

Mikro Gaz Türbinlerinde Güç Tahmini İçin Doğru Yapay Zekâ Modelinin Seçimi: Kapsamlı Bir Performans Çalışması

Yazar Emrullah GAZİOĞLU^{1*}

¹ Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Şırnak Üniversitesi, Şırnak, Türkiye

*¹ gazioglu@sirnak.edu.tr

(Geliş/Received: 29/12/2025;

Kabul/Accepted: 15/01/2026)

Öz: Bu çalışmada, 3 kilowatt gücündeki bir mikro gaz türbininden elde edilen 71.225 örneklik veri seti kullanılarak, on dört farklı Yapay Zeka modelinin (geleneksel Makine Öğrenmesi ve Derin Öğrenme) güç tahmin performansı değerlendirilmiştir. GRU mimarisi en yüksek doğruluğu (RMSE: 12,36; R²: 0,9997) elde ederken, XGBoost gibi geleneksel modeller önemli ölçüde düşük hesaplama gereksinimleri (77,13 saniyeye karşı 855,04 saniye eğitim süresi) ile rekabetçi performans sunmuştur. Sonuçlar, optimal model seçiminin belirli operasyonel gereksinimlere bağlı olduğunu ve gerçek zamanlı uygulamalar için geleneksel Makine Öğrenmesi modellerinin, yüksek doğruluk gerektiren senaryolar için ise Derin Öğrenme mimarilerinin tercih edilmesi gerektiğini göstermiştir.

Anahtar kelimeler: Mikro gaz türbinleri, enerji tahmini, derin öğrenme, zaman serisi analizi.

Choosing the Right AI Model for Power Forecasting in Micro Gas Turbines: A Comprehensive Performance Study

Abstract: This study evaluates the power prediction performance of fourteen different Artificial Intelligence models (traditional Machine Learning and Deep Learning) using a dataset of 71,225 samples from a 3-kilowatt micro gas turbine. The GRU architecture achieved the highest accuracy (RMSE: 12.36; R²: 0.9997), while traditional models such as XGBoost offered competitive performance with significantly lower computational requirements (77.13 seconds versus 855.04 seconds training time). Our findings demonstrate that optimal model selection depends on specific operational requirements, with traditional ML models being preferable for real-time applications and DL architectures for scenarios requiring high accuracy.

Keywords: Micro gas turbines, energy forecasting, deep learning, time series analysis

1. Giriş

Enerji altyapısı karmaşık hale geldikçe, Yapay Zeka'nın (YZ) enerji sistemlerine entegrasyonu kritik hale gelmiştir [1,2]. Enerji üretim sistemleri sofistike hale geldikçe [3], YZ güdümlü modelleme ve tahmin yetenekleri sistem güvenilirliği ve verimliliği için temel araçlar olarak ortaya çıkmıştır. Bu durum özellikle mikro gaz türbinleri gibi dinamik enerji sistemlerinde daha da belirginleşmiştir [4]. Bu noktada akıllı izleme ve kontrol sistemleri karmaşık, yani doğrusal olmayan davranışları ve zamana bağlı tepkileri ele almalıdır.

Mikro gaz türbinlerinde güç tahmini, değişen yük talepleri nedeniyle gerçek zamanlı izleme ve kontrol gerektiren zorlu süreçler içerir. Geleneksel yöntemler, doğrusal olmayan davranış ve kontrol girişlerine gecikmeli tepkiler sergilediğinde geçiş durumlarını modellemede zorlanır [5,6]. Ayrıca uzun vadeli eğitim verilerinin kısıtlılığı ve sistemin iç bileşenlerinden ayrıntılı ölçümler alınmanın yüksek maliyeti pratik kısıtlamalar oluşturur [7].

Mikro gaz türbini uygulamalarında, geleneksel Makine Öğrenmesi (MÖ) ile Derin Öğrenme (DÖ) yaklaşımlarının tahmin doğruluğu ve hesaplama verimliliği açısından kapsamlı karşılaştırması önemli bir araştırma ihtiyacıdır.

1.1. Çalışmanın katkıları

Bu çalışmada, 71.225 örneklik bir veri seti üzerinde 14 farklı YZ modelinin (5 geleneksel MÖ ve 9 DÖ mimarisi) mikro gaz türbini güç tahminindeki kapsamlı karşılaştırması sunulmuştur. Çalışmanın temel katkıları, model performanslarının sistematik değerlendirilmesi, hesaplama verimliliği ile tahmin doğruluğu arasındaki ilişkiyi analiz etme ve farklı operasyonel senaryolar için pratik model seçim rehberlerinin geliştirilmesidir.

* Sorumlu yazar: gazioglu@sirnak.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-7615-305X

2. Literatür Taraması

Güç tahmininde MÖ ve DÖ tekniklerinin uygulanması son on yılda önemli ölçüde gelişmiştir. İlk yaklaşımlar ağırlıklı olarak istatistiksel yöntemlere ve basit regresyon modellerine dayanıyordu [8], ancak alan hızla daha sofistike tekniklere doğru ilerlemiştir. Destek Vektör Makineleri (DVM) ve Rastgele Ormanlar dahil geleneksel MÖ yöntemleri, güç tahmin görevlerinde önemli başarılar göstermiştir [9]. Bu yöntemler, hesaplama verimliliği ve model yorumlanabilirliğinin birincil endişeler olduğu senaryolarda özellikle etkili olmuştur.

Son yıllarda DÖ yaklaşımlarına doğru önemli bir kaymaya tanıklık edilmiştir. Tekrarlayan Sinir Ağları ve varyantları, güç sistemlerinde zamansal bağımlılıkları yakalamada dikkate değer potansiyel göstermiştir [10]. Uzun Kısa Süreli Bellek (LSTM) ağları, çeşitli güç tahmin görevlerine başarıyla uygulanmış, uzun vadeli bağımlılıkları ele almada üstün performans göstermiştir [11-13]. Attention (Dikkat) mekanizmalarının ve transformatör mimarilerinin ortaya çıkması, bu alanda DÖ modellerinin yeteneklerini daha da genişletmiştir [14-17].

