



Derin Öğrenme (1D-CNN, RNN, LSTM, BiLSTM) ile Enerji Tüketim Tahmini: Diyarbakır AVM Örneği

Energy Consumption Forecasting with Deep Learning (1D-CNN, RNN, LSTM, BiLSTM): Diyarbakır Shopping Mall Example

Yusuf Berus¹, Yurdağül Benteşen Yakut^{2*}

¹ Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, yusufberus@gmail.com
ORCID: <https://orcid.org/0000-0003-3471-9892>

² Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, bentesen@dicle.edu.tr
ORCID: <https://orcid.org/0000-0003-3236-213X>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 05/01/2024
Revizyon 10/02/2024
Kabul 22/02/2024
Online 30/06/2024

Anahtar Kelimeler:

Enerji tüketim tahmini,
CNN, RNN, LSTM, BiLSTM

ÖZ

Bu makale çalışmada, Diyarbakır il merkezinde yer alan bir alışveriş merkezinin toplam 2027 günlük (5 yıl, 6 ay, 19 gün) aktif tüketim verileri kullanılarak, makine öğrenmesi yöntemleri ile enerji tüketim değişiminin tahmini amaçlanmıştır. Çalışmada kullanılan aktif tüketim miktarı saatlik ölçülerek 2027x24=48648 boyutunda veri seti elde edilmiş olup, gerekli onaylar Dicle Elektrik Dağıtım A.Ş.' den alınmıştır. Enerji aktif tüketiminin tahmini için 1D-CNN, RNN, LSTM ve BiLSTM olmak üzere dört farklı derin ağ modeli geliştirilmiştir. Söz konusu geliştirilen modellerin özellikle tekrarlayan sinir ağları yapısındaki modeller aynı ölçütlerde eğitime tabi tutularak, birbirleri arasındaki performans değerleri karşılaştırılmıştır. Tüm uygulamalar 10 kez tekrar edilerek en yüksek performansa sahip olan değerler kayda alınmıştır. Önerilen modellerin performansı RMSE, MAE ve R^2 ölçütlerine göre değerlendirilmiştir. Farklı mimarilerin önerildiği çalışmada, test veri setine göre determinasyon katsayısı dikkate alındığında Tekrarlayan sinir ağlarının başarımlarının performans aralığının [%92.17, %93.63] bant aralığında olduğu ve önerilen modeller ile belirli düzeyde başarımın elde edildiği gözlemlenmiştir. Tekrarlayan sinir ağlarında başarımların birbirine yakın performans sergiledikleri ve bunların içinde en iyi performansın BiLSTM modelinde ünite-düğüm sayısı 100 olan mimaride elde edildiği görülmüştür. Önerilen mimarilere göre 1D-CNN'in tekrarlayan sinir ağlara göre daha düşük bir performans sergilediği görülmüştür. 1D-CNN mimarisinin geliştirilerek, başarımının artırılacağı düşünülmektedir.

ARTICLE INFO

Article history:

Received 05/01/2024
Received in revised form 10/02/2024
Accepted 22/02/2024
Available online 30 June 2024

Keywords:

Energy consumption forecast,
CNN, RNN, LSTM, BiLSTM

Doi: 10.24012/dumf.1415055

* Sorumlu Yazar

ABSTRACT

This paper estimates the change in energy use using machine learning algorithms on a total of 2027 days (5 years, 6 months, and 19 days) of active consumption data from a mall center in Diyarbakır province. Hourly measurements of the active consumption amount were used in this investigation, and a data set of 2027x24 = 48648 was acquired along with the required clearances from Dicle Electricity Distribution Inc. For the purpose of predicting energy active consumption, four distinct deep network models—1D-CNN, RNN, LSTM, and BiLSTM—have been constructed. The created models under consideration, specifically those with a recurrent neural network topology, underwent training using identical criteria, and their performance values were subsequently compared. The values demonstrating the best performance were noted following 10 iterations of each program. The suggested models' performance was assessed using the R^2 , MAE, and RMSE criteria. The performance range of recurrent neural networks was determined to be in the band range of [92.17%, 93.63%] in the study where different designs were provided, when the coefficient of determination was taken into account in line with the test data set. Indeed, it has been observed that a certain level of performance has been achieved with the proposed models. The results of recurrent neural networks have demonstrated a degree of mutual similarity, with the Unit = 100 architecture in the BiLSTM model demonstrating the highest performance. Based on the proposed topologies, recurrent neural networks are found to outperform 1D-CNN. Performance may be increased by fine-tuning the 1D-CNN architecture.

Giriş

Elektrik enerjisi ekonomik kalkınmanın en önemli motorlarından biridir ve günlük yaşam için vazgeçilmez olarak kabul edilir. Enerji tüketimi gelişmekte olan ülkelerde, dünya çapında sürekli bir şekilde artmaktadır. Enerjiye olan bu ihtiyaç değişimi; elektrik enerjisinin dağıtımının ve ölçümünü de içeren tüketiminin daha iyi planlanmasını gerektirir [1]. Elektrik enerjisinin doğru bir şekilde kullanılması için dağıtılmasının yanısıra ihtiyaç olan miktarda üretilmesi de gerekmektedir. Bu yüzden enerji sektöründe planlama önemli bir yere sahip olmakta ve bunun temelini ise yük talep tahmini oluşturmaktadır. Enerji talebinin doğru bir şekilde tahmin edilememesi, arz ve buna bağlı olarak talep arasında oluşacak farklar ülke ekonomisi üzerinde olumsuz etkiler oluşturabilmektedir [2]. Değişen Enerji pazarlarının derecelendirilmesi, serbestleştirilmesi ve bir ülkenin sosyo-ekonomik gelişimine belirgin etkisi nedeniyle enerji analizi ile elektrik enerjisi tüketimi tahminleri daha da önemli hale gelmiştir [3]. Elektrik yükünün tahmin edilmesi, enerji üretim sistemlerinin planlanması ve modern elektrik tedarik ağlarının verimli çalışması ve sürdürülebilir büyümesi açısından çok önemli bir görevdir [4].

