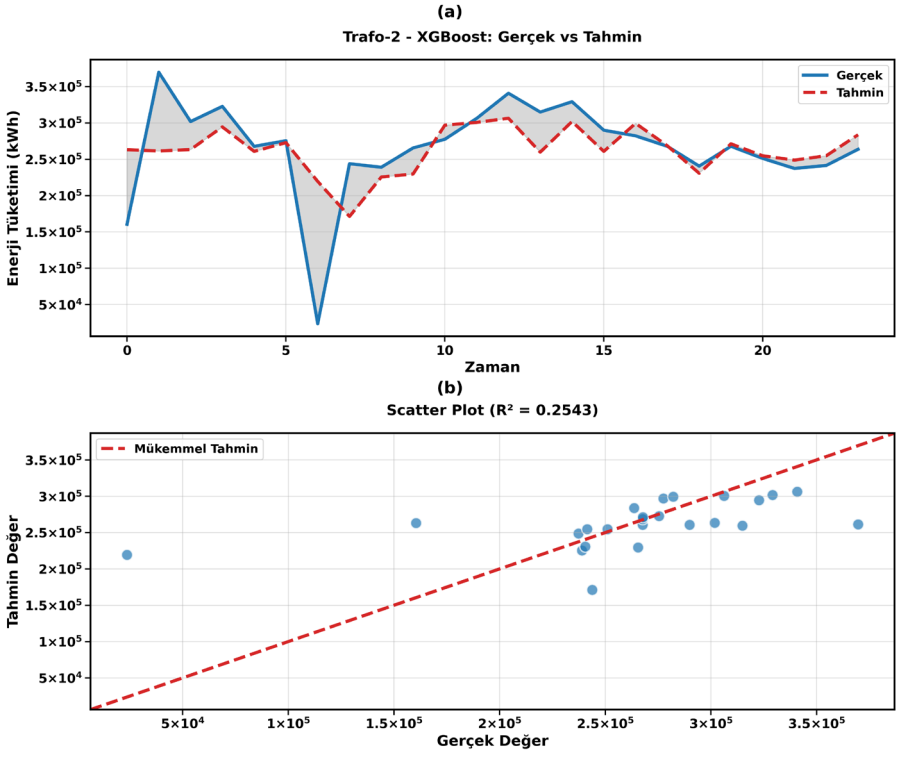

Şekil 3.18. Trafo-2 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

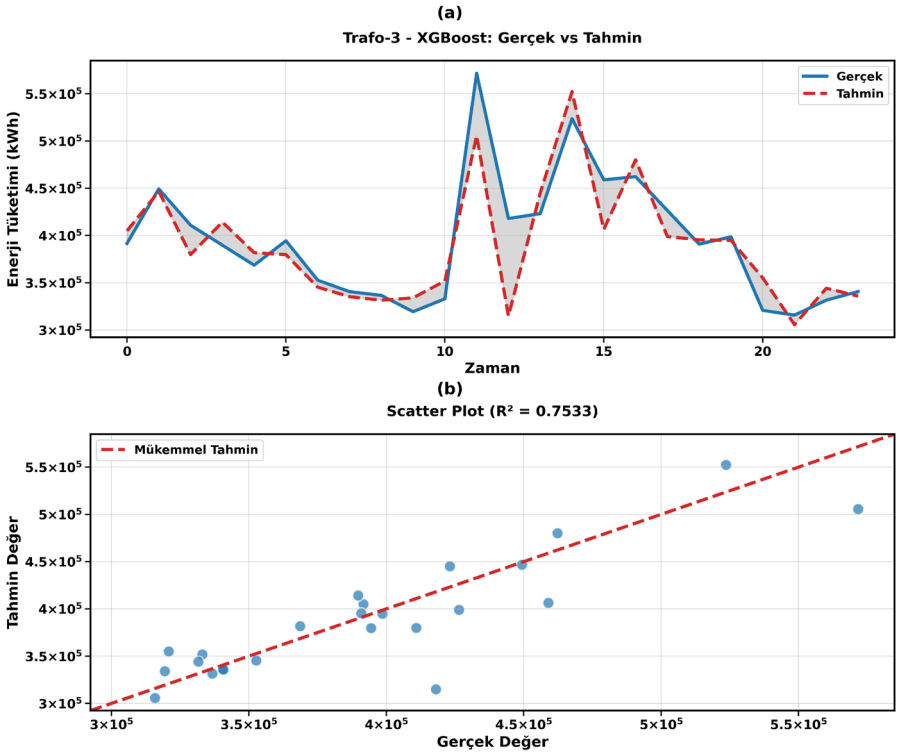

Şekil 3.19. Trafo-3 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

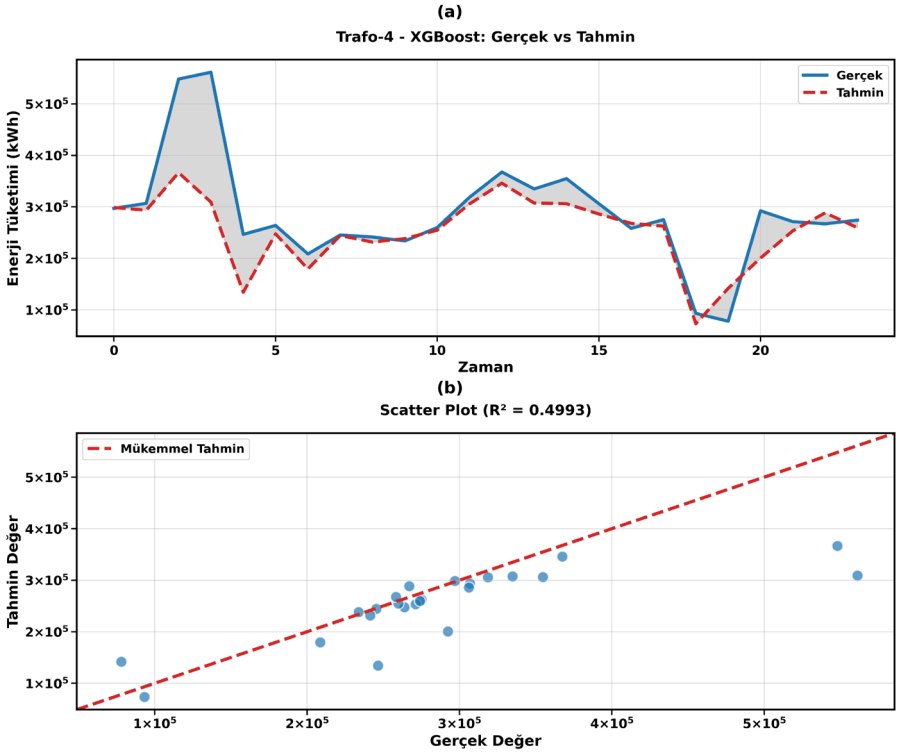

Şekil 3.20. Trafo-4 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

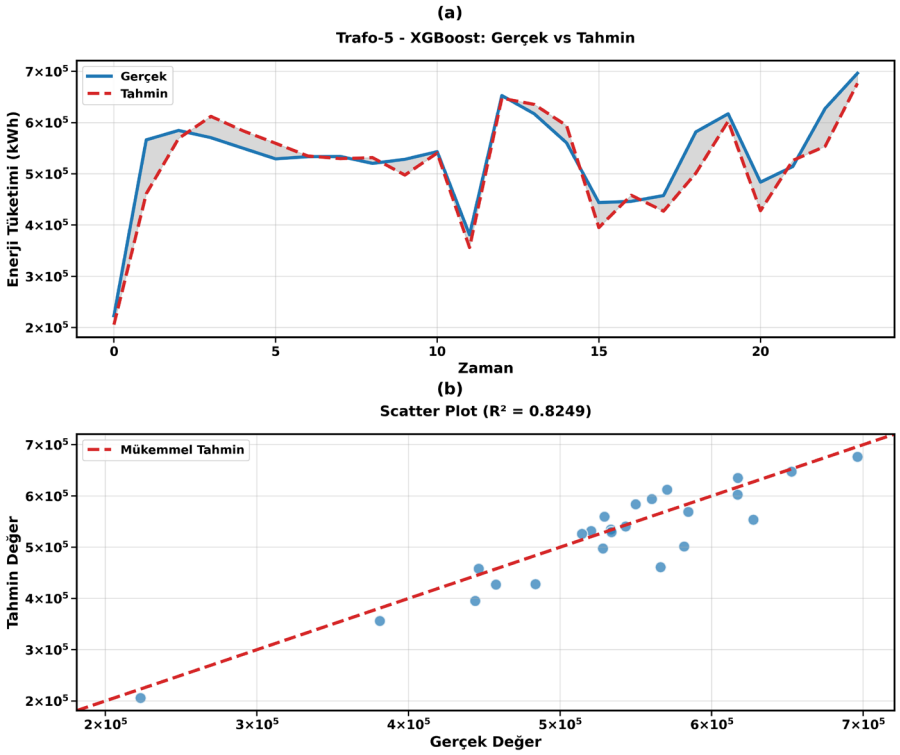

Şekil 3.21. Trafo-5 için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

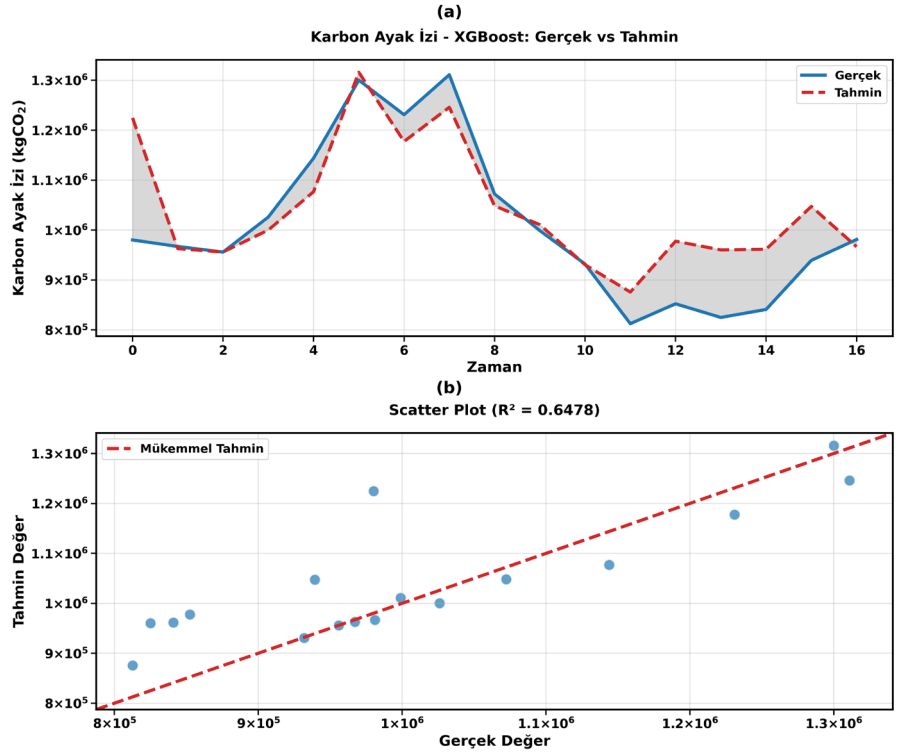

Şekil 3.22. Karbon ayak izi için XGBoost modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

XGBoost, SVR modeline yakın performans sergilemekle birlikte, özellikle bazı zaman dilimlerinde tahminlerde sapmalar gözlemlenmiştir. Bu durum, modelin karmaşık veri örüntülerini yakalama yeteneğinin genel olarak iyi olsa da bazı dalgalanmalara karşı hassas olabileceğini işaret etmektedir.

3.4.3. LSTM Tahmin ve Dağılım Grafikleri

Şekil 3.23-3.28'de, LSTM modelinin enerji tüketimi tahminleri gerçek değerlerle karşılaştırılmış ve dağılım grafikleri ile modelin tahmin başarısı görselleştirilmiştir.