Gaz türbinleri ve mikro gaz türbinlerinin özel bağlamında, çeşitli çalışmalar farklı modelleme yaklaşımlarını araştırmıştır. Geleneksel fizik tabanlı modeller kademeli olarak veri güdümlü yaklaşımlarla desteklenmiş veya değiştirilmiştir [18]. Fiziksel içgörülerini MÖ teknikleriyle birleştiren hibrit modeller, karmaşık sistem dinamiklerini yakalamada umut verici sonuçlar göstermiştir [19]. Son çalışmalar, çeşitli çalışma koşullarını ve sistem durumlarını ele alabilen daha sağlam ve uyarlanabilir modeller geliştirmeye odaklanmıştır [18,20].

Güç tahmininde topluluk (ensemble) yöntemlerinin uygulanması da dikkat çekmiştir. Yapılan çalışmalarda, tahmin doğruluğunu ve sağlamlığını artırmak için torbalama (bagging), artırma (boosting) ve istifleme (stacking) dahil çeşitli topluluk stratejileri araştırılmıştır. Ancak, bu yöntemlerin etkinliği genellikle belirli uygulama bağlamlarına ve hesaplama kısıtlamalarına bağlı kalmıştır [21-24].

Alandaki son eğilimler arasında, geliştirilmiş genelleme için fizik-bilgili sinir ağlarının entegrasyonu [25,26], değişen çalışma koşullarına uyum sağlayacak uyarlanabilir öğrenme stratejilerinin geliştirilmesi [27], daha iyi model anlayışı için yorumlanabilir YZ tekniklerinin araştırılması [28-30] ve sistemler arası adaptasyon için transfer öğrenme yaklaşımlarının uygulanması [31-33] yer almaktadır.

3. Materyal ve Yöntemler

3.1. Veri seti açıklaması

Bu çalışmada, [34]'te sunulan zaman serisi veri seti kullanılmış olup, 3 kilowatt gücündeki ticari bir mikro gaz türbini sisteminden elde edilen ölçümleri kapsamaktadır. Bu kapsamlı veri setinde, 8 farklı deney serisine bölünmüş 71.225 örnek bulunmaktadır. Her deney 1,8 ile 3,3 saat arasında sürmüştür. Ölçümler yaklaşık olarak 1 saniye aralıklarla alınmış, bu da türbindeki davranış kalıplarının ince ayrıntılarını incelemek için yüksek zamansal çözünürlük sağlamıştır. Veri seti üç temel değişken içermektedir: saniye cinsinden zamansal bilgi, volt cinsinden kontrol giriş voltajı ve hedef değişken olan watt cinsinden elektrik güç çıkışı. Bu deney serileri iki ana türe ayrılabilir. İlki, kontrol girişinde ani değişiklikler ve güç çıkışında önemli gecikmeler içeren dört dikdörtgen dalga serisi deneyi içermekte olup, geçiş ve kararlı durum fazlarının modellenmesi için kritiktir. Buna karşılık, dört sürekli dalga serisi deneyi, kontrol girişinde kademeli değişiklikler ve güç çıkışında neredeyse hiç gecikme olmadan ilerlemekte ve ağırlıklı olarak kararlı durum davranışının modellenmesine odaklanmaktadır. [34]'te atılan temeller üzerine ilerlenerek, bu makalede ilgili çalışma geliştirilmiş ve bu değerli veri setine çeşitli klasik MÖ ve DÖ yöntemleri uygulanmıştır.

3.2. Veri ön işleme

Kurulan veri ön işleme iş hattında, veri hazırlamaya sistematik bir yaklaşım uygulanmıştır. Veri seti stratejik olarak bölünmüş, Deneylerde, [34]'te uygulandığı gibi 1, 9, 20, 21, 23 ve 24 numaralı veriler eğitim (train) için ayrılırken, 4 ve 22 numaralı veriler test kümesi olarak ayrılmıştır. Özellik mühendisliği ile, 5 ile 30 zaman adımı arasında değişen geriye bakış pencereleri (look-back Windows) oluşturulmuş [35], StandardScaler [36] aracılığıyla standardizasyon uygulanmış ve DÖ modelleri için diziler uygun şekilde yeniden şekillendirilmiştir. Kalite güvencesi önlemleri, veri tamlığının kapsamlı doğrulanması, zamansal tutarlılık validasyonu ve kapsamlı sinyal kalitesi değerlendirmesinden oluşmuştur.

3.3. Karşılaştırmalı değerlendirme yaklaşımı

3.3.1. Klasik makine öğrenmesi modelleri

Bu çalışmada beş geleneksel MÖ yöntemi uygulanmıştır: torbalama topluluk öğrenme yöntemiyle optimize edilmiş rastgele durumla 100 ağaçtan oluşan bir orman kullanan Rastgele Orman [37]. Paralel işleme kullanarak aşırı öğrenmeyi (overfitting) önleyen düzenleme terimlerini içeren ağaç tabanlı bir öğrenme algoritması olan gradyan artırmanın hızlı ve verimli bir uygulaması olan XGBoost [38]. Microsoft'un histogram tabanlı özellik gruplama ve gradyan tabanlı tek taraflı örnekleme eklentisiyle yaprak odaklı ağaç büyüme stratejisi izleyen LightGBM çerçevesi [39]. Radyal tabanlı fonksiyon (RBF) çekirdeği kullanan Destek Vektör Regresyonu (DVR), doğrusal olmayan ilişkileri modellemek için çekirdek dönüşümü, epsilon-duyarsız kayıp fonksiyonu ve düzenleme yöntemlerini içermektedir. Gradyan Artırma ise, ağaç modellerini kare kaybını optimize edecek şekilde sıralı olarak oluşturan klasik bir yaklaşımla, küçültme tabanlı düzenleme kullanılarak uygulanmıştır.

3.3.2. Derin öğrenme mimarileri

Bu çalışmada dokuz DÖ mimarisi kullanılmıştır: LSTM, GRU, BiLSTM, CNN-LSTM, Zamansal Evrişimsel Ağ (TCN), Transformatör, LSTM+Dikkat, CNN-LSTM+Dikkat ve Transformatör-CNN hibridi.

LSTM ve GRU, kapılama mekanizmaları aracılığıyla uzun vadeli zamansal bağımlılıkları yakalamada etkilidir. BiLSTM, dizileri hem ileri hem geri yönde işleyerek bağlamsal bilgiyi artırır. CNN-LSTM hibrit modelleri, evrişimsel katmanlarla yerel özellik çıkarmayı LSTM'in zamansal modelleme gücüyle birleştirir. Transformatör mimarileri öz-dikkat (self attention) mekanizmaları kullanırken, dikkat mekanizmalı varyantlar giriş dizisinin farklı zaman adımlarına uyarlanabilir önem verir.