Enerjinin dağıtımının ay sonu değerlerinin bilinmesi için sayaçlar aracılığı ile doğrudan veya uzaktan okuma ile yapılabilmektedir. Ancak okumalar her zaman gerçek tüketim değerlerini yansıtamaya bilmektedir. Enerji Piyasası Düzenleme Kurulu (EPDK) tarafından ay sonu endeks değerlerinin tahmin yoluyla belirlenmesi için tahminleme yapılmaktadır. EPDK tahminleme yöntemine göre; tahmini yapılacak tarih ile en son okuma yapılan tarihin farkı alınmaktadır. Bu sonuç değeri güç değişim katsayısı, endeks ilerleme eğilimi ve mevsimsellik katsayısı ile çarpılarak, ilgili aya ait bir tahmini tüketim değeri hesaplanmış olur [5]. Ancak bu tahminleme yöntemi her zaman doğru olmayabilmektedir. Güç sistemlerindeki elektrik talep miktarını tahmin etmek birçok parametreye bağlıdır. Elektrik yükünün tahmini, karmaşık bir süreçtir ve gelecekteki taleplerin doğru bir şekilde öngörülmesi, enerji talep yönetimi tekniklerinin kullanılmasını gerektirir. Bu süreç, geçmiş verilerin analiziyle başlar ve ardından bu verilerin üzerine kurulmuş modellerin kullanılmasıyla devam eder. Makine öğrenimi yöntemleri, karmaşık doğrusal olmayan bağlantıları geçmiş veri modellerini içeren bir öğrenme süreci aracılığıyla modelleyebildiğinden, elektrik yükünün doğasına iyi bir şekilde uyarlanmıştır [4]. Geçmiş elektrik tüketim verilerinin analizi yapılarak gelecekteki elektrik tüketim miktarlarının tahmini için çeşitli makine öğrenmesi yöntemleri etkili olabilmektedir. Makine öğrenmesi yöntemlerinde zaman serisine bağlı güç bilgisi verileri ile elektrik yükü tahmininde başarılı sonuçlar elde edilebilir. Makine öğrenmesi algoritmaları, veri analizi ile gelecekteki elektrik enerji taleplerini tahmin etme çalışmalarında kullanılabilir. Bu yaklaşım, geçmiş verilerin analizi ile gelecekteki enerji talebini daha doğru bir şekilde tahmin etmeye ve enerji tedarik zincirini daha etkin bir şekilde yönetmeye yardımcı olabilir. Makine öğrenmesi yapay zekanın bir dalıdır. Bilgisayarlara insanlar için doğal gelen bir şeyi yapmayı ve deneyimlerden öğrenmeyi öğreten bir yaklaşımdır. Öğrenme

için örnek sayısı arttıkça algoritmanın performansı uyarlanabilir şekilde artar [6]. Derin öğrenme, otonom sürüşten tıbbi cihazlara kadar pek çok sektöre uygulandığı gözlemlenmektedir [4].

Güç sistemlerinde enerji tahmini için makine öğrenmesi yöntemlerinin kullanıldığı, birçok bilimsel çalışmada görülmektedir. Tablo 1'de enerji tahminleme ile ilgili çeşitli çalışmaların içeriği ve kullanılan yöntemler verilmiştir.

Tablo 1'de görüldüğü üzere geniş bir vizyonda çalışmaların yapıldığı görülmekte olup, makine öğrenmesi yöntemleri ile gerçekleştirilen çalışmaların bazıları; kısa-orta ve uzun vadeli elektrik tüketim tahmini, geçmiş elektrik enerjisi tüketimlerine bakılarak saatlik bazda elektrik tüketim tahmini, önceki dönem verileri ile birlikte güç sistemlerinde talep edilen güç miktarı ile kısa dönem için yük tahmini, güç sistemlerinde meydana gelen kayıp miktarı, belli bir pilot bölge için enerji talep miktarının tahmini, elektrik enerjisinin verimlilikle kullanılması için bir fabrikada çalışan elektrik motorlarının devreye alınmasıdır.

Yapılan çalışmalar incelendiğinde genel anlamda makine öğrenmesi yöntemlerinin kullanıldığı ve elektrik tüketiminin tahmini çalışmalarında özellikle doğal dil işleme amacıyla geliştirilen Tekrarlayan sinir ağı (Recurrent Neural Network, RNN), Uzun Kısa Süreli Bellek Ağları (Long Short-Term Memory, LSTM) ve çift yönlü geçitli yinelenen birim (Gated Recurrent Unit, GRU) yöntemlerinin tercih edildiği görülmektedir. Bu makale çalışmasında, Diyarbakır il merkezinde yer alan bir alışveriş merkezinin 5 yılı aşan aktif tüketim verileri kullanılarak, makine öğrenmesi yöntemleri ile enerji tüketim değişiminin tahmini amaçlanmıştır. Literatürdeki performanslarından kaynaklı olarak derin öğrenme yöntemlerinden Bir Boyutlu *Evrişimli Sinir Ağı* (1D-Convolutional neural network, 1D-CNN), RNN, LSTM ve Çift Yönlü LSTM (Bidirectional LSTM, BiLSTM) yöntemleri bu çalışmada tercih edilmiş ve elde edilen başarımları karşılaştırılmıştır.

Materyal ve Yöntem


Veri Seti ve Uygulanan Ön İşlemler

Çalışma kapsamında kullanılan veri seti için Dicle Elektrik Dağıtım A.Ş.' den temin edilmiş olup, firmanın merkezi Diyarbakır olmak üzere Şanlıurfa, Batman, Mardin, Siirt ve Şırnak illeri kapsamında hizmet verdiği görülmektedir.

Diyarbakır il merkezinde yer alan bir alışveriş merkezinin 01.12.2017-20.06.2023 tarihleri arasında toplam 2027 günlük (5 yıl, 6 ay, 19 gün) aktif tüketim verileri kullanılmıştır. Her saat başı tüketim miktarı ölçüldüğünden, veri seti boyutunun $2027 \times 24 = 48648$ olduğu görülmüştür. Enerji aktif tüketiminin saat çözünürlüğünde değişimi Şekil 1(a)'da ve veri setinde yer alan örneklerin hangi ölçüde tekrar ediyor olduğunu gösteren histogram değişimi Şekil 1(b)'de gösterilmiştir. Veri setinin bulunduğu uzaydaki dağılımının tespiti için istatistiksel değerler hesaplanmış ve elde edilen bilgiler Tablo 2'de verilmiştir.

Tablo 1. Güç sistemlerinde enerji tahmini için makine öğrenmesi tabanlı yapılan örnek çalışmalar