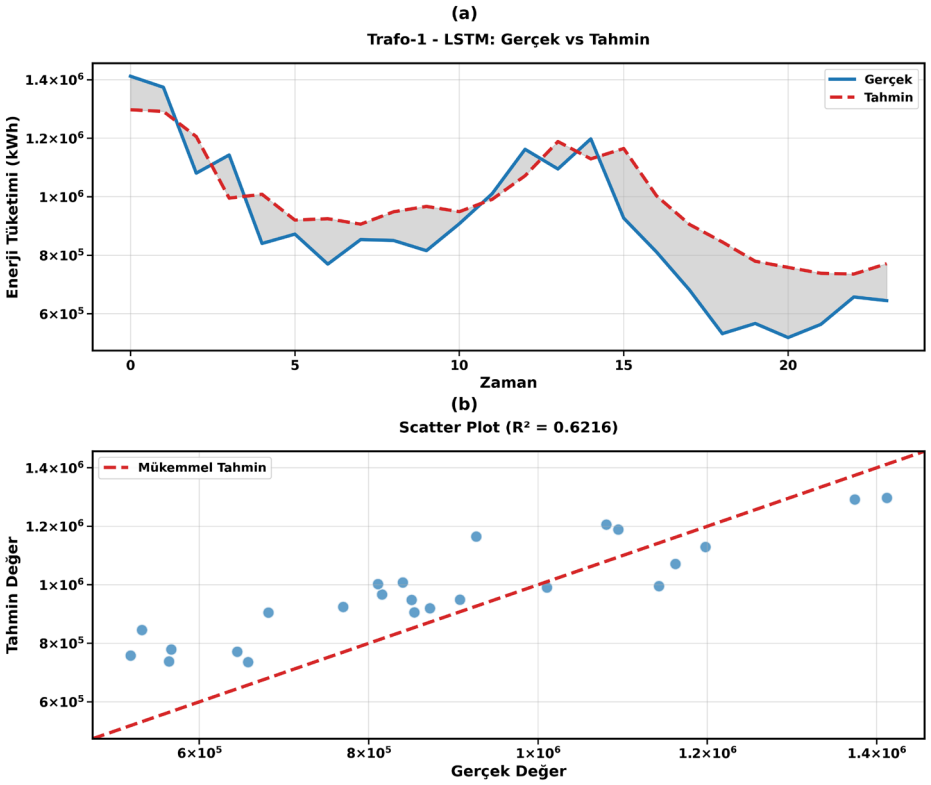

Şekil 3.23. Trafo-1 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

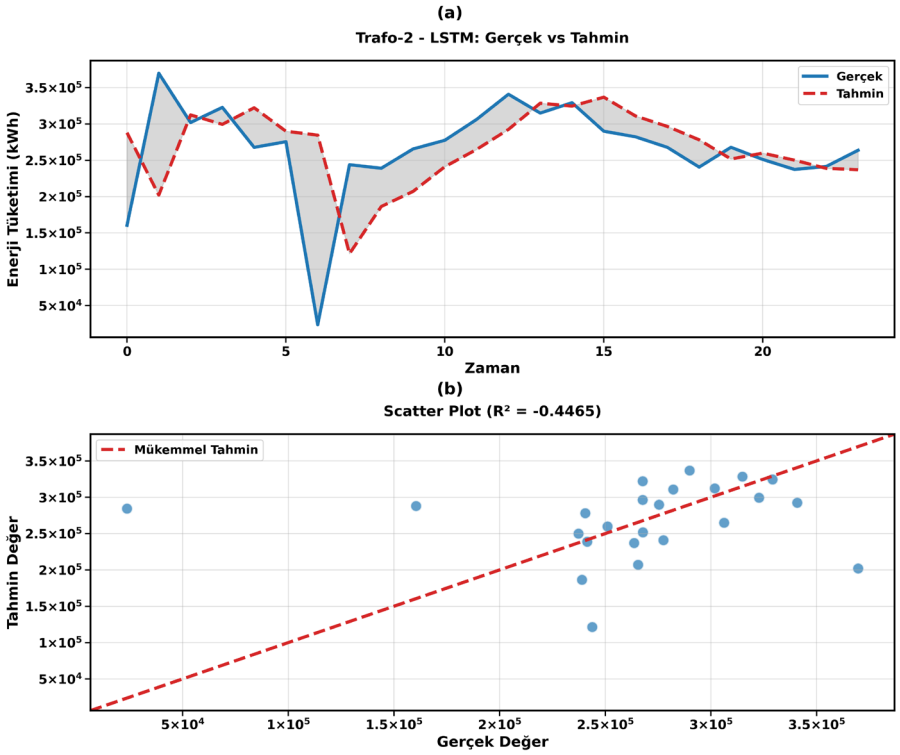

Şekil 3.24. Trafo-2 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

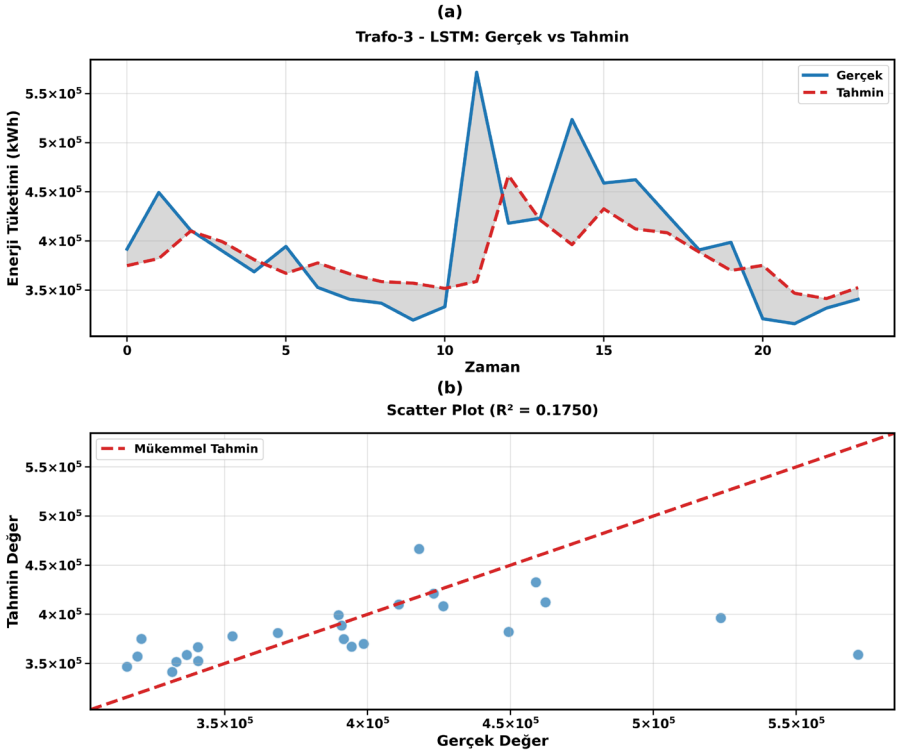

Şekil 3.25. Trafo-3 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

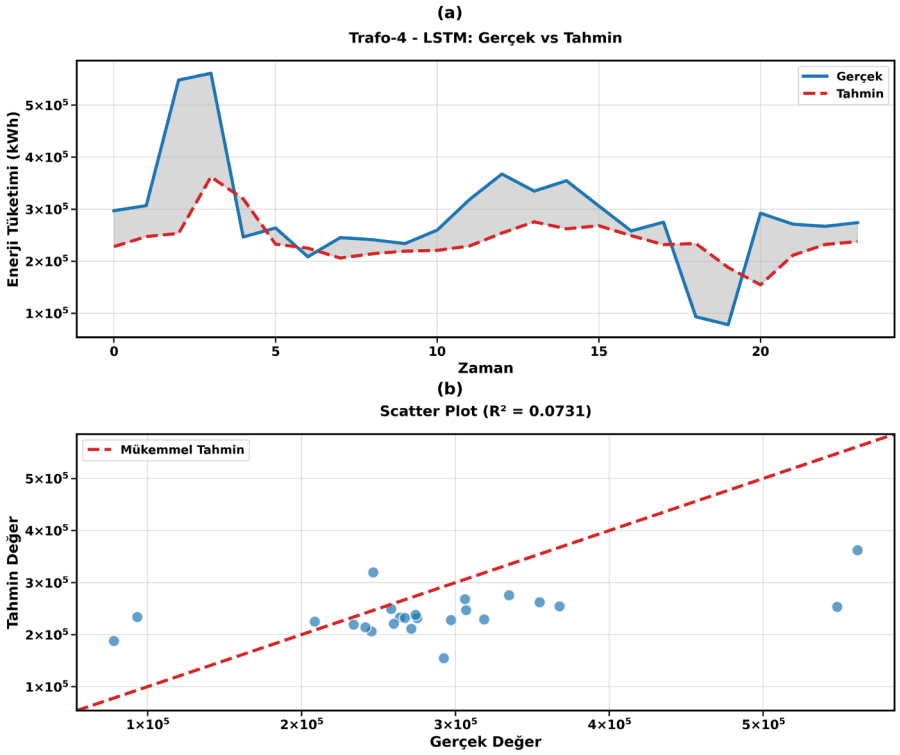

Şekil 3.26. Trafo-4 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

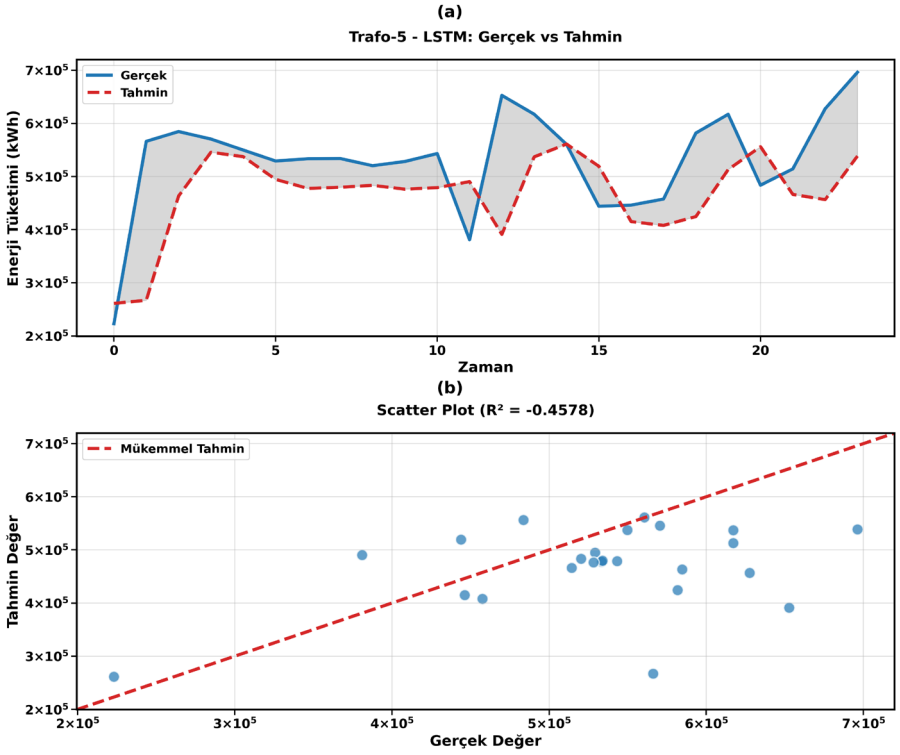

Şekil 3.27. Trafo-5 için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

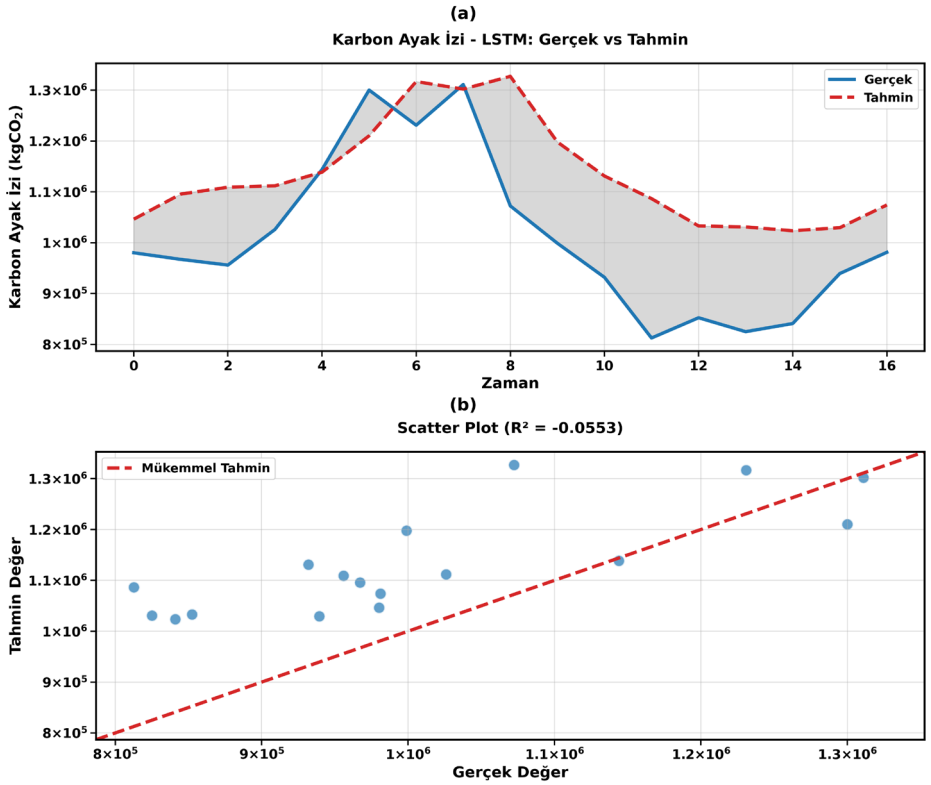

Şekil 3.28. Karbon ayak izi için LSTM modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

LSTM, zaman serisi verilerindeki uzun dönemli bağımlılıkları modelleme avantajına sahip olmasına rağmen, tahmin performansı diğer modellerin gerisinde kalmıştır. Özellikle kısa ve orta vadeli dalgalanmaları yakalamada yetersiz kalmış, bu da sınırlı veri seti ve model parametrelerinin optimizasyonuna bağlı olabilmektedir.

3.4.4. ANFIS Tahmin ve Dağılım Grafikleri

Şekil 3.29-3.34'te, ANFIS modelinin enerji tüketim tahminleri ile gerçek değerlerin karşılaştırılması ve dağılım grafikleri sunulmuştur.