Tüm modeller iki katmanlı yapıda (64 ve 32 birim), Adam optimizör (öğrenme oranı: 0,001) ve erken durdurma ile eğitilmiştir.

3.3.3. Topluluk yöntemleri

Bu çalışmada üç farklı topluluk yaklaşımı araştırılmıştır. İstifleme için beş temel model kullanılmıştır: Rastgele Orman, Gradyan Artırma, XGBoost, LightGBM ve modele özgü tabanlar. Bir meta-öğrenici temel modele eşit olarak ayarlanmış ve meta-özellik üretimi için çapraz doğrulama uygulanmıştır. Torbalama uygulaması, yerleştirmeli rastgele örnekleme ve tahmin edicilerin paralel eğitimini kullanarak son tahminler için ortalamaları kullanmıştır. Artırma yönteminde, modeller sıralı olarak inşa edilmiş ve gradyanlara dayalı optimize edilmiştir. Optimal performans için öğrenme oranı katsayısı uygulanmıştır.

3.4. Parametre ayarları

MÖ ve DÖ modellerinin performansı, hiper-parametre konfigürasyonlarına bağlıdır. Tablo 1'de, deneyde kullanılan her model için detaylı parametre ayarları gösterilmiştir.

Parametre ayarları, zaman serisi tahmini literatüründeki deneyler ve önceki çalışmalar referans alınarak yapılmıştır. Geleneksel MÖ modellerinde topluluk boyutu ve ağaç parametreleri, DÖ modellerinde mimari derinliği ve öğrenme oranı önceliklendirilmiştir. DÖ modelleri, aşırı uyumu engellemek amacıyla erken durdurma ile eğitilmiş ve en iyi performanslı versiyonları kontrol noktalarına kaydedilmiştir. Tüm DÖ modellerinde Adam optimizör 0,001 başlangıç öğrenme oranıyla kullanılmış, doğrulama kaybı sabitlendiğinde 0,1 faktörle düşürülmüştür.

Geriye bakış penceresi, performansı araştırmanın bir yolu olarak 5 ila 30 zaman adımı aralığında değiştirilmiştir. Bu aralık, zamansal bağımlılıkların yakalanması ile hesaplama fizibilitesinin korunması arasında denge kurularak seçilmiştir. Tüm modeller üç giriş özelliğini dikkate alır: voltaj ölçümü, gücün tarihsel değerleri ve mevcut voltaj. Tüm veriler StandardScaler kullanılarak normalize edilmiş, bu da tüm özellikler arasında aynı ölçeği zorunlu kılmıştır.

Tablo 1. MÖ ve DÖ modelleri için parametre ayarları.

Model Kategorisi	Model	Parametreler	Değer
Geleneksel MÖ	Rastgele Orman	n_estimators max_depth random_state	100 Yok Rastgele(1-100)
	XGBoost	learning_rate max_depth n_estimators random_state	0,1 6 100 Rastgele(1-100)
	LightGBM	learning_rate num_leaves n_estimators random_state	0,1 31 100 Rastgele(1-100)
	DVR	kernel C	RBF 1,0
	Gradyan Artırma	learning_rate n_estimators max_depth random_state	0,1 100 3 Rastgele(1-100)
DÖ (1. Kısım)	LSTM	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	LSTM(64) → LSTM(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	GRU	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	GRU(64) → GRU(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	BiLSTM	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	BiLSTM(64) → BiLSTM(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	CNN-LSTM	CNN katmanları LSTM katmanları yoğun katmanlar aktivasyon optimizasyon	Conv1D(64,3) → MaxPool(2) LSTM(32) → LSTM(16) 8 → 1 ReLU, Doğrusal Adam(lr=0,001)
Model Kategorisi	Model	Parametreler	Değer
DÖ (2. Kısım)	Transformer	attention heads key dimension yoğun katmanlar activation optimizer	8 64 64 → 1 ReLU, Linear Adam(lr=0.001)
	TCN	filters kernel size dilation rates activation dropout	64 3 [1, 2, 4, 8] ReLU 0.2
	LSTM+Attention	LSTM katmanı attention tipi pooling yoğun katman optimizer	LSTM(64) Self-attention Global Average 1 Adam(lr=0.001)
	CNN-LSTM+Attention	CNN katmanı LSTM katmanı attention tipi pooling optimizer	Conv1D(64,3) + MaxPool(2) LSTM(64) Self-attention Global Average Adam(lr=0.001)
	Transformer+CNN	attention katmanı CNN katmanı LSTM katmanı yoğun katman optimizer	Self-attention Conv1D(64,3) + MaxPool(2) LSTM(64) 1 Adam(lr=0.001)
Eğitim Ayarları	Genel	epochs validation split early stopping patience sequence length features	100 0.2 5 5-30 3 (voltage, power, current)
	Callbacks	early stopping model checkpoint learning rate reduction	monitor='val_loss' save_best_only=True factor=0.1, patience=3

*LB (Look-back window): model girdisi olarak kullanılan geçmiş zaman adımı sayısını ifade eder.

3.5. Deneysel kurulum

Deneysel çerçeve, 5-30 zaman adımından kısa vadeli ile uzun vadeli tahmini dikkate alarak kapsamlı zaman penceresi analizini içermektedir. Model hiper-parametreleri her mimari türü için dikkatle ayarlanmıştır; klasik MÖ modelleri tahmin edicilerin ve derinlik parametrelerinin özel konfigürasyonlarını kullanırken, DÖ modelleri çok dikkatli seçilmiş bir öğrenme oranı ve parti boyutu ile Adam optimizasyonunu kullanmıştır. Eğitim prosedürü, kapsamlı

veri standardizasyonu, stratejik veri bölme ve en iyi performansı takip etmek için model kontrol noktalarıyla gerçekleştirilmiştir.