Kaynakça	Yöntem	Performans ölçütü / Başarımı	Çalışmanın içeriği
[7]	LSTM, GRU, RNN, Ototregresif entegre hareketli ortalama (ARIMA)	Gerçek ve tahmin arasındaki uyum oranı / %67.47 ile LSTM, %67.32 ile GRU, %66.17 ile RNN ve %19.48 ARIMA.	Tekstil endüstrisi makinelerinin bekleme durumunda aşırı kaynak tüketimini önlemek amacıyla Derin Öğrenme destekli bir elektrik tahmin modeli tasarlanmıştır.
[8]	Derin Kalıntı Ağları (Deep residual neural network, DRNN), KNN, SVR, Karar Ağacı, Lineer Regresyon, Gradient boosting, XGBoost, random forest	RMSE, MAE, R^2 / Tüm ölçütlere göre DRNN tabanlı model en iyi performansı sergilemiştir.	Slovenia Pecan Caddesi'nde evlerin yaklaşık dört yıllık elektrik enerjisi tüketimi verilerini içeren deneysel analizi ve değerlendirmesi derin öğrenme yöntemleri ile çalışılmıştır.
[9]	Linear Regression, Lasso, Ridge, Elastic Net, Extra Trees Regressor, Random forest, Ada Boost, Gradient boosting Support vector, K-Neighbours	Ort. MSE, Ort. RMSE, Ort. MAE, Ort. R^2 / en iyi performansın Extra Trees Regressor yöntemi ile elde edildiği tespit edilmiştir.	24 saat boyunca elektrik talebi profili tahmin etmek için on bir çevrimdışı öğrenme ve beş çevrimiçi öğrenme algoritmasının etkileri araştırılmıştır.
[10]	LSTM, CNN-RNN Yapay sinir ağları (ANN)	Doğruluk / İki uygulama yapılmış ve her iki uygulamada da sırasıyla %81 ve %78 doğruluk ile CNN-RNN'nin en iyi performansa sahip olduğu gözlemlenmiştir.	Yunanistan'da gerçek yaşam ortamlarında oluşturulan gerçek yük ile tahmin edilen yük arasındaki farkın azaltılması için çalışılmıştır.
[11]	ANN, MLR, Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS), SVM	RMSE / Uzun vadede her iki yıl için SVM, Kısa vadede ise her iki yıl için ANN'nin en iyi performans sergilediği gözlemlenmiştir.	Kıbrıs'ta 2016-2017 verileri ile yapay sinir ağı (ANN), çoklu doğrusal regresyon (MLR), uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) ve destek vektör makinesini (SVM) içeren makine öğrenme stratejileri kullanılarak uzun/kısa vade için elektrik talebinin tahmini üzerine çalışılmıştır.
[12]	LSTM, Lineer Regresyon	MAE, MAPE, Relatif Performans / MAE=11.5, MAPE=%8.7 ve Relatif Performans=%40 ile LSTM en iyi performansı sergilenmiştir.	Finlandiya'da elektrik şebekesi kaybı tahmini için LSTM tekrarlayan sinir ağı modelini önermektedir.
[13]	BiLSTM, GRU, SVR, Deri Öğrenme Regresyon (DLR), XGBoost, AdaBoost, RF	MAPE, RMSE, MSE, R^2 / MAPE=%2.90, RMSE=50.3, MSE=2534.69, R^2 =-0.93 ile DLR en iyi performansı sergilemiştir.	Panama'da elektrik tahmini ile kısa vadeli yük tahmini 1 saat ila 24 saat önceden tahmin edilmesini hedeflemiştir.
[14]	LSTM	MAPE / Farklı makine öğrenmesi yöntemleri içinde en iyi performansı LSTM sağlamıştır (%1.4472).	Zaman serisi verileri gibi sıralı verilerle LSTM derin öğrenme yöntemi ile kısa vadede elektrik tüketimi tahmini yapılmıştır.
[15]	Yapay sinir ağları (ANN)	Korelasyon katsayısı, R^2 / Farklı ANN mimarisinde geliştirilen modeller karşılaştırılmıştır.	Türkiye'deki demiryolu taşıtlarının son 43 yıldaki hat uzunluğu, yolcu sayısı ve yük miktarı değerleri esas alınarak toplam enerji tüketim miktarları incelenmiştir.
[16]	Tam bağlı (Fully Connected) CW, CNN, LSTM	MAE, MAPE, MdAPE / Tüm ölçütlere göre LSTM tabanlı model en iyi performansı sergilemiştir.	Çalışmalarında kullanılan veriler San Antonio'daki dört konuttan toplandı. Derin öğrenme tekniklerini kullanarak aylık enerji tüketimini tahmin edecek bir sistem önerilmiştir.
Önerilen Çalışma	1D-CNN, RNN, LSTM, BiLSTM	RMSE, MAE ve R^2 / Determinasyon katsayısına göre önerilen modellerin başarımlarının performans aralığının [%92.17 %93.63] bant aralığında olduğu gözlemlenmiştir.	Enerji tüketiminden elde edilen saatlik bazda zaman dizisi kullanılarak, geçmiş 5 (lookback=5) değerden oluşan vektörden bir sonraki enerji tüketim değerinin tahmini



Şekil 1. (a) Diyarbakır il merkezinde yer alan bir alışveriş merkezinin 2027 günlük aktif tüketiminin zamanla değişimi (b) Veri setini oluşturan örneklerin histogram değişimi

Veri seti geliştirilen makine öğrenmesi modellerine uygulanmadan önce çeşitli ön işlem adımlarından geçirilmiştir. Bu adımlar aşağıda listelenmiştir.

a) Elektrik tüketimin ölçüm sürecinde veri setinde 17 adet boşluk tespit edilmiştir. Bu boşluklara bir önceki ve bir sonraki değerlerin ortalama değeri atanmıştır.


b) Bu çalışmada kullanılan makine öğrenmesi yöntemlerinin veri ölçeğine bağımlı olmaları nedeniyle, veri seti normalizasyon işlemi ile değer aralığı [0, 1] aralığına dönüştürülmüştür.

c) Veri setinin ilk %80'lik oranı eğitim için ve kalan %20'lik oran ise test veri seti olarak ayrılmıştır. Eğitim setinin ise %20'lik oranı ise çapraz doğrulama için validasyon kümesi olarak ayrılmıştır.

d) Bu çalışmada geri bakış (timestep) değeri farklı değerlerde denenmiş ve en iyi performansın 5 olduğu görülmüştür. Bundan dolayı 5 önceki değere bakılarak bir sonraki değer tahmini gerçekleştirilmiştir. Buna göre oluşturulan veri setinin zaman akışı şekil 2'de gösterilmiştir.

Tablo 2. Çalışmada kullanılan veri setinin istatistiksel bilgileri.

Parametre	Değer
Veri setindeki örnek sayısı (Count)	48666
Ortalama (mean)	1250.57
Standart sapma (std)	1008.94
Minimum (min)	0.00
Seriye baştan %25, sondan %75 oranında iki kısma ayıran değer	358.80
Seriye baştan %50, sondan %50 oranında iki kısma ayıran değer (medyan)	883.20
Seriye baştan %75, sondan %25 oranında iki kısma ayıran değer	1959.60
Maksimum (max)	4678.20



Şekil 2. Oluşturulan veri setinin zaman akışı

Derin Öğrenme Modelleri


Bu çalışmada, enerji aktif tüketiminin tahmini için 1D-CNN, RNN, LSTM ve BiLSTM olmak üzere farklı derin öğrenme modelleri geliştirilmiştir. Dört farklı yaklaşımın kısa açıklamaları ve her dört yaklaşım için önerilen mimarileri bu bölümde açıklanmıştır.

a) CNN Modeli

CNN, bir derin öğrenme yaklaşımı olup, temel olarak iki boyutlu dizileri işleyebilmek amacıyla geliştirilmiştir. İki boyutlu olan bir imgenin kapsamındaki farklı özellikleri algılayabilmek amacıyla, mimariye birçok katman eklenebilmektedir [16]. İmgelerin farklı özellikleri farklı çözünürlüklerde evrişimli filtreler ile elde edilir ve elde edilen çıkış, bir sonraki katmanın girişi olarak uygulanır. CNN mimarisinin kapsamında; konvolüsyon katmanı, aktivasyon katmanı ve havuzlama (pooling) katmanı yer alır. Bu üç katman genel olarak bir grup katman olup, tekrarlanarak iki boyutlu dizilerin özellikleri elde edilmeye çalışılır. Regresyon problemlerindeki sürekli verileri tahmin edebilmek amacıyla, modelin sonuna regresyon katmanı eklenebilmektedir.