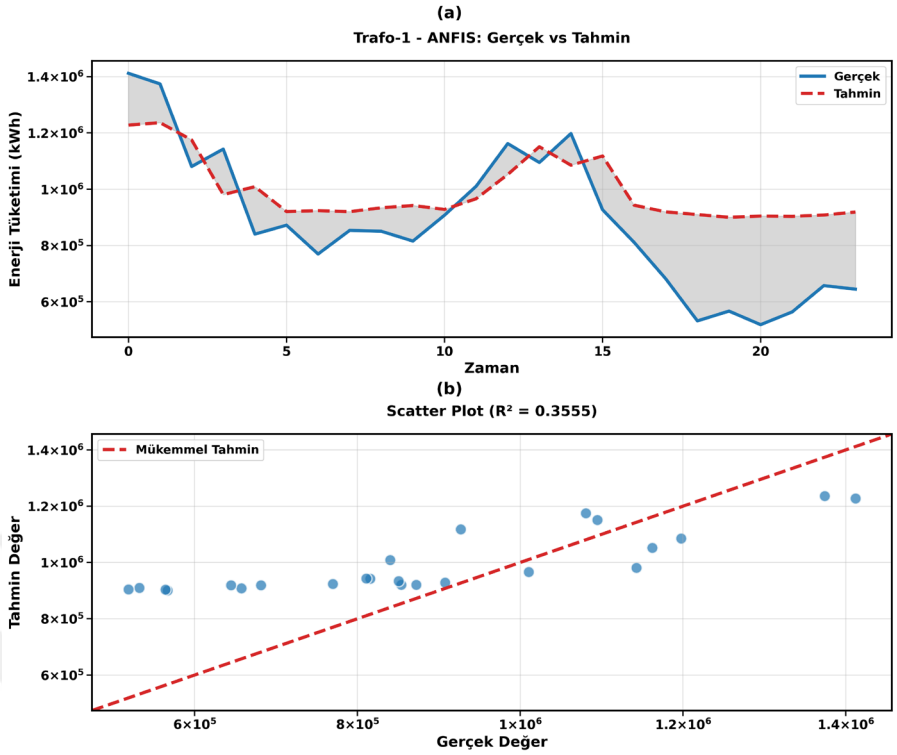

Şekil 3.29. Trafo-1 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

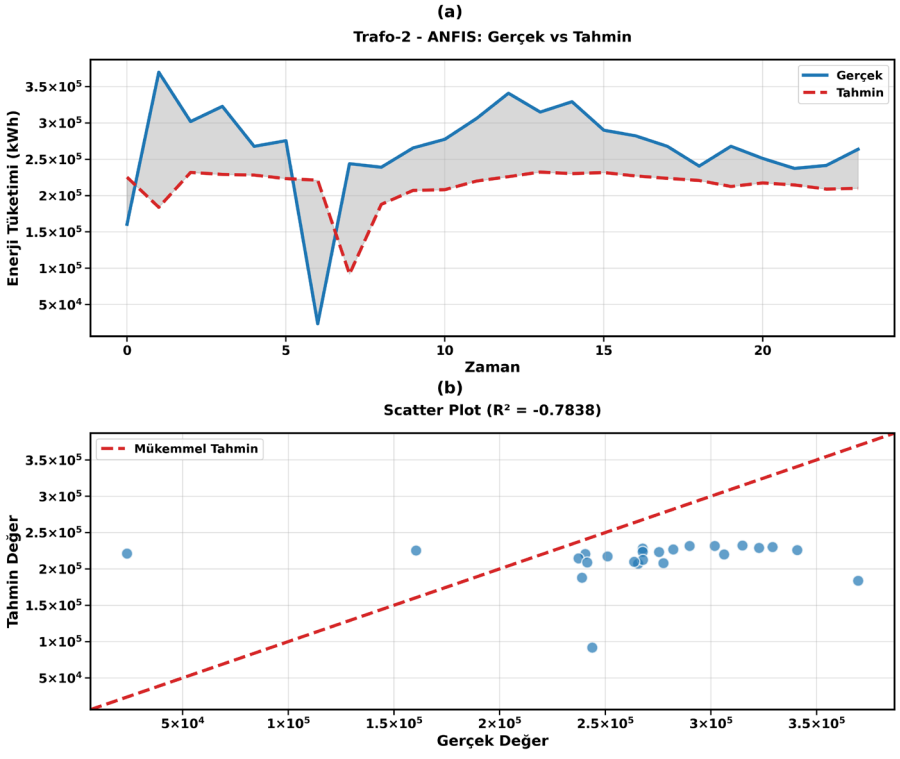

Şekil 3.30. Trafo-2 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

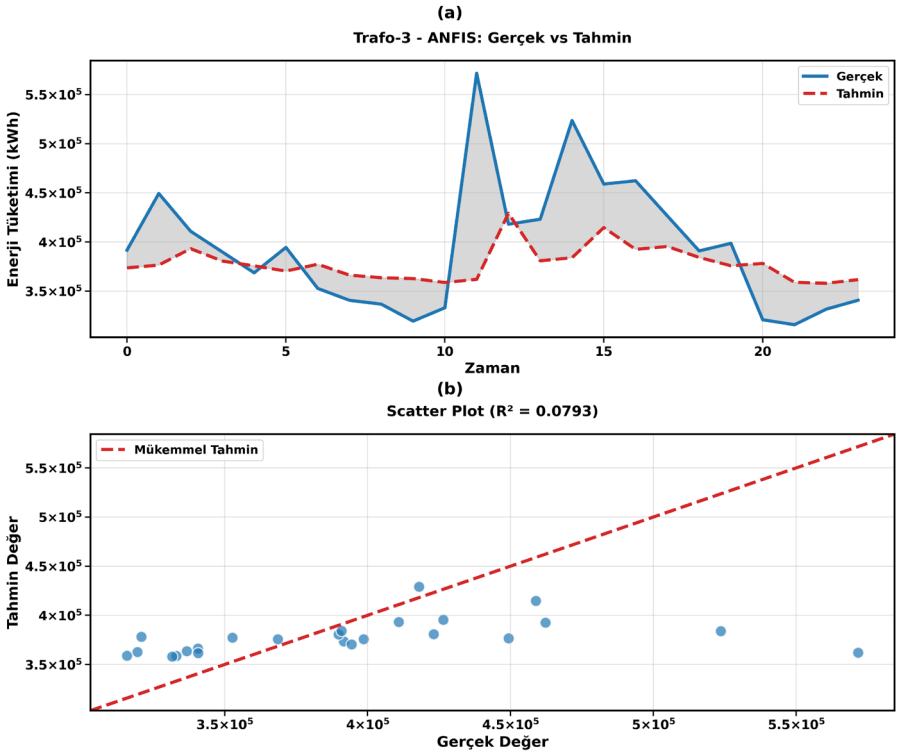

Şekil 3.31. Trafo-3 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

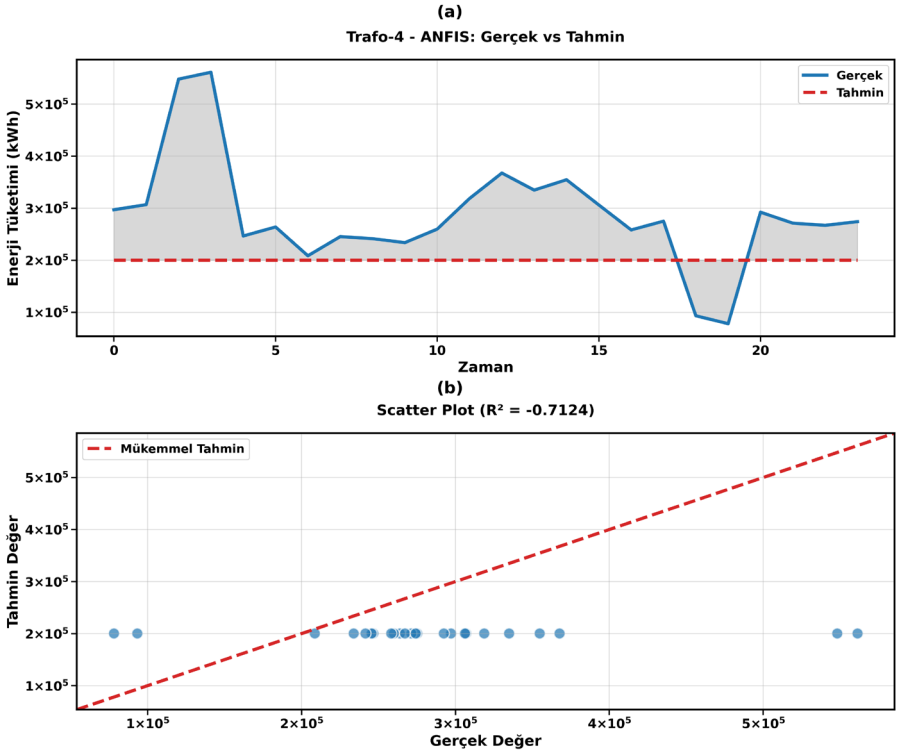

Şekil 3.32. Trafo-4 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

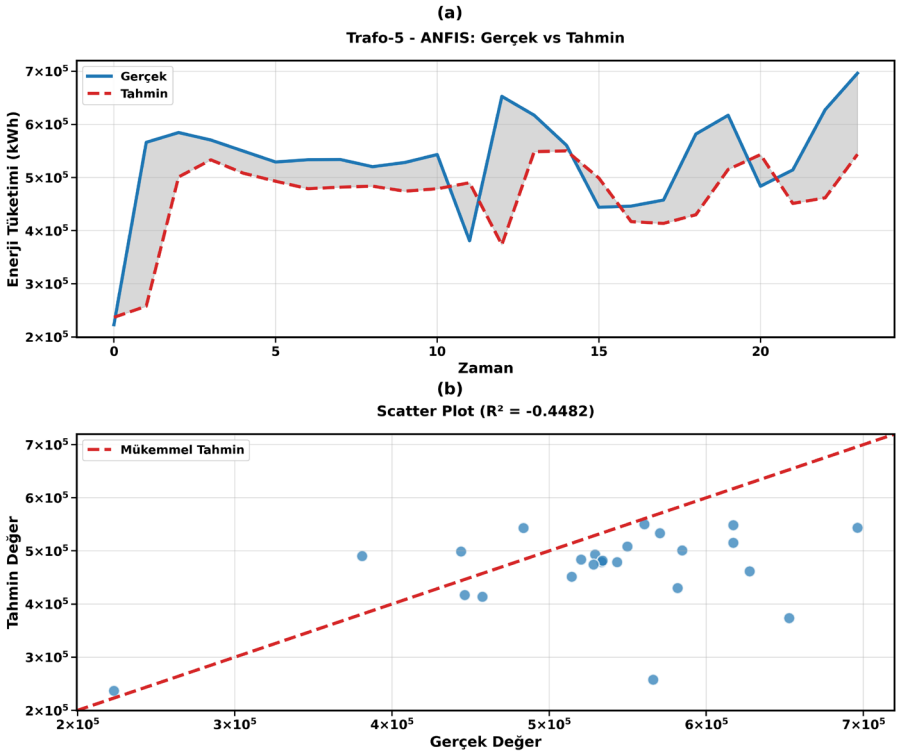

Şekil 3.33. Trafo-5 için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

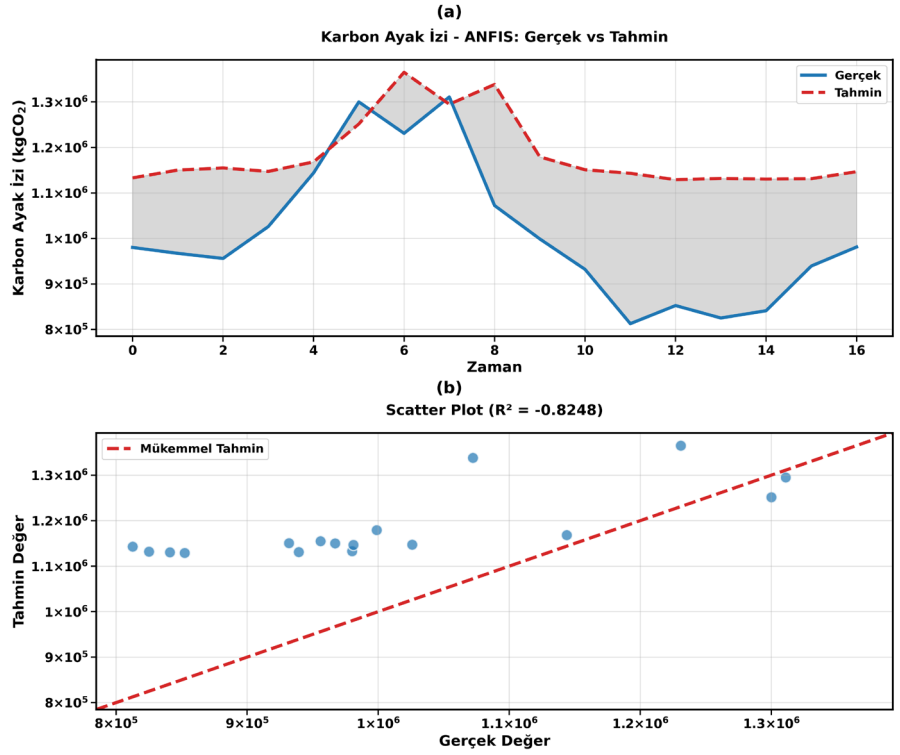

Şekil 3.34. Karbon ayak izi için ANFIS modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

ANFIS modelinin tahminleri, gerçek değerlerden belirgin sapmalar göstermiştir. Bu durum, modelin karmaşık doğrusal olmayan ilişkileri yakalama kapasitesinin sınırlı olduğunu ve daha karmaşık veya parametre ayarlaması gerektiren veri setlerinde performansının düşebileceğini ortaya koymaktadır.

3.4.5. NAR-NN Tahmin ve Dağılım Grafikleri

Şekil 3.35-3.40'da NAR-NN modeline ait enerji tüketimi tahminleri ile zaman serileri gerçek değerlerinin karşılaştırması ve dağılım grafikleri verilmiştir.