Değerlendirme sürecinde, sadece tahmin doğruluğunun incelemesi değil, aynı zamanda bütün resmin görülmesi de amaçlanmıştır. Bu nedenle, farklı ölçüm türlerini kullanılarak kapsamlı bir test yaklaşımı geliştirildi: Doğruluğu (Accuracy) kontrol etmek için RMSE, Kök Ortalama Kare Yüzde Hatası (RMSPE) ve Ortalama Mutlak Hata (MAE) gibi klasik metrikler kullanılırken, tahminlerin gerçeklikle ne kadar iyi eşleştiğini anlamak için R^2 Skoru ve Pearson korelasyon katsayıları (*Corr*) kullanılmış, göreceli hataların bir anlayışını elde etmek için Ortalama Mutlak Yüzde Hatası (MAPE) kullanılmıştır. Bu değerlendirme metriklerinin matematiksel formülasyonları Denklem 1, Denklem 2, Denklem 3, Denklem 4 Denklem 5 ve Denklem 6'daki gibidir:

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

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2} \times \%100 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times \%100 \quad (5)$$

$$Corr = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (6)$$

burada, y_i gerçek değeri, \hat{y}_i tahmin edilen değeri, \bar{y} gerçek değerlerin ortalamasını, $\bar{\hat{y}}$ tahmin edilen değerlerin ortalamasını ve son olarak n örnek sayısını temsil etmektedir.

4. Deneysel Sonuçlar ve Tartışma

Bu bölüm, dört tamamlayıcı test seti kullanarak deneysel sonuçlarımızın derinlemesine analizi için yapılandırılmış bir çerçeve sağlamaktadır. Deneysel kurulumumuzun açıklamasıyla başlıyor, her mimarinin temel performans özelliklerini belirlememize olanak tanıyan Test Seti 1'de tüm modellerimizin temel değerlendirmesiyle devam ediyoruz. Daha sonra, geriye bakış pencere boyutunun model performansı üzerindeki etkisini test etmek için Test Seti 2'yi kullanıyoruz, ardından Test Seti 3 ile topluluk yöntemlerinin etkinliğinin değerlendirilmesi geliyor. Son olarak, modellerin hesaplama verimliliğine bakıyor ve endüstriyel uygulamalar için pratik sonuçlarını tartışıyoruz. Bu yapılandırılmış yaklaşım, her model konfigürasyonunun hem tahmin performansının hem de pratik değerlendirmelerinin kapsamlı bir incelemesini yapmamızı sağlar.

4.1. Deneysel çerçeveye genel bakış

Bu çalışmada, her biri güç tahmin probleminin farklı yönlerini hedefleyen üç tamamlayıcı test setinden oluşan sistematik bir deneysel çerçeve tasarlandı. Test Seti 1, tüm on dört modelin 10 zaman adımlık sabit bir geriye bakış penceresi kullanılarak birbirleriyle karşılaştırıldığı kapsamlı temel değerlendirme olarak kullanıldı. Bu temel karşılaştırma, üç performans kademesi gösterdi: GRU ve CNN-LSTM+Dikkat gibi yüksek performanslı DÖ modelleri, XGBoost ve LightGBM gibi rekabetçi geleneksel MÖ modelleri ve Transformatör ile DVR gibi nispeten düşük performanslı modeller. Test Seti 2'de geriye bakış pencere boyutunun model performansı üzerindeki etkisi araştırıldı, Test Seti 3'te ise topluluk yöntemlerinin etkinliği değerlendirildi. Tablo 2, her test seti için model seçimleri, geriye bakış pencere boyutları ve topluluk yöntemi varyasyonları dahil olmak üzere detaylı konfigürasyon parametrelerini sunmaktadır.

Tablo 2. Test kümesi ayarları.

Test Seti	Amaç	Modeller	Parametreler
1	Temel Model Karşılaştırma	Tüm modeller (1-14)	Geriye bakış: 10 Topluluk: Yok
2	Geriye Bakış	XGBoost (2)	Geriye bakış: 5,10,15,20,30

Test Seti	Amaç	Modeller	Parametreler
3	Pencere Analizi	LSTM (6) CNN-LSTM (9) Transformatör (10)	Topluluk: Yok
	Topluluk Yöntem Analizi	XGBoost (2) LightGBM (3) Transformatör (10)	Geriye bakış: 10 Topluluk türleri: İstifleme, Torbalama, Artırma