Enerji aktif tüketim verileri bir boyutlu olması nedeniyle çalışma kapsamında 1D-CNN ağı tercih edilmiştir.

Tasarlanan derin ağ modelinin detayları Şekil 3'de gösterilmiştir. Birinci CNN katmanında (3,) boyutunda 256 filtre ve aktivasyon fonksiyonu olarak ReLU kullanılmıştır. İkinci CNN katmanında ise yine (3,) boyutunda 128 filtre ve aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Ardından verileri matris biçiminden vektör formuna dönüştürülen flatten katmanı gelir ve son olarak her iterasyonda 1 değer tahmin ettiğimiz için 1 nöron içeren bir katman (Dense) eklenmiştir.




Şekil 3. Tasarlanan 1D-CNN model katmanları

b) RNN Modeli

Yinelemeli Sinir Ağları kullanılarak geliştirilen RNN'ler ardışıl verilerin veya zaman serilerinin tahmin edilmesinde kullanılan bir çeşit yapay sinir ağıdır. Yapay sinir ağlarında olduğu gibi RNN ağlarını eğitmek için de gradyan inişi (gradient descent) ve geri yayılım algoritması kullanılır. Şekil 4'de gösterilen bir RNN ünitesi için çıkış ifadesi denklem (1)'de verilmiştir.

$$h_t = f(W_h h_{t-1} + W_x x_t + b) \quad (1)$$

Denklemden yer alan W ağırlık, b bias, h_t hücrenin t zamanındaki çıktı verisi, x_t ise t zamanındaki girdi verisini ifade eder [16].



Şekil 4. RNN Ünitesi


Çalışmada önerilen modelde tek bir RNN modeli kullanılmış ve ünite-düğüm sayısı 50, 100 ve 500 olarak alınmıştır. Ünite-düğüm sayısı, katmanın çıkış boyutu anlamına gelir ve dolayısıyla giriş örüntüsünün belirtilen çıkış boyutunda temsiline dönüştürülmesi sağlanır. Her üç mimari için tek çıkışlı bir katman (Dense) kullanılmıştır. Tek çıkış olmasının nedeni ise eğitim aşamasında tahmin edilmek istenen değer tek değerden oluşmasıdır (Şekil 2). Her 3 uygulama için oluşturulan mimaride eğitilebilir parametre sayısı Şekil 5'de gösterilmiştir. RNN katmanı için tanh ve Dense katmanı için ReLU aktivasyon fonksiyonu kullanılmıştır.

Mimari 1			Mimari 2		Mimari 3	
Layer (type)	Output Shape	Param #	Output Shape	Param #	Output Shape	Param #
simple_rnn_1 (SimpleRNN)	(None, 50)	2800	(None, 100)	10600	(None, 500)	253000
dense_1 (Dense)	(None, 1)	51	(None, 1)	101	(None, 1)	501
Total params: 2,851 Trainable params: 2,851 Non-trainable params: 0			Total params: 10,701 Trainable params: 10,701 Non-trainable params: 0		Total params: 253,501 Trainable params: 253,501 Non-trainable params: 0	

Şekil 5. Tasarlanan 3 farklı RNN model mimarisinin katmanları ve eğitilebilir parametre sayıları

c) LSTM Modeli

RNN hücrelerinde zamanda geri yayılım algoritması kullanıldığında, ünite sayısının fazla olması durumunda kaybolan veya patlayan gradyan problemlerine sebep olmaktadır. RNN'in eksikliği, kaybolan gradyan problemi nedeniyle uzun vadeli bağımlılıkları hatırlayamamalarıdır [17]. LSTM, uzun vadeli bağımlılık sorunlarına çözüm sunmak amacıyla geliştirilmiştir [18]. LSTM farklı fonksiyonlara sahip kapılardan oluşmaktadır. Örneğin LSTM, farklı zaman adımları arasındaki bilgi akışını kontrol etmek için bir unutmaya kapısına sahiptir. Giriş kapısı, hücreye gelen girdiden yeni bilgilerin öğrenmeye çalışıldığı birimdir ve diğer kapı olan Unutmaya kapısı ise önceki zaman damgasından gelen bilgilerin ilişkili veya unutulabilir olup olmadığına karar verir. Son olarak Çıkış kapısı ise hücredeki güncellenmiş bilgiyi mevcut zaman damgasından bir sonraki zaman damgasına iletir [19].



Şekil 6. LSTM Ünitesi [20]

Şekil 6'da gösterilen bir LSTM ünitesi için çıkış ifadesi denklem (2)'de verilmiştir.

$$\text{Giriş kapısı } i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\text{Unutmaya kapısı } f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (3)$$

$$\text{Çıkış kapısı } o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t * \tanh(C_t) \quad (5)$$

Hücre durumu

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_C * [h_{t-1}, x_t] + b_C) \quad (6)$$

Denklemlerde yer alan σ lojistik sigmoid fonksiyonunu ve W terimleri ise ağırlık matrislerini ifade etmektedir. Kapı olarak belirtilen vektörler, h gizli (hidden) vektörü ile aynı

boyuta sahiptir. LSTM ağında yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid ve hiperbolik tanjanttır.

Çalışmada önerilen modelde tek bir LSTM modeli kullanılmış ve ünite-düğüm sayısı 50, 100 ve 500 olarak alınmıştır. Her üç mimari için tek çıkışlı bir Dense katmanı kullanılmıştır. Her 3 uygulama için oluşturulan mimaride eğitilebilir parametre sayısı Şekil 7'de gösterilmiştir. LSTM katmanında için tanh ve dense katmanı için ReLu aktivasyon fonksiyonu kullanılmıştır.

Mimari 1			Mimari 2		Mimari 3	
Layer (type)	Output Shape	Param #	Output Shape	Param #	Output Shape	Param #
lstm (LSTM)	(None, 50)	11200	(None, 100)	42400	(None, 500)	1012000
dense_3 (Dense)	(None, 1)	51	(None, 1)	101	(None, 1)	501
Total params: 11,251			Total params: 42,501		Total params: 1,012,501	
Trainable params: 11,251			Trainable params: 42,501		Trainable params: 1,012,501	
Non-trainable params: 0			Non-trainable params: 0		Non-trainable params: 0	


Şekil 7. Tasarlanan 3 farklı LSTM model mimarisinin katmanları ve eğitilebilir parametre sayıları

Mimari 1			Mimari 2		Mimari 3	
Layer (type)	Output Shape	Param #	Output Shape	Param #	Output Shape	Param #
bidirectional	(None, 100)	22400	(None, 200)	84800	(None, 1000)	2024000
dense_6 (Dense)	(None, 1)	101	(None, 1)	201	(None, 1)	1001
Total params: 22,501			Total params: 85,001		Total params: 2,025,001	
Trainable params: 22,501			Trainable params: 85,001		Trainable params: 2,025,001	
Non-trainable params: 0			Non-trainable params: 0		Non-trainable params: 0	

Şekil 9. Tasarlanan 3 farklı BiLSTM model mimarisinin katmanları ve eğitilebilir parametre sayıları

d) Çift Yönlü Uzun Kısa Süreli Bellek Ağları (BiLSTM) Modeli

Hem RNN hem de LSTM modeli, bilginin yalnızca zaman içinde ileriye doğru yayılmasına izin verir [21]. Bağlam bilgisini geçmiş ve gelecek zamandan aynı anda yakalamak için çift yönlü RNN geliştirilmiştir. Bu aşamadan sonra şekil 8'de gösterildiği gibi geçmiş ve gelecek bilgilerin etkin kullanımını sağlamak için çift yönlü RNN ve LSTM birimleri birleştirilerek BiLSTM modeli geliştirilmiştir [22-23]. İleri ve geri katmanlardan gelen girdiler, çıktı katmanı tarafından eş zamanlı olarak işlenir [24].