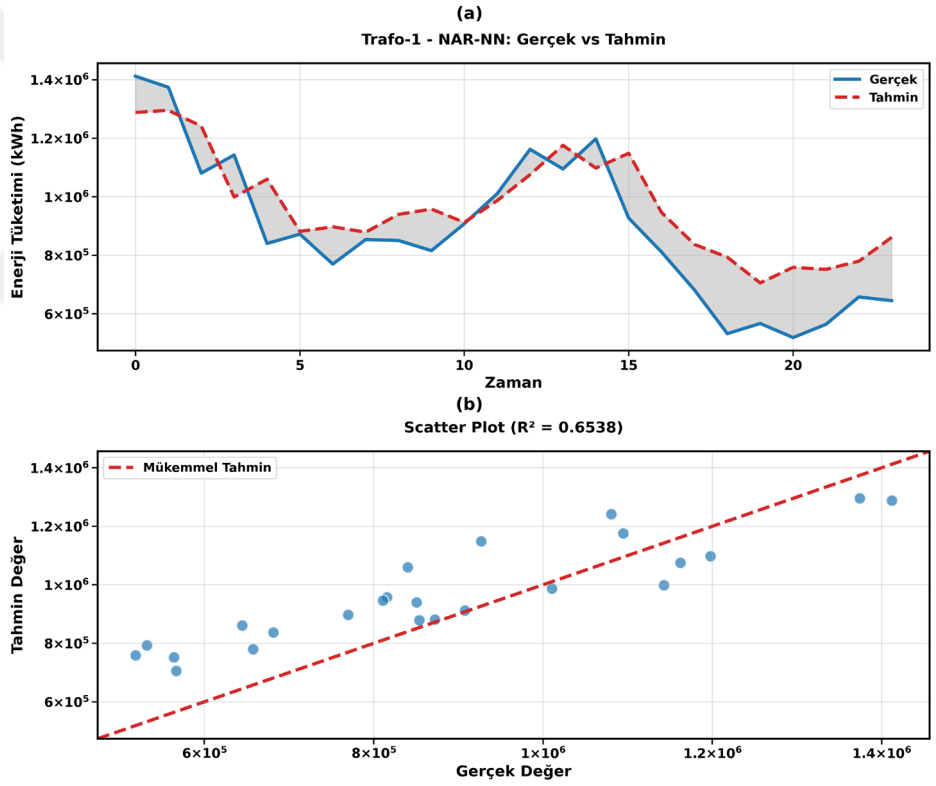

Şekil 3.35. Trafo-1 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

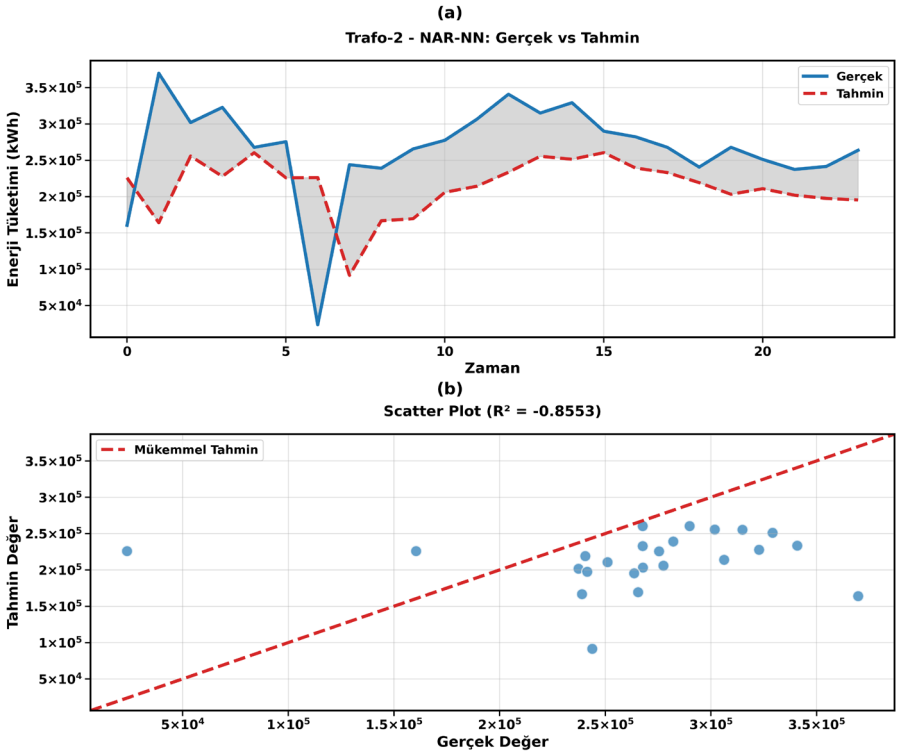

Şekil 3.36. Trafo-2 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

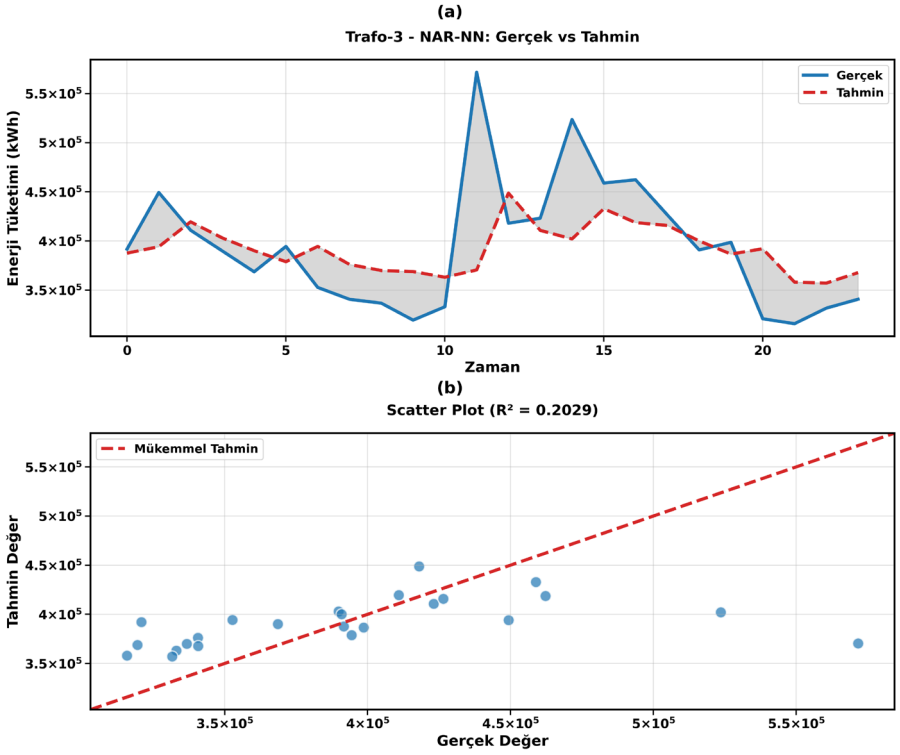

Şekil 3.37. Trafo-3 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

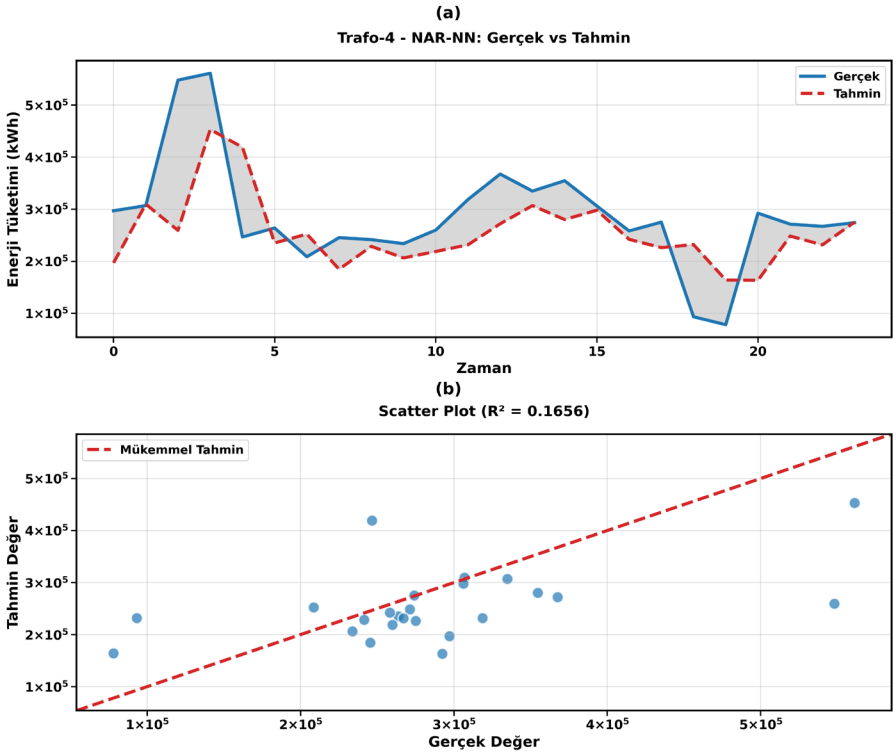

Şekil 3.38. Trafo-4 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

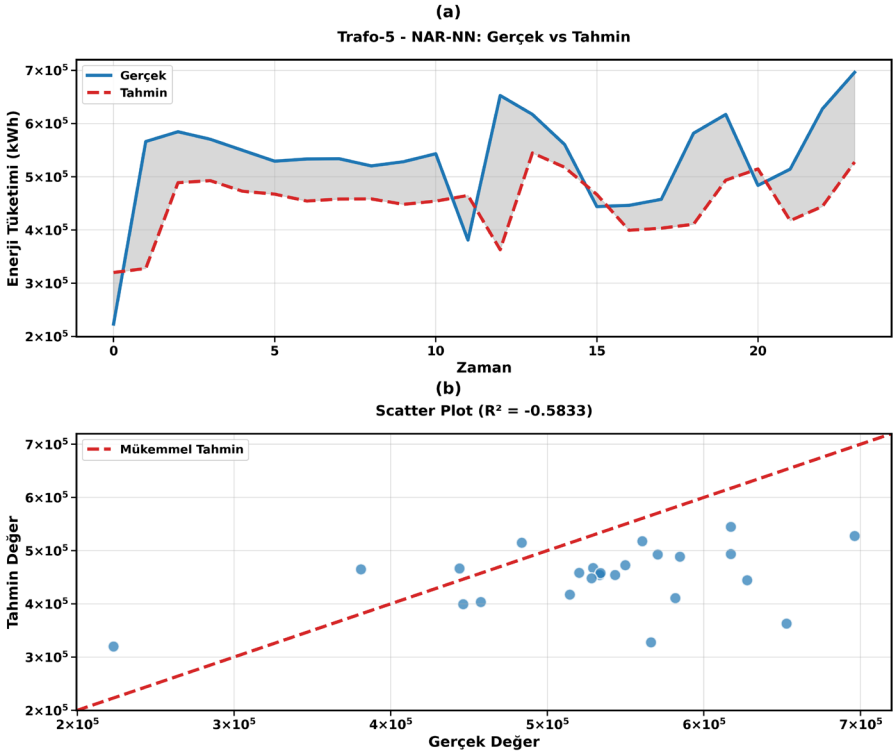

Şekil 3.39. Trafo-5 için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

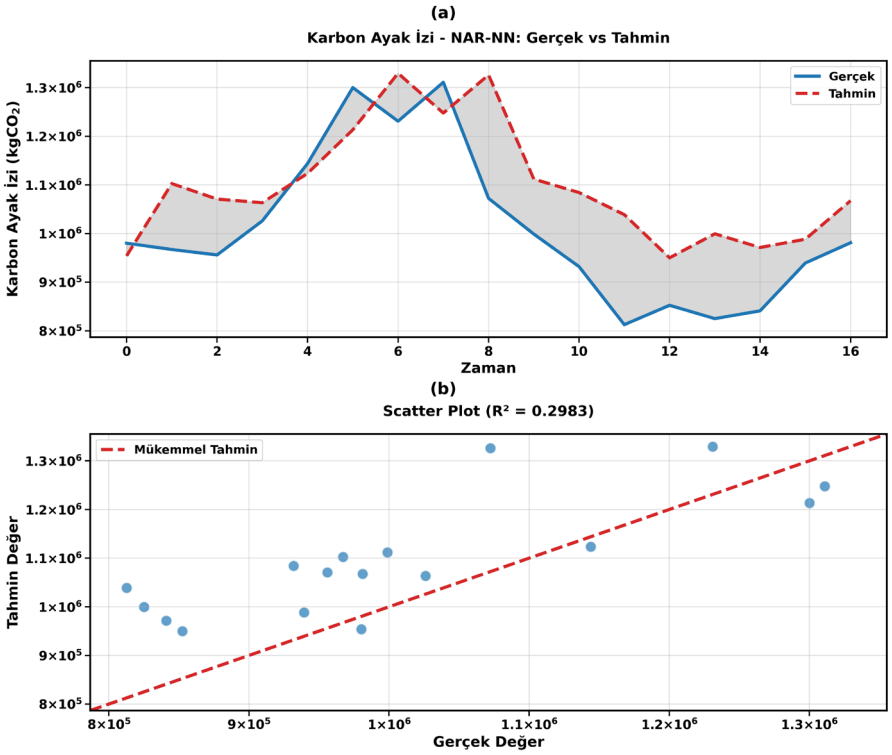

Şekil 3.40. Karbon ayak izi için NAR-NN modeli tahmin değerlerinin: (a) gerçek değerler ile karşılaştırılması ve (b) dağılım grafiği