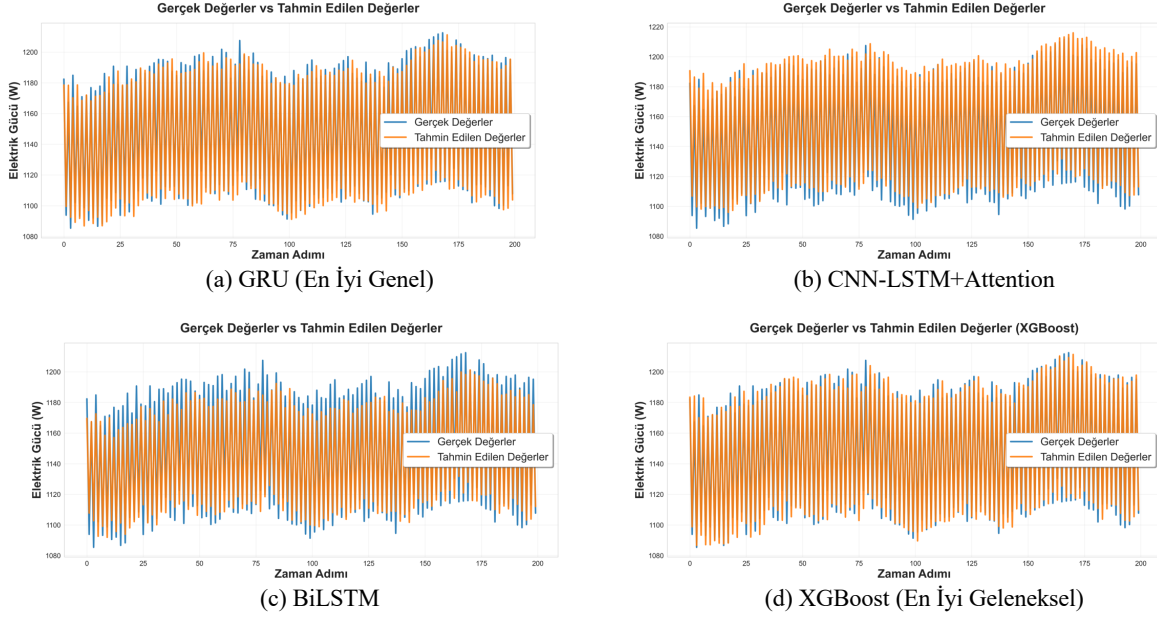
4.2. Temel model performans analizi

Kapsamlı mikro gaz türbini güç tahmini çalışmasında, farklı model mimarileri ve konfigürasyonları için çeşitli önemli bulgular elde edilmiştir. Tablo 3'te görüldüğü üzere, DÖ yöntemleri geleneksel MÖ yöntemlerine kıyasla belirgin şekilde daha iyi performans sergilemiştir. Tablo 3 ve Şekil 1'de sunulan sonuçlara göre, GRU mimarisi test edilen tüm modeller arasında 12,36 RMSE ve 0,9997 R² değerleriyle en yüksek doğruluğa ulaşmış, bunu 13,73 RMSE ve 0,9997 R² ile dikkat mekanizmalı CNN-LSTM izlemiştir. Ancak bu üstün performans, önemli ölçüde daha uzun eğitim süresi gerektirmektedir: GRU 855,04 saniye eğitim süresine ihtiyaç duyarken, XGBoost yalnızca 77,13 saniyede eğitilebilmektedir.

Elde edilen bulgular, gerçek dünya uygulamaları açısından önemli pratik sonuçlar ortaya koymaktadır. XGBoost gibi geleneksel MÖ modelleri, sınırlı hesaplama kaynaklarıyla gerçek zamanlı tahmin gerektiren senaryolarda doğruluk ve verimlilik arasında optimal denge sağlamaktadır. Öte yandan, tahmin doğruluğunun öncelikli olduğu ve yeterli hesaplama kaynaklarının mevcut bulunduğu durumlarda, özellikle dikkat mekanizmaları içeren DÖ yaklaşımları üstün performans sunmaktadır. Pencere boyutu seçiminin kritik bir faktör olduğu gözlemlenmiş, çoğu mimarinin 10-15 zaman adımı aralığında optimal performans gösterdiği belirlenmiştir.

Tablo 3. Test kümesi 1 sonuçları: 10 zaman adımı geriye bakış (LB=10) için modellerin karşılaştırması.

Model	LB	RMSE	RMSPE	MAE	R ²	MAPE	Korelasyon.	Eğitim Süresi (sn)
GRU	10	12.36	0.72	9.09	0.9997	0.51	0.9998	855.04
CNN-LSTM+Att	10	13.73	0.77	9.94	0.9997	0.55	0.9998	419.35
BiLSTM	10	18.43	1.08	13.43	0.9994	0.76	0.9997	610.81
CNN-LSTM	10	19.73	1.02	13.36	0.9994	0.69	0.9997	474.14
LSTM	10	19.20	1.14	14.45	0.9994	0.84	0.9997	720.78
TCN	10	22.02	1.38	14.13	0.9992	0.82	0.9996	398.20
XGBoost	10	26.51	1.01	13.87	0.9989	0.65	0.9995	77.13
LightGBM	10	26.80	1.01	14.07	0.9989	0.66	0.9995	136.95
GBM	10	27.20	1.03	14.68	0.9988	0.69	0.9995	85.19
Random Forest	10	27.48	1.04	13.89	0.9988	0.65	0.9995	223.64
LSTM+Att	10	27.38	1.65	20.84	0.9988	1.20	0.9996	499.73
Transformer	10	39.76	2.26	27.55	0.9975	1.54	0.9988	517.17
Trans+CNN	10	46.96	2.58	33.24	0.9966	1.80	0.9985	353.85
SVR	10	42.57	2.21	33.20	0.9972	1.82	0.9988	2.52



Şekil 1. Önde gelen modellerin performans karşılaştırması: (a) RMSE 12,36 ile en iyi genel performansı elde eden GRU, (b) karşılaştırılabilir performans gösteren CNN-LSTM+Dikkat (RMSE 13,73), (c) güçlü temel performans gösteren BiLSTM (RMSE 18,43), ve (d) en iyi geleneksel MÖ yaklaşımını temsil eden XGBoost (RMSE 26,51).

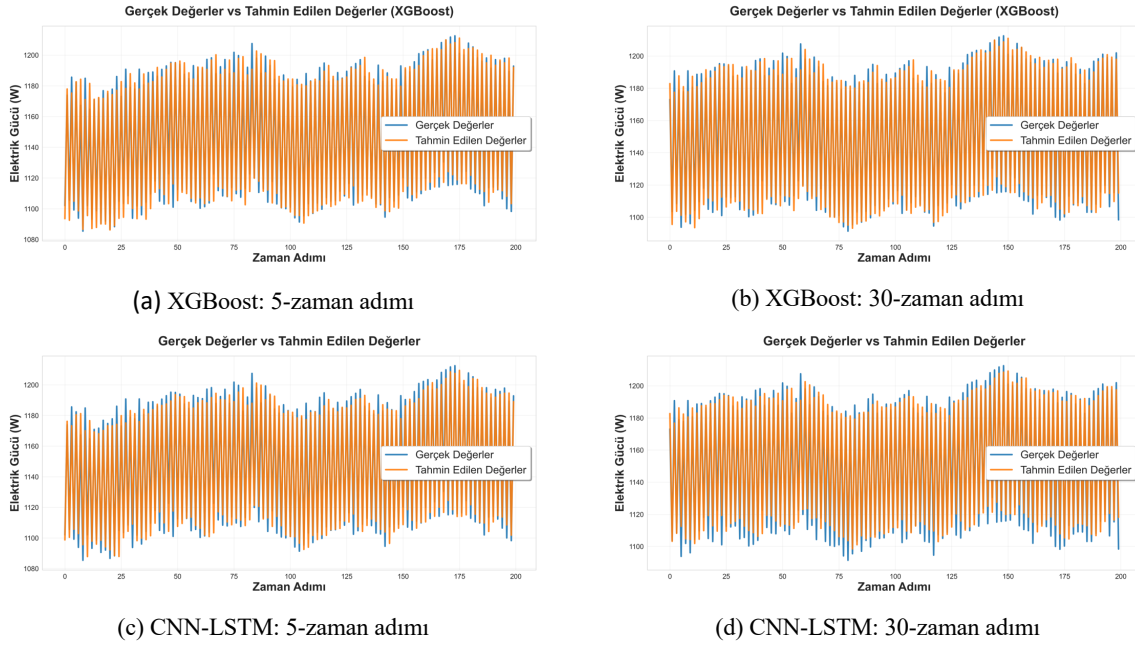
4.3. Geriye bakış pencere boyutunun etkisi

Geriye bakış pencere boyutunun etkisi Tablo 4 ve Şekil 2'de sunulmakta olup, farklı mimarilerde ilginç kalıplar gözlemlenmektedir. Geleneksel MÖ modelleri, özellikle XGBoost, farklı pencere boyutları için oldukça kararlı bir performans sergilemiştir.