Şekil 8. BiLSTM Ünitesi

Çalışmada önerilen modelde tek bir BiLSTM modeli kullanılmış ve ünite-düğüm sayısı 50, 100 ve 500 olarak alınmıştır. Çift yönlü olması nedeniyle, mimaride düğüm sayısı sırasıyla 100, 200 ve 1000 olduğu görülebilmektedir. Her üç mimari için tek çıkışlı bir Dense katmanı kullanılmıştır. Her 3 uygulama için oluşturulan mimaride eğitilebilir parametre sayısı Şekil 9'de gösterilmiştir. BiLSTM katmanında için tanh ve dense katmanı için ReLu aktivasyon fonksiyonu kullanılmıştır.

Performans Metrikleri

Tahminleme yapılırken algoritma gerçek veri değerleri ile tahminleme sonucunda tespit ettiği değerler arasındaki sapmanın miktarını ve ne kadar olduğunu hesaplayan çeşitli metrikler bulunur. Bu çalışmada önerilen modellerin performansını değerlendirmek için, ortalama mutlak hata (mean absolute error - MAE), kök ortalama kare hatası (root mean square error - RMSE) ve determinasyon katsayısı (the coefficient of determination, R^2) olmak üzere üç gösterge kullanılmıştır. MAE ve RMSE, tahmindeki pozitif ve negatif hataların karşılıklı olarak karşılaştırılmasından kaçınarak, sırasıyla tahmin edilen değerlerin gerçek değere yakınlığını ve tutarsızlığını değerlendirir [24]. R^2 , bağımlı değişkendeki değişikliklerin ne kadarının bağımsız değişkenlerdeki değişikliklerden kaynaklandığını gösterir. R^2 değeri [0 1]

aralığında yer alır ve değerinin 1'e yakınsaması, modelin doğruluğunun artması anlamına gelmektedir.

Aşağıda sırasıyla RMSE, MAE ve R^2 metriklerine ilişkin denklemler verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^* - x_i)^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - x_i^*)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{ve} \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (9)$$

Denklemlerde yer alan x_i , x_i^* , \bar{x} ve n ifadeleri sırasıyla gerçek değeri, tahmin edilen değeri, ortalama değeri ve örneklem büyüklüğünü ifade eder.

Bulgular

Bu makale çalışmasında, Diyarbakır il merkezinde yer alan bir alışveriş merkezinin toplam 2027 günlük (5 yıl, 6 ay, 19 gün) aktif tüketim verileri kullanılarak, makine öğrenmesi yöntemleri ile enerji tüketim değişiminin tahmini amaçlanmıştır. Enerji aktif tüketiminin tahmini için 1D-CNN, RNN, LSTM ve BiLSTM olmak üzere dört farklı derin ağ modeli geliştirilmiştir. Söz konusu geliştirilen modellerin özellikle tekrarlayan sinir ağları yapısındaki modeller aynı ölçütlerde eğitime tabi tutularak, birbirleri arasındaki performans değerleri karşılaştırılmıştır. Modellerin derlenmesinde kullanılan parametreler; kayıp (loss) fonksiyonu olarak ortalama karesel hata (mean squared error

- MSE), optimizasyon algoritması olarak Adam, her bir iterasyonda dikkate alınan örnek sayısı (batch_size) 32 ve eğitim için tam bir tur sayısı (epochs) olarak 50 alınmıştır. Tüm uygulamalar 10 kez tekrar edilerek en yüksek performansa sahip olanlar tespit edilmiştir. Buna göre başarı performansı olan RMSE, MAE ve R^2 ölçütlerine göre elde edilen bulgular değerlendirilmiştir.

a) *1D-CNN Uygulaması için Bulgular:* Öncelikle 1D-CNN modeli için belirlenen mimari ile elde edilen en yüksek başarı performansı Tablo 3'de gösterilmiştir.