NAR-NN modelinin tahmin sonuçları, gerçek değerlere kıyasla önemli sapmalar göstermekte olup, modelin veri setindeki dinamikleri yeterince öğrenemediğini göstermektedir. Bu düşük performans, model yapısının karmaşık enerji tüketim örüntülerini yakalamada yetersiz kaldığını ve daha kapsamlı eğitim ile optimizasyonun gerektiğini işaret etmektedir.

4. BÖLÜM

SONUÇ VE ÖNERİLER

Bu tez çalışmasında, kentsel raylı ulaşım sistemlerinin enerji tüketimi ve karbon ayak izini tahmin etmek amacıyla beş farklı makine öğrenmesi algoritması kapsamlı biçimde değerlendirilmiştir. Tramvay raylı sistemine ait beş dağıtım trafo merkezinden elde edilen 10 yıllık (119 gözlem) enerji tüketiminin aylık verileri kullanılmış; eksik değerler Seasonal K-NN yöntemiyle tamamlanmış, komşular aynı mevsim/ay içinden seçilerek mevsimselliğin korunması hedeflenmiş ve veri kronolojik olarak %80 eğitim–%20 test biçiminde ayrılmıştır. Hiperparametreler Rastgele Arama yöntemi ile 20 iterasyonda optimize edilmiştir.