Test Seti 2, geriye bakış pencere boyutunun model performansı üzerindeki etkisinin araştırılması amacıyla oluşturulmuştur. Farklı mimari paradigmalardan üç temsili model seçilmiştir: en iyi performans gösteren geleneksel MÖ modeli olarak XGBoost, hibrit mimarilerden güçlü performans sergileyen CNN-LSTM ve Test Seti 1'deki düşük performansının nedenlerini anlamak üzere Transformatör. Bu seçim, deneysel kapsamın yönetilebilir tutulmasının yanı sıra farklı mimari yaklaşımların değişen zamansal bağlam uzunluklarına nasıl tepki verdiğinin incelenmesine olanak sağlamıştır. Diğer modeller, ön testlerde mimari muadilleriyle benzer davranış kalıpları sergilemeleri veya daha az umut verici temel performans göstermeleri nedeniyle değerlendirme dışında bırakılmıştır.

Tablo 4. Test kümesi 2 sonuçları: Geriye bakış pencere analizi.

Model	LB	RMSE	RMSPE	MAE	R^2	MAPE	Corr.	Eğitim Süresi (sn)
XGBoost	5	27.13	1.06	14.26	0.9988	0.68	0.9995	118.43
	10	26.51	1.01	13.87	0.9989	0.65	0.9995	118.16
	15	26.66	1.04	14.07	0.9989	0.67	0.9995	118.84
	20	26.30	1.04	13.98	0.9989	0.67	0.9995	115.89
	30	25.85	0.98	13.47	0.9989	0.64	0.9995	113.79
CNN-LSTM	5	18.53	1.01	11.68	0.9994	0.62	0.9997	257.66
	10	17.88	0.99	12.04	0.9995	0.66	0.9997	734.35
	15	19.02	0.99	12.51	0.9994	0.64	0.9997	668.11
	20	18.50	1.01	11.86	0.9994	0.64	0.9997	548.85
	30	18.23	1.03	12.09	0.9994	0.66	0.9997	778.05
Transformer	5	33.40	1.82	24.67	0.9982	1.35	0.9991	385.03
	10	43.84	2.45	30.67	0.9970	1.70	0.9985	519.47
	15	30.49	1.47	18.58	0.9985	0.94	0.9993	915.92
	20	67.42	3.50	49.65	0.9930	2.77	0.9969	384.46
	30	69.76	3.99	52.68	0.9925	3.02	0.9963	257.31



Şekil 2. Geriye bakış pencere boyutunun model tahminleri üzerindeki etkisi: (a,b) Tutarlı performans gösteren XGBoost için en kısa (5-zaman adımı) ve en uzun (30-zaman adımı) pencereler arasındaki karşılaştırma (RMSE farkı:1,28) ve (c,d) daha kısa pencerelerde optimal performans gösteren CNN-LSTM (RMSE farkı: 0,30).

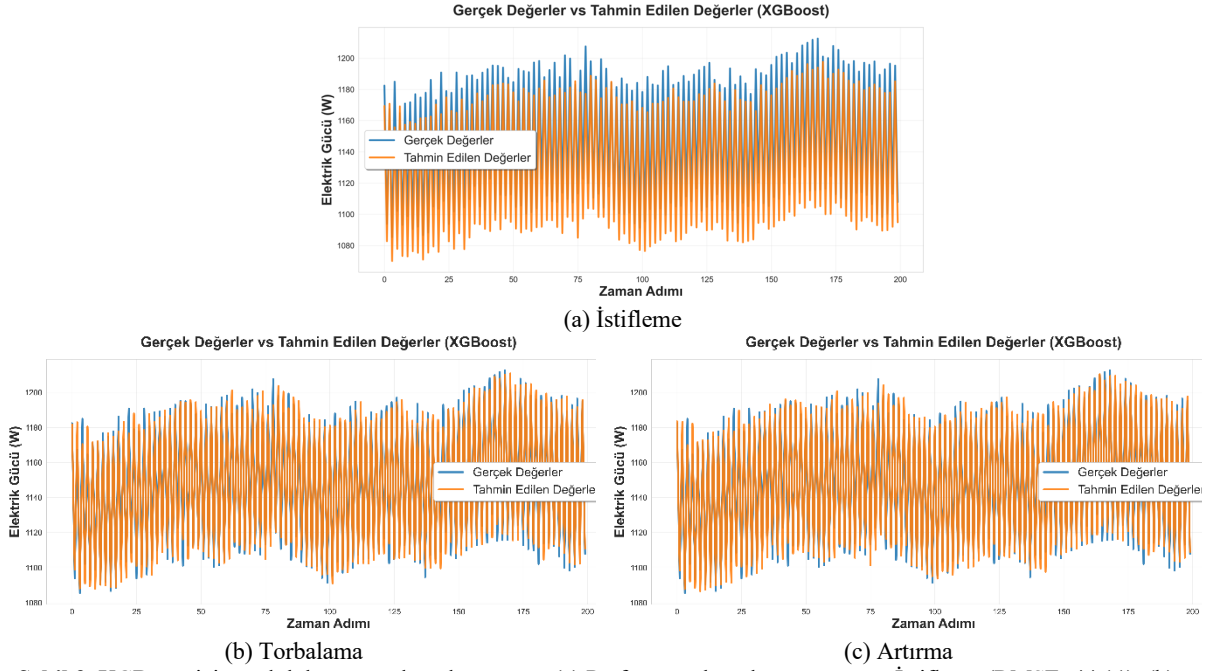
Tablo 5. Test kümesi 3 sonuçları: Topluluk metotları analizi.