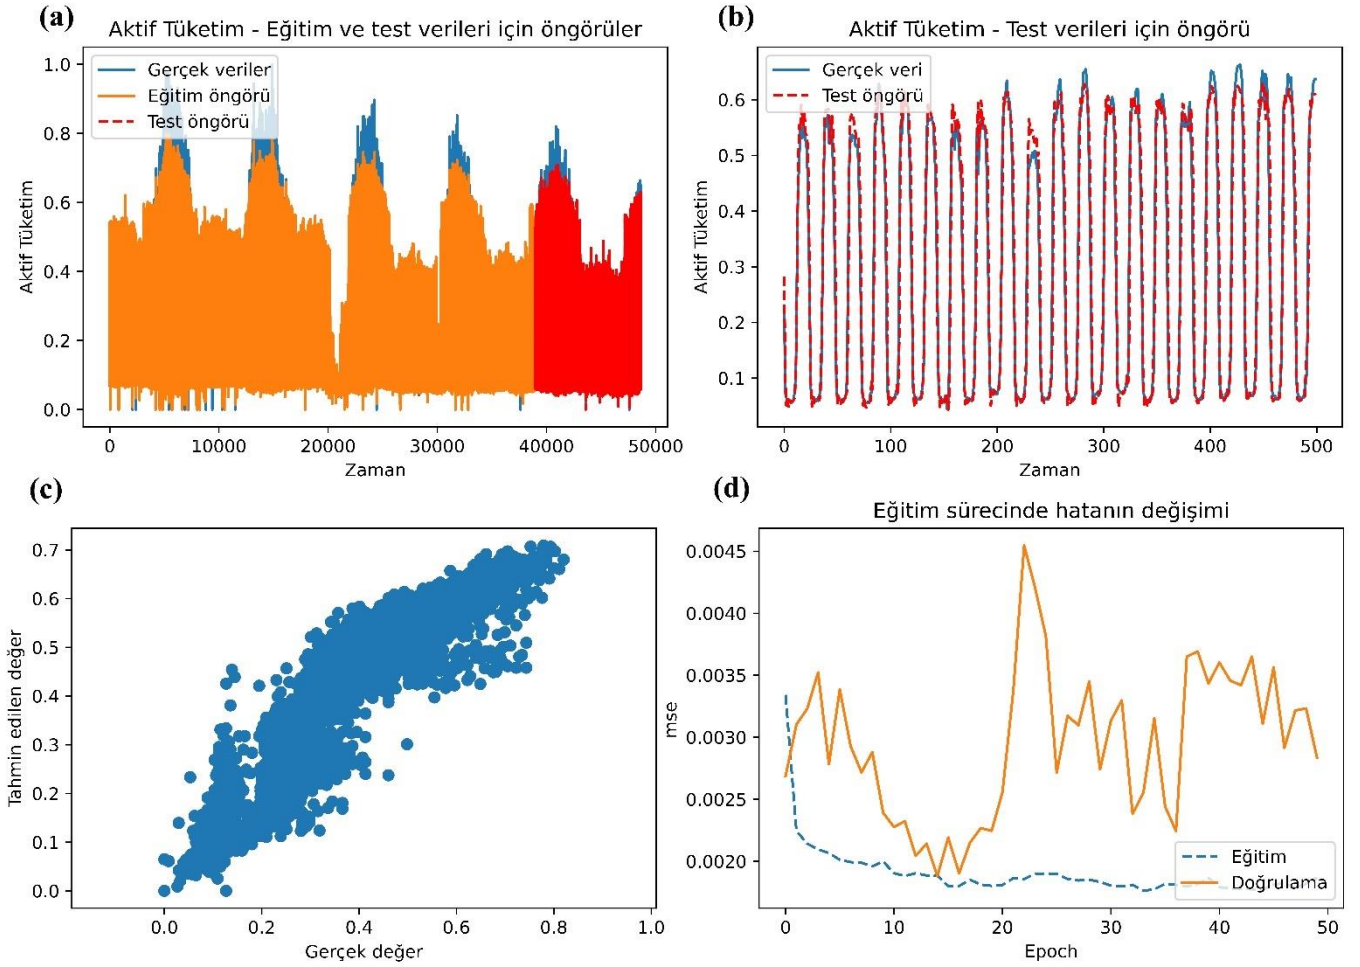
Tablo 3'de sonuçları verilmiş olan mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri şekil 10'da gösterilmiştir. Şekil 10(a)'da hem ölçülen ve hem de eğitim ile birlikte test verileri için elde edilen tüm öngörü değişimleri gösterilmiştir. Elde edilen sonucun daha iyi görülebilmesi için Şekil 10(b)'de test verisinin son 500 örneğine ilişkin elde edilen tahmin grafiği gösterilmiştir. Test tahmin değerleri ve gerçek değerlerin arasındaki ilişkiyi belirlemek için serpilme diyagramından (scatter plot) yararlanılmış ve elde edilen değişim şekil 10(c)'de gösterilmiştir. Şekil 10 (d)'de ise eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi gösterilmiştir.

b) *RNN Uygulaması için Bulgular:* Uygulamada ünite-düğüm sayısı =50, 100 ve 500 için elde edilen en yüksek başarı performansları Tablo 4'de gösterilmiştir.

Tablo 4'de sonuçları verilmiş olan mimarilere ilişkin başarımların birbirine yakın olduğu ancak en iyi performansın ünite-düğüm sayısı 50 olan mimaride elde edildiği görülmektedir. Daha iyi başarımlar sergileyen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri şekil 11'de gösterilmiştir.

Tablo 3. Önerilen 1D-CNN modeli için elde edilen en iyi performans


1D-CNN Ağ Mimarisi	Mimari	RMSE		MAE		R^2	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
	2 Conv katmanı, Flaten ve Dense katmanı	0.0672	0.0529	0.0418	0.0364	0.9064	0.9287



Şekil 10. Enerji tüketim tahmini için saatlik çözünürlükte 1D-CNN modelinin tahmin grafikleri: (a) Ölçülen aktif tüketim ve model ile elde edilen tahmini değerler, (b) Test verisinin son 500 örneğine ilişkin ölçülen aktif tüketim değerleri ve elde edilen tahmini değerler, (c) test veri setinde tahmin ve gerçek değer arasındaki ilişkiyi gösteren serpilme (scatter plot) diyagramı, (d) Eğitim sürecinde elde edilen epoch-mse değişimi.

Tablo 4. Önerilen RNN modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar

RNN Ağ Mimarisi	Ünite-düğüm sayısı	RMSE		MAE		R^2	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
	50	0.0631	0.0520	0.0387	0.0351	0.9176	0.9311
	100	0.0610	0.0525	0.0383	0.0358	0.9228	0.9296
	500	0.0633	0.0554	0.0388	0.0361	0.9170	0.9217



Şekil 11. Enerji tüketim tahmininde RNN modelinin ünite-düğüm sayısı 50 olan mimarisi için tahmin grafikleri: (a) Eğitim ve test verileri için öngörüler, (b) Test verisinin son 500 örneğinin tahmin grafiği, (c) test tahmin ve gerçek verisinin serpilme (scatter plot) diyagramı, (d) Eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi.

Tablo 5. Önerilen LSTM modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar


LSTM Ağ Mimarisi	Ünite-düğüm sayısı	RMSE		MAE		R^2	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
	50	0.061	0.052	0.044	0.03	0.9252	0.9324
	100	0.058	0.047	0.031	0.029	0.9283	0.9334
	500	0.060	0.054	0.034	0.032	0.9192	0.9326

c) *LSTM Uygulaması için Bulgular:* Uygulamada ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en yüksek başarımlar Tablo 5'de gösterilmiştir.