Sonuçlar incelendiğinde SVR tüm serilerde en yüksek doğruluğu veren yöntem olmuştur; beş trafo serisinde R^2 aralığı 0.896–0.993 düzeyinde elde edilmiştir. Bu, SVR'nin (özellikle RBF çekirdeği ile) sınırlı örneklemde mevsimsellik ve doğrusal olmama bileşimini iyi temsil edebildiğini ve küçük ve orta ölçekli zaman serilerinde güçlü bir genelleme kapasitesine sahip olduğuna işaret etmektedir. Karbon ayak izi tahmininde SVR modeli $R^2 = 0.942$ ile üstün bir başarı sergilemiş ve RMSE = 36453.30 ile düşük tahmin hatası üretmiştir.

XGBoost genel olarak ikinci sırada yer almakla birlikte performansı seri karakterine duyarlıdır: düzenli mevsimsellikte güçlü, oynaklık/ani sıçrama içeren serilerde daha kırılgandır. XGBoost, karbon ayak izi verisi için $R^2 = 0.648$ ile düşük olsa da ikinci en iyi performansı göstermiştir. Bir topluluk (ensemble) yöntem olarak XGBoost, özellikle Trafo-1 ($R^2 = 0.925$) ve Trafo-5 ($R^2 = 0.825$) gibi düzenli örüntülere sahip serilerde daha başarılıdır. Buna karşılık, beklentilerin aksine sinir ağı tabanlı modeller (LSTM, ANFIS ve NAR-NN) yetersiz performans sergilemiş ve birçok seride düşük hatta negatif R^2 üretmiştir. Bu durum ortalama baz çizgisinden daha kötü performans anlamına gelir.

LSTM, karbon ayak izi tahmininde $R^2 = -0.064$ üretirken; ANFIS ($R^2 = -1.288$) ve NAR-NN ($R^2 = 0.232$) benzer şekilde düşük performans göstermiştir. Bu sonuç, derin öğrenme yöntemlerinin genellikle yüksek performans için daha büyük veri setlerine ihtiyaç duymasıyla uyumludur; 119 aylık veri seti, LSTM gibi daha karmaşık mimarilerin etkili biçimde eğitilmesi için yetersiz kalmıştır. Benzer bulgular trafo merkezi veri setleri için de elde edilmiştir. Sonuç olarak sinir ağı tabanlı modellerin genelleme için yeterli veriyi bulmakta zorlandığı, buna karşın SVR/XGBoost'un daha dengeli bir genelleme sunduğunu anlaşılmaktadır.

Trafo bazlı bakacak olursak da yüksek varyans ve düzensiz tüketim nedeniyle 2. trafodan elde edilen enerji tüketim zaman serisi, zor bir öngörü problemine dönüşmüştür. Sonuçlar sadece SVR'nin gerçek değerleri tutarlı biçimde takip edebildiği, XGBoost'un ise ani dalgalanmalarda yetersiz kaldığını vurgulamaktadır.

Uygulama açısından değerlendirildiğinde, kentsel raylı ulaşım sistemlerinde enerji yönetimi ve karbon ayak izi izleme için SVR tabanlı tahmin modellerinin kullanılması önerilmektedir. %3.51 MAPE, enerji arz planlaması ve karbon bütçelemesi için kabul edilebilir bir doğruluk düzeyi sunmaktadır. Bu tahminler, yenilenebilir enerji entegrasyonunun planlanması, pik yük yönetimi ve karbon dengeleme projelerinin boyutlandırılmasına destek olabilir. Çalışmanın önemli bir getirisi de enerji tüketimi tahminlerinin planlama ve işletme süreçlerinde kullanılabilirliğinin ortaya konulmasıdır. Yeni raylı sistem hatlarının planlanması aşamasında, benzer işletme koşullarına sahip mevcut hatlardan elde edilen veriler kullanılarak enerji tüketimi öngörülebilir; bu sayede trafo kapasitesi seçimi, enerji altyapısı planlaması ve işletme maliyetleri daha gerçekçi biçimde değerlendirilebilir. Bunun yanı sıra, enerji tüketimine dayalı karbon ayak izi hesaplamaları, raylı sistem işletmecilerinin karbon emisyonlarını izleyebilmesine ve azaltım senaryolarını değerlendirebilmesine olanak sağlamaktadır. Bu çalışma ile özellikle işletme bünyesinde gerçekleştirilecek yenilenebilir enerji yatırımları, enerji geri kazanım sistemleri veya enerji verimliliği iyileştirmelerinin toplam karbon salımı üzerindeki etkilerinin bu tür tahmin modelleri yardımıyla nicel olarak analiz edilebileceği ortaya konmaktadır.

Ayrca gelecek çalışmalarda modele dışsal değişkenlerin (ör. hava koşulları, yolcu sayıları ve tatil günleri) dâhil edilmesi planlanmaktadır. Ayrıca, transfer öğrenme yaklaşımlarının

küçük veri setlerinde derin öğrenme modellerinin performansını iyileştirip iyileştiremeyeceği de gelecekteki bir araştırma yönü olarak değerlendirilmektedir.

KAYNAKÇA

1. Qureshi, M., Arbab, M. A., Rehman, S., 2024. Deep learning-based forecasting of electricity consumption. **Scientific Reports**, **14**, 6489. https://doi.org/10.1038/s41598-024-56602-4

2. Elhabyb, K., Baina, A., Bellafkih, M., Deifalla, A. F., 2024. Machine learning algorithms for predicting energy consumption in educational buildings. **International Journal of Energy Research**, **2024**, 6812425. https://doi.org/10.1155/2024/6812425

3. Morcillo-Jimenez, R., Mesa, J., Gómez-Romero, J., Vila, M. A., Martin-Bautista, M. J., 2024. Deep learning for prediction of energy consumption: an applied use case in an office building. **Applied Intelligence**, **54**: 5813–5825. https://doi.org/10.1007/s10489-024-05451-9

4. Mahjoub, S., Chrifi-Alaoui, L., Marhic, B., Delahoche, L., 2022. Predicting energy consumption using LSTM, multi-layer GRU and Drop-GRU neural networks. **Sensors**, **22** (11), 4062. https://doi.org/10.3390/s22114062

5. Ramos, P. V. B., Villela, S. M., Silva, W. N., Dias, B. H., 2023. Residential energy consumption forecasting using deep learning models. **Applied Energy**, **350**, 121705. https://doi.org/10.1016/j.apenergy.2023.121705

6. Chan, J. W., Yeo, C. K., 2024. A transformer-based approach to electricity load forecasting. **The Electricity Journal**, **37** (2), 107370. https://doi.org/10.1016/j.tej.2024.107370

7. Chung, J., Jang, B., 2022. Accurate prediction of electricity consumption using a hybrid CNN–LSTM model based on multivariable data. **PLOS ONE**, **17** (11), e0278071. https://doi.org/10.1371/journal.pone.0278071

8. Maleki, N., Lundström, O., Musaddiq, A., Jeansson, J., Olsson, T., Ahlgren, F., 2024. Future energy insights: Time-series and deep learning models for city load forecasting. **Applied Energy**, **374**, 124067. https://doi.org/10.1016/j.apenergy.2024.124067

9. Deng, Y., Yue, Z., Wu, Z., Li, Y., Wang, Y., 2024. TCN-Attention-BIGRU: Building energy modelling based on attention mechanisms and temporal convolutional networks. **Electronic Research Archive**, **32** (3): 2160–2179. https://doi.org/10.3934/era.2024098

10. Frikha, M., Taouil, K., Fakhfakh, A., Derbel, F., 2024. Predicting power consumption using deep learning with stationary wavelet transform. **Forecasting**, **6** (3): 864–884. https://doi.org/10.3390/forecast6030043

11. Gorzałczany, M. B., Rudziński, F., 2024. Energy consumption prediction in residential buildings—An accurate and interpretable machine learning approach combining fuzzy systems with evolutionary optimization. **Energies**, **17** (13), 3242. https://doi.org/10.3390/en17133242

12. Chahardoli, M., Osati Eraghi, N., Nazari, S., 2025. An energy consumption prediction approach in smart cities by CNN-LSTM network improved with game theory and Namib Beetle Optimization (NBO) algorithm. **The Journal of Supercomputing**, **81**, 403. https://doi.org/10.1007/s11227-024-06811-5

13. Ajala, A. A., Adeoye, O. L., Salami, O. M., Jimoh, A. Y., 2025. An examination of daily CO_2 emissions prediction through a comparative analysis of machine learning, deep learning, and statistical models. **Environmental Science and Pollution Research**, **32**: 2510–2535. https://doi.org/10.1007/s11356-024-35764-8

14. Begum, A. M., Mobin, M. A., 2025. A machine learning approach to carbon emissions prediction of the top eleven emitters by 2030 and their prospects for meeting Paris agreement targets. **Scientific Reports**, **15**, 19469. https://doi.org/10.1038/s41598-025-04236-5

15. Xia, X., Zhu, D., Sha, J., Ma, R., Kang, W., 2025. Research on industrial carbon emission prediction method based on CNN–LSTM under dual carbon goals. **International Journal of Low-Carbon Technologies**, **20**: 580–589. https://doi.org/10.1093/ijlct/ctaf012

16. Meng, Z., Sun, H., Wang, X., 2022. Forecasting energy consumption based on SVR and Markov model: A case study of China. **Frontiers in Environmental Science**, **10**, 883711. https://doi.org/10.3389/fenvs.2022.883711

17. Li, F., Sun, M., Xian, Q., Feng, X., 2024. MDL: Industrial carbon emission prediction method based on meta-learning and diff long short-term memory networks. **PLOS ONE**, **19** (9), e0307915. https://doi.org/10.1371/journal.pone.0307915

18. Ghorbal, A. B., Grine, A., Elbatal, I., Almetwally, E. M., Eid, M. M., El-Kenawy, E. M., 2025. Predicting carbon dioxide emissions using deep learning and Ninja metaheuristic optimization algorithm. **Scientific Reports**, **15**, 4021. https://doi.org/10.1038/s41598-025-86251-0

19. Alam, G. M. I., Tanim, S. A., Sarker, S. K., Watanobe, Y., Islam, R., Mridha, M. F., Nur, K., 2025. Deep learning model based prediction of vehicle CO_2 emissions with eXplainable AI integration for sustainable environment. **Scientific Reports**, **15**, 3655. https://doi.org/10.1038/s41598-025-87233-y

20. Lee, E. H., Lee, I., Cho, S.-H., Kho, S.-Y., Kim, D.-K., 2019. A travel behavior-based skip-stop strategy considering train choice behaviors based on smartcard data. **Sustainability**, **11** (10), 2791. https://doi.org/10.3390/su11102791.