Model	Top.	RMSE	RMSPE	MAE	R^2	MAPE	Kor.
XGBoost	1	44,11	1,48	20,28	0,9970	0,86	0,9989
	2	26,55	1,00	13,64	0,9989	0,64	0,9995
	3	26,51	1,01	13,87	0,9989	0,65	0,9995
LightGBM	1	40,37	1,48	19,32	0,9975	0,86	0,9991
	2	26,83	1,02	14,09	0,9989	0,66	0,9995
	3	26,80	1,01	14,07	0,9989	0,66	0,9995
Transformatör	1	43,57	2,36	30,22	0,9971	1,60	0,9986
	2	42,14	2,35	28,14	0,9973	1,53	0,9987
	3	44,56	2,43	31,36	0,9970	1,68	0,9985

4.4. Topluluk yöntemleri analizi

Bu çalışmada, potansiyel performans iyileştirmelerinin değerlendirilmesi amacıyla seçili temel modellerle üç farklı topluluk yaklaşımı araştırılmıştır (Tablo 5, Şekil 3). Elde edilen sonuçlar, mikro gaz türbini güç tahmininde topluluk yöntemlerinin sınırlı etkinliğe sahip olduğunu ortaya koymuştur.

İstifleme yaklaşımının beklenmedik şekilde performans bozulmasına yol açtığı gözlemlenmiştir; XGBoost için RMSE 26,51'den 44,11'e, LightGBM için 26,80'den 40,37'ye yükselmiştir. Torbalama yöntemiyle temel model performansı korunmuş (XGBoost: 26,55 RMSE), ancak hesaplama süresi %50 oranında artmıştır. Artırma yöntemiyle minimal iyileşme sağlanmış (XGBoost: 26,51 RMSE), sadece %10 ek hesaplama yükü getirilmiştir. Bu sınırlı etkinlik, güç tahmin verilerinin zamansal yapısının çeşitli model kombinasyonlarının faydalarını sınırladığına ve temel modellerin zaten öğrenilebilir kalıpların büyük çoğunluğunu yakaladığına işaret etmektedir. Mikro gaz türbini güç tahmini bağlamında, topluluk yöntemlerinin getirdiği ek karmaşıklığın performans faydalarıyla gerekçelendirilemediği sonucuna ulaşılmıştır.



Şekil 3. XGBoost için topluluk yöntem karşılaştırması: (a) Performans bozulması gösteren İstifleme (RMSE: 44,11), (b) Temel performansı koruyan Torbalama (RMSE: 26,55), ve (c) Minimal iyileşme gösteren Artırma (RMSE: 26,51).

5. Sonuç ve Gelecek Çalışmalar

Bu çalışmada, mikro gaz türbini güç tahmini için on dört farklı yapay zeka modelinin kapsamlı karşılaştırması gerçekleştirilmiştir. Geniş kapsamlı deneysel değerlendirmeler sonucunda, derin öğrenme mimarilerinin üstün tahmin doğruluğuna ulaştığı, buna karşın geleneksel makine öğrenmesi modellerinin belirgin hesaplama verimliliği avantajı sunduğu ortaya konmuştur.

Model seçiminin, uygulamaya gereksinimlerine bağlı olarak yapılması gerektiği belirlenmiştir. Gerçek zamanlı tahmin ve sınırlı hesaplama kaynakları gerektiren senaryolarda geleneksel makine öğrenmesi yaklaşımlarının, yüksek doğruluğun öncelikli olduğu uygulamalarda ise derin öğrenme mimarilerinin tercih edilmesi önerilmektedir. Topluluk yöntemlerinin bu özel problemde sınırlı katkı sağladığı, ancak dikkat mekanizmalarının model performansını iyileştirdiği gözlemlenmiştir.

Gelecek araştırmalarda, değişen çevresel koşullar altında model sağlamlığının incelenmesi, uyarlanabilir öğrenme stratejilerinin geliştirilmesi ve derin öğrenme tahminlerinin yorumlanabilirliğinin artırılması yoluyla bu alanda önemli katkılar sağlanabileceği düşünülmektedir.

Özetle, bu çalışma mikro gaz türbini güç tahmininde model doğruluğu ile hesaplama maliyeti arasındaki temel ödünleşimi açık biçimde ortaya koymuştur. GRU ve dikkat mekanizmalı derin öğrenme mimarileri en yüksek tahmin doğruluğunu sağlarken, XGBoost gibi geleneksel makine öğrenmesi modelleri gerçek zamanlı uygulamalar için rekabetçi bir alternatif sunmaktadır. Bu bulgular, farklı operasyonel gereksinimler için uygun model seçimine yönelik pratik bir rehber niteliğindedir.

Kaynaklar

- [1] Su W, Zeng F, Shi M, Xiao X, Sun T, Guo J. A data-driven multi-time scale coordinated economic dispatch model for flexible interconnection low-voltage distribution station areas. In: 2022 Power System and Green Energy Conference (PSGEC); 25-27 August 2022; Shanghai, China. New York, NY, USA: IEEE. pp. 859-867.
- [2] Massaoudi M, Abu-Rub H, Refaat SS, Chihi I, Oueslati FS. Deep learning in smart grid technology: A review of recent advancements and future prospects. IEEE Access 2021; 9: 54558-54578.
- [3] Ahmadi B, Ceylan O, Ozdemir A. Distributed energy resource allocation using multi-objective grasshopper optimization algorithm. Electr Power Syst Res 2021; 201: 107564.
- [4] Ghenai C, Husein LA, Al Nahlawi M, Hamid AK, Bettayeb M. Recent trends of digital twin technologies in the energy sector: A comprehensive review. Sustain Energy Technol Assess 2022; 54: 102837.