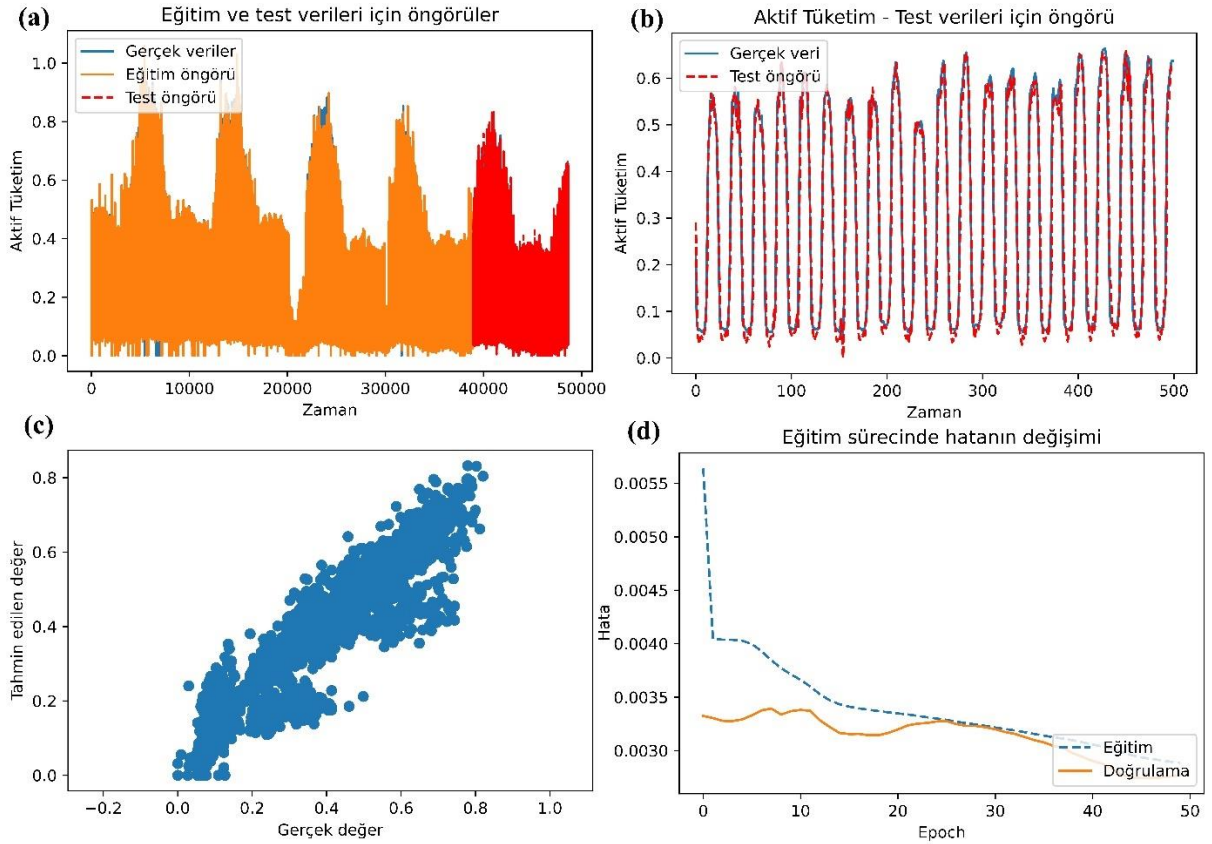
Tablo 5'de sonuçları verilmiş olan mimarilere ilişkin başarımların bir önceki uygulamada olduğu gibi birbirine yakın olduğu ve en iyi performansın ünite-düğüm sayısı 100 olan mimaride elde edildiği görülmektedir. Daha iyi başarımlar sergileyen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri Şekil 12'de gösterilmiştir.

d) *BiLSTM Uygulaması için Bulgular:* Uygulamada yine ünite-düğüm sayısı=50, 100 ve 500 için denenmiş ve elde edilen en yüksek başarımlar Tablo 6'da gösterilmiştir.

Tablo 6'da sonuçları verilmiş olan mimarilere ilişkin başarımların bir önceki uygulamada olduğu gibi birbirine yakın olduğu ve en iyi performansın yine ünite-düğüm sayısı 100 olan mimaride elde edildiği görülmektedir. Daha iyi başarımlar sergileyen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri Şekil 13'de gösterilmiştir.



Şekil 12. Enerji tüketim tahmininde LSTM modelinin ünite-düğüm sayısı 100 olan mimarisi için tahmin grafikleri: (a) Eğitim ve test verileri için öngörüler, (b) Test verisinin son 500 örneğinin tahmin grafiği, (c) test tahmin ve gerçek verisinin serpilme (scatter plot) grafiği, (d) Eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi.



Şekil 13. Enerji tüketim tahmininde BiLSTM modelinin ünite-düğüm sayısı 100 olan mimarisi için tahmin grafikleri: (a) Eğitim ve test verileri için öngörüler, (b) Test verisinin son 500 örneğinin tahmin grafiği, (c) test tahmin ve gerçek verisinin serpilme (scatter plot) diyagramı, (d) Eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi.

Tablo 6. Önerilen BiLSTM modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar.

BiLSTM Ağ Mimarisi	Ünite-düğüm sayısı	RMSE		MAE		R^2	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
	50	0.0608	0.0520	0.0366	0.0354	0.9234	0.9310
	100	0.0588	0.0500	0.0327	0.0317	0.9285	0.9363
	500	0.0588	0.0507	0.0340	0.0345	0.9283	0.9345

Tartışma

Literatüre bakıldığında, çalışmaların daha çok kısa vade üzerinden gerçekleştirildiği diğer bir değişle, saat bazında geçmiş veriler üzerinden güç tüketiminin tahmini yapıldığı görülebilmektedir. Bu makalede yapılan çalışmanın kısa vade açısından özellikle [9, 11-12] nolu çalışmalarla benzerlik gösterdiği görülmektedir. Diğer bir benzerlik ise yöntem açısından derin öğrenme tabanlı (farklı mimarilere sahip) modellerin en iyi performansı sergilemeleridir.

Sonuçlar

Bu makale çalışmasında, Diyarbakır il merkezinde yer alan bir alışveriş merkezinin toplam 2027 günlük (5 yıl, 6 ay, 19 gün) aktif tüketim verileri kullanılarak, makine öğrenmesi yöntemleri ile enerji tüketim değişiminin tahmini amaçlanmıştır. Bu çalışmada kullanılan aktif tüketim miktarı saatlik ölçülerek $2027 \times 24 = 48648$ boyutunda veri seti, Dicle Elektrik Dağıtım A.Ş. kurumundan temin edilmiştir. Enerji aktif tüketiminin tahmini için 1D-CNN, RNN, LSTM ve BiLSTM olmak üzere dört farklı derin ağ modeli geliştirilmiştir. CNN modelinde iki evrişim katman kullanırken, diğer tekrarlayan sinir ağları için ünite-düğüm sayısı sırasıyla 50, 100 ve 500 alınmıştır. Tüm uygulamalar 10 kez tekrar edilmiş ve RMSE, MAE ve R^2 ölçütlerine göre en yüksek performansa sahip olan başarımlar kayda alınmıştır.

Elde edilen bulgulara göre yapılabilecek çıkarımlar aşağıda listelenmiştir.

- Önerilen mimarilere göre 1D-CNN'in tekrarlayan sinir ağlara göre daha düşük bir performans sergilediği görülmüştür. Önerilen 1D-CNN modeline ilişkin performansın beklenen seviyenin altında kaldığı ancak çeşitli güncellemeler ile performansın artırılacağı düşünülmektedir. Bu güncellemeler çeşitli stratejiler içerir ki bunlar; mimari tasarımında ayarlamalar (model derinliğinin artırılması, filtre boyutlarının ayarlanması ve artık bağlantıların kullanımı), düzenleme teknikleri (dropout tekniği, Batch Normalizasyon işlemi, zamanla öğrenme katsayısının düşürülmesi, vs.) ve veri ön işlemdir. Söz konusu güncellemeler ile başarımın artırılacağı düşünülmektedir.
- Farklı mimarilerin önerildiği çalışmada, test veri setine göre determinasyon katsayısı dikkate alındığında Tekrarlayan sinir ağlarının başarımlar performans aralığının [%92.17, %93.63] bant aralığında olduğu ve önerilen modeller ile belirli düzeyde başarımın elde edildiği gözlemlenmiştir.

- Tekrarlayan sinir ağlarında başarımların birbirine yakın performans sergiledikleri ve bunların içinde en iyi performansı ünite-düğüm sayısı 100 olan BiLSTM modeli ile elde edildiği görülmüştür.