21. Zhu, C., Yang, X., Wang, Z., Fang, J., Wang, J., Cheng, L., 2023. Optimization for the train plan with flexible train composition considering carbon emission. **Engineering Letters**, **31** (2), 562–573.

22. Han, Z., Gonzales, E., Christofa, E., Oke, J. 2023. Line-specific energy modeling framework for urban rail transit systems: A case study of Boston. **Transportation Research Record: Journal of the Transportation Research Board**, **2678** (1), 150-164. https://doi.org/10.1177/03611981231170181

23. Tang, Z., Yin, H., Yang, C., Yu, J., Guo, H., 2021. Predicting the electricity consumption of urban rail transit based on binary nonlinear fitting regression and support vector regression. **Sustainable Cities and Society**, **66**, 102690. https://doi.org/10.1016/j.scs.2020.102690

24. Chen, B., Lin, Y., 2025. Construction of a prediction model for energy consumption in urban rail transit operations using a bottom–up approach. **Energies**, **18** (4), 888. https://doi.org/10.3390/en18040888

25. Wang, J., Rakha, H. A., 2017. Electric train energy consumption modeling. **Applied Energy**, **193**, 346–355. https://doi.org/10.1016/j.apenergy.2017.02.058

26. Ma, Q., Wang, H., Luo, P., Peng, Y., Li, Q., 2022. Ultra-short-term railway traction load prediction based on DWT-TCN-PSO_SVR combined model. **International Journal of Electrical Power & Energy Systems**, **135**, 107595. https://doi.org/10.1016/j.ijepes.2021.107595

27. Hou, Z., Du, Z., Yang, G., Yang, Z., 2022. Short-term passenger flow prediction of urban rail transit based on a combined deep learning model. **Applied Sciences**, **12** (15), 7597. https://doi.org/10.3390/app12157597

28. Wu, C., Ochieng, W., Pien, K.-C., Shang, W.-L., 2025. Carbon-efficient timetable optimization for urban railway systems considering wind power consumption. **Applied Energy**, **388**, 125593. https://doi.org/10.1016/j.apenergy.2025.125593

29. Deng, L., Chen, M., Duan, K., Li, O., Shi, F., 2023. Integrated energy-efficient optimization for urban rail transit timetable. **IET Intelligent Transport Systems**, **17** (9): 1819-1834. https://doi.org/10.1049/itr2.12377

30. Zhong, L., Xu, G., Liu, W., 2024. Energy-efficient and demand-driven train timetable optimization with a flexible train composition mode. **Energy**, **305**, 132183. https://doi.org/10.1016/j.energy.2024.132183

31. Li, M., Dai, C., Chen, W., 2024. Train timetable optimization for suppressing traction power fluctuations, especially on mountainous railway lines with long, steep grades. **Transportation Research Record: Journal of the Transportation Research Board**, **2678** (8), 761-771. https://doi.org/10.1177/03611981231220631

32. He, J., Wang, F., Duan, Y., Yang, Z., Yang, J., 2025. Energy-efficient train timetable optimization for tram system under multi-signal priority strategies. **Scientific Reports**, **15**, 8123. https://doi.org/10.1038/s41598-025-91891-3

33. Wang, D., Wu, J., Wei, Y., Chang, X., Yin, H., 2024. Energy-saving operation in urban rail transit: A deep reinforcement learning approach with speed optimization. **Travel Behaviour and Society**, **36**, 100796. https://doi.org/10.1016/j.tbs.2024.100796

34. Dong, L., Qin, L., Xie, X., Zhang, L., Qin, X., 2023. Collaborative optimization method for multi-train energy-saving control with urban rail transit based on

DRLDA algorithm. **Applied Sciences**, **13** (4), 2454. https://doi.org/10.3390/app13042454

35. Aroso, A., Bugarín, M. R., 2024. Energy efficiency improvement on railway lines: an overview. **Energy Science & Engineering**, **12** (12): 5753-5764. https://doi.org/10.1002/ese3.1971

36. Pappaterra, M. J., Flammini, F., Vittorini, V., Bešinović, N., 2021. A systematic review of artificial intelligence public datasets for railway applications. **Infrastructures**, **6** (10), 136. https://doi.org/10.3390/infrastructures6100136

37. Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., Botstein, D., Altman, R. B., 2001. Missing value estimation methods for DNA microarrays. **Bioinformatics**, **17** (6): 520–525. https://doi.org/10.1093/bioinformatics/17.6.520

38. Beretta, L., Santaniello, A., 2016. Nearest neighbor imputation algorithms: a critical evaluation. **BMC Medical Informatics and Decision Making**, **16**, 74. https://doi.org/10.1186/s12911-016-0318-z

39. Vapnik, V. N., 1995. The nature of statistical learning theory (1st ed.). Springer New York, NY, 188. https://doi.org/10.1007/978-1-4757-2440-0

40. Chen, T., Guestrin, C., 2016. XGBoost: A scalable tree boosting system, 785–794. *KDD'16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,* August 13 - 17, 2016, San Francisco, California, USA. https://doi.org/10.1145/2939672.2939785

41. 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

42. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, **15**: 1929–1958.

43. Jang, J.-S. R., 1993. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, **23** (3): 665–685. https://doi.org/10.1109/21.256541

44. Narendra, K. S., Parthasarathy, K., 1990. Identification and control of dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, **1** (1): 4–27. https://doi.org/10.1109/72.80202

45. Kingma, D. P., Ba, J., 2015. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015,* May 7-9, 2015, San Diego, CA, USA. https://doi.org/10.48550/arXiv.1412.6980

46. Bergstra, J., Bengio, Y., 2012. Random search for hyper-parameter optimization. **Journal of Machine Learning Research**, **13**: 281–305.

EKLER

EK 1. Tahmin modelleri için arama aralığında Rastgele Arama yöntemi ile seçilen hiperparametreler.

Model	Parametre	Trafo-1	Trafo-2	Trafo-3	Trafo-4	Trafo-5	Karbon Ayak izi
SVR	C	1.9762	1.9762	2.2465	1.9762	1.9762	1.9762
	epsilon	0.0312	0.0312	0.0105	0.0312	0.0312	0.0312
	gamma	0.0685	0.0685	0.6708	0.0685	0.0685	0.0685
	kernel	rbf	rbf	poly	rbf	rbf	rbf
XGBoost	n_estimators	138	94	94	150	31	91
	max_depth	4	5	5	2	4	3
	learning_rate	0.0726	0.2330	0.2330	0.2925	0.2267	0.1857
	subsample	0.9506	0.8796	0.8796	0.9497	0.9187	0.7423
	colsample_bytree	0.7962	0.7468	0.7468	0.7637	0.9314	0.9407
	min_child_weight	4	4	4	4	4	4
	gamma	0.1163	0.1232	0.1232	0.1734	0.2434	0.4948
	reg_alpha	0.6318	0.8796	0.8796	0.3738	0.2043	0.7950
	reg_lambda	0.7098	0.6410	0.6410	0.5723	0.8768	0.2788
LSTM	units_1	9	23	23	9	17	17
	units_2	14	3	3	14	4	4
	dropout	0.3803	0.2195	0.2195	0.3803	0.4486	0.4486
	learning_rate	0.005106	0.008890	0.008890	0.005106	0.002274	0.002274
	batch_size	8	32	32	8	8	8
	lookback	6	5	5	6	4	4
ANFIS	n_mfs	2	3	3	3	3	3
	learning_rate	0.0201	0.0205	0.0148	0.0893	0.0132	0.0196
	lookback	4	4	2	5	4	4
NAR-NN	hidden_units	15	18	10	14	17	17
	n_layers	1	2	2	1	1	1
	activation	tanh	relu	tanh	relu	relu	tanh
	learning_rate	0.0352	0.0116	0.0771	0.0232	0.0483	0.0391
	lookback	3	3	4	4	4	2

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Kamber KÜLAHCI
Uyruğu: Türkiye (T.C)
Doğum Tarihi ve Yeri:
Medeni Durum:
e-mail:
Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi

İŞ DENEYİMLERİ

Yıl	Kurum	Görev

YABANCI DİL

İngilizce

YAYINLAR

1. Savaş, S., Külahcı, K., 2026. Machine learning-based energy consumption and carbon footprint forecasting in urban rail transit systems. **Applied Sciences**, **16** (3), 1369. https://doi.org/10.3390/app16031369