- [5] Beucler T, Pritchard M, Rasp S, Ott J, Baldi P, Gentine P, ve diğerleri. Enforcing analytic constraints in neural networks emulating physical systems. *Phys Rev Lett* 2021; 126(9): 098302.
- [6] Robinson H, Pawar S, Rasheed A, San O, ve diğerleri. Physics guided neural networks for modelling of non-linear dynamics. *Neural Netw* 2022; 154: 333-345.
- [7] Gopisetty S, Treffinger P. Generic combined heat and power (CHP) model for the concept phase of energy planning process. *Energies* 2016; 10(1): 11.
- [8] Forootan MM, Larki I, Zahedi R, Ahmadi A. Machine learning and deep learning in energy systems: A review. *Sustainability* 2022; 14(8): 4832.
- [9] Gaboitaolelwe J, Zungeru AM, Yahya A, Lebekwe CK, Vinod DN, Salau AO. Machine learning based solar photovoltaic power forecasting: A review and comparison. *IEEE Access* 2023; 11: 40820-40845.
- [10] Saffari M, Khodayar M. Spatiotemporal deep learning for power system applications: A survey. *IEEE Access* 2024.
- [11] Wang J, Zhu H, Zhang Y, Cheng F, Zhou C. A novel prediction model for wind power based on improved long short-term memory neural network. *Energy* 2023; 265: 126283.
- [12] Jiang T, Liu Y. A short-term wind power prediction approach based on ensemble empirical mode decomposition and improved long short-term memory. *Comput Electr Eng* 2023; 110: 108830.
- [13] Pasandideh M, da Silva JA, Gonzalez-Hernandez JL, Mehr AS, Chen Y, Wang Y, Ting DSK, Carriveau R, ve diğerleri. Predicting steam turbine power generation: A comparison of long short-term memory and willans line model. *Energies* 2024; 17(2): 352.
- [14] Huang S, Yan C, Qu Y. Deep learning model-transformer based wind power forecasting approach. *Front Energy Res* 2023; 10: 1055683.
- [15] Khan ZA, Hussain T, Baik SW. Dual stream network with attention mechanism for photovoltaic power forecasting. *Appl Energy* 2023; 338: 120916.
- [16] Tian C, Niu T, Wei W. Developing a wind power forecasting system based on deep learning with attention mechanism. *Energy* 2022; 257: 124750.
- [17] Dong H, Zhu J, Li S, Wu W, Zhu H, Fan J. Short-term residential household reactive power forecasting considering active power demand via deep transformer sequence-to-sequence networks. *Appl Energy* 2023; 329: 120281.
- [18] Olsson T, Ramentol E, Rahman M, Oostveen M, Kyprianidis K. A data-driven approach for predicting long-term degradation of a fleet of micro gas turbines. *Energy AI* 2021; 4: 100064.
- [19] Belov S, Nikolaev S, Uzhinsky I. Hybrid data-driven and physics-based modeling for gas turbine prescriptive analytics. *Int J Turbomach Propuls Power* 2020; 5(4): 29.
- [20] Aslanidou I, Rahman M, Zaccaria V, Kyprianidis KG. Micro gas turbines in the future smart energy system: Fleet monitoring, diagnostics, and system level requirements. *Front Mech Eng* 2021; 7: 676853.
- [21] Souhaila C, Mohamed M. Ensemble methods comparison to predict the power produced by photovoltaic panels. *Procedia Comput Sci* 2021; 191: 385-390.
- [22] Piotrowski P, Baczyński D, Kopyt M, Gulczyński T. Advanced ensemble methods using machine learning and deep learning for one-day-ahead forecasts of electric energy production in wind farms. *Energies* 2022; 15(4): 1252.
- [23] Akilandeswari A, Raja SP, Shonika S, Anuradha S. Enhancing solar power generation forecasting using advanced machine learning and ensemble methods. In: 2024 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS); 8-9 October 2024; Chennai, India. New York, NY, USA: IEEE. pp. 1-6.
- [24] Li J, Jia L, Zhou C. Probability density function based adaptive ensemble learning with global convergence for wind power prediction. *Energy* 2024; 312: 133573.
- [25] Hu Z, Jagtap AD, Karniadakis GE, Kawaguchi K. When do extended physics-informed neural networks (XPINNs) improve generalization? arXiv preprint arXiv:2109.09444, 2021.
- [26] Kapoor T, Wang H, Núñez A, Dollevoet R. Transfer learning for improved generalizability in causal physics-informed neural networks for beam simulations. *Eng Appl Artif Intell* 2024; 133: 108085.
- [27] Hashmi MB, Mansouri M, Assadi M. Dynamic performance and control strategies of micro gas turbines: State-of-the-art review, methods, and technologies. *Energy Convers Manage X* 2023; 18: 100376.
- [28] Mubarak H, Stegen S, Bai F, Abdellatif A, Sanjari MJ. Enhancing interpretability in power management: A time-encoded household energy forecasting using hybrid deep learning model. *Energy Convers Manage* 2024; 315: 118795.
- [29] Chen Z, Xiao F, Guo F, Yan J. Interpretable machine learning for building energy management: A state-of-the-art review. *Adv Appl Energy* 2023; 9: 100123.
- [30] Machlev R, Heistrene L, Perl M, Levy KY, Belikov J, Mannor S, Levron Y, ve diğerleri. Explainable artificial intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities. *Energy AI* 2022; 9: 100169.
- [31] Li G, Chen L, Liu J, Fang X. Comparative study on deep transfer learning strategies for cross-system and cross-operation-condition building energy systems fault diagnosis. *Energy* 2023; 263: 125943.
- [32] Li G, Zhang X, Mikulski M, Chen X, Ma Z, Ahn J, ve diğerleri. An improved transfer learning strategy for short-term cross-building energy prediction using data incremental. *Build Simul* 2024; 17: 165-183.
- [33] Chen L, Liu J, Li G, Wang Z, Zhang G, Liu Y, Li Y, Cheng L, ve diğerleri. Fault diagnosis for cross-building energy systems based on transfer learning and model interpretation. *J Build Eng* 2024; 91: 109424.
- [34] Bielski P, Eismont A, Bach J, Leiser F, Kottonau D, Böhm K. Knowledge-guided learning of temporal dynamics and its application to gas turbines. In: Proceedings of the 15th ACM International Conference on Future and Sustainable Energy Systems; 4-7 June 2024; Singapore, Singapore. pp. 279-290.

- [35] Ermshaus A, Schäfer P, Leser U. Window size selection in unsupervised time series analytics: A review and benchmark. In: International Workshop on Advanced Analytics and Learning on Temporal Data; 19-23 September 2023; Grenoble, France. Springer. pp. 83-101.
- [36] Maharana K, Mondal S, Nemade B. A review: Data pre-processing and data augmentation techniques. Glob Transit Proc 2022; 3(1): 91-99.
- [37] Probst P, Wright MN, Boulesteix AL. Hyperparameters and tuning strategies for random forest. WIREs Data Min Knowl Discov 2019; 9(3): e1301.
- [38] Nalluri M, Pentela M, Eluri NR. A scalable tree boosting system: XG boost. Int J Res Stud Sci Eng Technol 2020; 7(12): 36-51.
- [39] Ke G, Meng Q, Finley T, Wang T, Chen W, Ma W, Ye Q, Liu TY, ve diğerleri. Lightgbm: A highly efficient gradient boosting decision tree. Adv Neural Inf Process Syst 2017; 30.