Literatür çalışmasında, elektrik tüketiminin tahmini için kısa, orta ve uzun vadeli olarak yapıldığı görülmekte olup, yapı olarak benzer yöntemlerin (CNN, RNN, LSTM, BiLSTM, GRU) izlendiği görülmektedir. Bu çalışmada da orta vadede elde edilen geçmiş veriden yola çıkılarak enerji tüketiminin tahmini gerçekleştirilmiştir. Bu çalışmada önerilen modeller geliştirilerek, farklı sektörlerle ilişkin enerji tüketim verilerine uygulanması, gelecek çalışmalar kapsamında değerlendirilmektedir.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkıları

Yazar makaleyi tasarladı, literatür taraması yaptı ve analizler yaptı, sonuçları tartıştı ve makaleyi yazdı.

Teşekkür

Bu tez çalışmasında Dicle elektrik dağıtım şirketinden (DEDAŞ) veriler alınmıştır. Dağıtım şirketine verilerin kullanımı için izin verdiğinden dolayı teşekkür ederim.

Kaynaklar

- [1] Berriel, R. F., Lopes, A. T., Rodrigues, A.O, Varejao, F. M. and Oliveira-Santos, T. (2017). *Monthly energy consumption forecast: a deep learning approach* [Bildiri sunumu] IEEE, Brazil.
- [2] Kaysal, K., Akarlan, E. ve Hocaoglu, F. O. (2022). Türkiye kısa dönem elektrik yük talep tahmininde makine öğrenmesi yöntemlerinin karşılaştırılması. *Bseu Journal Of Science*, 9(2), 693-702. <https://doi.org/10.35193/bseufbd.1004827>
- [3] Bedi, J. ve Toshniwal, D. (2019). Deep learning framework to forecast electricity demand. *Applied Energy*, 238, 1312-1326. <https://doi.org/10.1016/j.apenergy.2019.01.113>
- [4] Solyali, D. (2020). A comparative analysis of machine learning approaches for short-/long-term electricity load forecasting in cyprus. *Sustainability*, 3612(12), 2-34. [doi:10.3390/su12093612](https://doi.org/10.3390/su12093612)

- [5] Gezmez, K. Ç. (2022). *Bir ilin elektrik tüketim verilerinin makine öğrenmesi yöntemleri ile analizi* [Yayımlanmamış yüksek lisans tezi]. Başkent Üniversitesi.
- [6] Bouktif, S.; Fiaz, A.; Ouni, A.; Serhani, M.A. Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies* **2018**, *11*, 1636. [CrossRef]
- [7] Yurdođlu, H. (2023). *Bir tekstil fabrikasının elektrik tüketim değerlerinin derin öğrenme ile tahminlenmesi* [Yayımlanmamış yüksek lisans tezi]. Pamukkale Üniversitesi
- [8] Kiprijanovska, İ., Stankoski, S., Ilievski, İ. ve Jovanovski, S. (2020). Houseec: day-ahead household electrical energy consumption forecasting using deep learning. *Energies*, *13*(2672), 2-29. [10.3390/en13102672](https://doi.org/10.3390/en13102672)
- [9] Kell, A. J., MCGOUGH, A. S. ve FORSHAW, M. (2021). The impact of online machine-learning methods on long-term investment decisions and generator utilization in electricity markets. *Sustainable Computing: Informatics And Systems*, *30*,1-12. <https://doi.org/10.1016/j.suscom.2021.100532>
- [10] Kollia, İ. ve KOLLIAS, S. (2018, May). *A deep learning approach for load demand forecasting of power systems*. IEEE, Çeşme/İzmir
- [11] Tulensalo, J., Seppänen, J. ve Ilin, A. (2020). An lstm model for power grid loss prediction. *Electric Power Systems Research*, *189*,1-4. <https://doi.org/10.1016/j.epsr.2020.106823>
- [12] Ibrahim, B., Rabelo, L., Gutierrez-Franco, E. ve Clavijo-Buritica, N. (2022). Machine learning for short-term load forecasting in smart grids. *Energies*, *8079*(15), 2-19. <https://doi.org/10.3390/en15218079>
- [13] Torres, J. F., Lvarez, F. M. ve Troncoso, A. (2022). A deep lstm network for the spanish electricity consumption forecasting. *Neural Computing And Applications*, *34*, 10533–10545. <https://doi.org/10.1007/s00521-021-06773-2>
- [14] Kuşkan, E., Çodur, M. K. ve Çodur, M. Y. (2022). Türkiye'deki demiryolu enerji tüketiminin yapay sinir ağları ile tahmin edilmesi. *Konya Journal Of Engineering Sciences*, *10*(1), 72-84. [10.36306/konjes.935621](https://doi.org/10.36306/konjes.935621)
- [15] X. Wan, H. Song, L. Luo, Z. Li, G. Sheng, and X. Jiang, "Pattern recognition of partial discharge image based on one-dimensional convolutional neural network," In 2018 Condition Monitoring and Diagnosis (CMD), 2018, pp. 1-4.
- [16] M. Tosun, F. ŞENTÜRK, (2023). Kasislerin Yakıt Tüketimine Etkisinin RNN, LSTM, GRU Tekrarlayan Derin Öğrenme Algoritmaları ile Tespiti. *Journal of Intelligent Systems: Theory and Applications*, *6*(1), 12-23. <https://doi.org/10.38016/jista.1141359>
- [17] Fu, Y., Lou, F., Meng, F., Tian, Z., Zhang, H., Jiang, F., 2018. "An Intelligent Network Attack Detection Method Based on RNN". 2018 IEEE Third International Conference on Data Science in Cyberspace (DSC), 483–489. <https://doi.org/10.1109/DSC.2018.00078>
- [18] P. Bahad, P. Saxena, and R. Kamal, "Fake news detection using bi-directional LSTM-recurrent neural network," *Procedia Computer Science*, vol. 165, pp. 74-82, 2019.
- [19] S. Patil, V. M. Mudaliar, P. Kamat, S. Gite, "LSTM based Ensemble Network to enhance the learning of long-term dependencies in chatbot," *International Journal for Simulation and Multidisciplinary Design Optimization*, vol. 11, no. 25, 2020.
- [20] Olah, C. (2015). Understanding lstm networks. <https://colah.github.io/posts/2015-08-Understanding-LSTMs>.
- [21] S. Zhang, D. Zheng, X. Hu ve M. Yang, Bidirectional long short-term memory networks for relation classification, In *Proceedings of the 29th Pacific Asia conference on language, information and computation*, 73-78, 2015.
- [22] Ekinci, E., İlhan Omurca, S., Özbay, B. Comparative assessment of modeling deep learning networks for modeling ground-level ozone concentrations of pandemic lock-down period, *Ecological Modelling*, 2021, 457, pp. 109676.
- [23] Graves, A., Schmidhuber, J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures, *Neural Networks*, 2005, *18*(5-6), pp. 602-610.
- [24] Karaman, Ö. A., & Bektaş, Y. (2023). Makine Öğrenmesi ve Optimizasyon Yöntemleri ile Uzun Dönem Elektrik Enerjisi Tahmini: Türkiye Örneği. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, *5*(2), 285-292. <https://doi.org/10.46387/bjesr.1306577>