

established in  
2016

# MAS JOURNAL of Applied Sciences

ISSN 2757-5675

DOI: <http://dx.doi.org/10.52520/masjaps.v7i2id168>

Araştırma Makalesi

## Elektrik Enerji Tüketim Tahmininde Yapay Yenilemeli Sinir Ağı Modellerinin Karşılaştırılması

Enes AVCİ<sup>1\*</sup> (Orcid ID: 0000-0002-7774-9138), Musa AYDIN<sup>1</sup> (Orcid ID: 0000-0001-5545-1456)<sup>1</sup>Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Bursa

\*Sorumlu yazar: enesavci@outlook.com

Geliş Tarihi: 25.01.2022

Kabul Tarihi: 28.02.2022

### Özet

Teknolojinin gelişmesi ve verinin öneminin artmasıyla akıllı şebekelerin önemi ve etkisi her geçen gün artmaktadır. Akıllı şebekelerde sensörler, akıllı sayaçlar, akıllı reaktif güç röleleri gibi verilerin toplanmasına yardımcı olan cihazlar bulunmaktadır. Elektrik güç tüketim verileri, toplanan veri türlerinden birisidir. Modern güç sisteminin gelişimi boyunca yük tahmini temel konu olmuştur. Akıllı şebekelerde enerji tüketim profillerinin kestirimi sonucunda enerji arzının planlaması, şebeke bakım sürelerinin kestirilmesi gibi konularda kullanılmaktadır. Yük tahmininde istatistiksel yöntemler, zaman serisi yöntemi ve son zamanlarda popüler olan yapay sinir ağları metodu kullanılmaktadır. Yapılan bu çalışmada elektrik enerjisi yük tahmini için yapay sinir ağı modelleri kullanılmıştır. Çalışmada kullanılan veriler, Amerika Birleşik Devletleri'nin Eastern Kentucky eyaletinin enerji tüketim verilerinden alınmıştır. Veriler yapay sinir ağına verilmeden önce normalizasyon işlemi ile standartlaştırılmıştır. Elektrik yük tahmini için yapay zekâ tabanlı tahmin algoritması olan Yenilemeli Sinir Ağı (YSA), Yenilemeli Sinir Ağı Tabanlı Uzun-Kısa Süreli Bellek (UKSB) ve Evrişimsel Sinir Ağı-Uzun-Kısa Süreli Bellek (ESA-UKSB) beraber kullanılmıştır. Kentucky eyaleti enerji tüketim verileri bu üç model üzerinde, her biri 50 dönüm (epoch) yapılarak, kayıp fonksiyonu ise "Adam" en iyileştirici kullanılarak eğitilmiştir. Eğitilen modeller aynı test kümesi üzerinde denenip elde edilen verilerle elektrik tüketim enerji miktarları tahmin edilmeye çalışılmıştır. Bu modeller; tahmin edilen veriler ile gerçek veriler, ortalama kare hata ve ortalama mutlak hata katsayıları seçilip karşılaştırılarak değerlendirilmiştir. Modellerden elde edilen verilerin karşılaştırılması sonucunda Evrişimsel Sinir Ağı-Uzun-Kısa Süreli Bellek modelinin diğer iki modellere göre test verileri üzerinde en az hata oranı verdiği sonucuna ulaşılmıştır.

**Anahtar Kelimeler:** Elektrik yük tahmini, yenilemeli yapay sinir ağı, evrişimsel sinir ağı, uzun-kısa süreli bellek, akıllı şebeke

### Comparision Of Artificial Recurrent Neural Network For Load Forecasting

#### Abstract

With the development of technology and increasing importance of data, the importance and impact of smart grids is increasing day by day. In smart grids, there are devices that help collect data such as sensors, smart meters, smart reactive power relays. Electrical power consumption data is one of the data types collected. Load estimation has been a key issue throughout the development of the modern power system. Estimation of energy consumption profile in smart grids is used in the planning of energy supply, estimation of grid maintenance times. Statistical methods, time series method and recently popular artificial neural network method are used in load estimation. In this study, artificial neural network models were used for electrical energy load estimation. The data used in the study were taken from the energy consumption data of the Eastern Kentucky state of the United States. Before the data were given to the artificial neural network they were standardized by the normalization process. Recurrent neural network (RNN), Long short term memory (LSTM) and Convolutional neural network-Long short term memory (CNN-LSTM), which are Artificial intelligence-based prediction algorithms, were used together for electrical load estimation. State of Kentucky energy consumption data were trained on these models using the Adam optimizer, each with fifty epoch and loss functions. Kentucky state energy consumption data were trained on these three models, each one 50 epoch (epoch) and using the "Adam" optimizer as the loss function, too. The trained models were tried to estimate the electricity consumption energy amounts on the same test set. These models were evaluated by selecting and comparing the estimated data with the actual data by choosing the mean square error and mean absolute error coefficients. As a result of the comparison of the data obtained from the models, it was concluded that the Convolutional Neural Network- Long Short-Term Memory (CNN-LSTM) model gave the least error rate on the test data compared to the other two models.

**Keywords:** Electricity load forecasting, LSTM, RNN, LSTM-CNN, smart grid

## GİRİŞ

Teknolojinin gelişmesi ve verinin öneminin artmasıyla akıllı şebekelerin önemi ve etkisi her geçen gün artmaktadır. Akıllı şebekelerde sensörler, akıllı sayaçlar, akıllı reaktif güç röleleri gibi verilerin toplanmasına yardımcı olan cihazlar bulunmaktadır. Elektrik güç tüketim verilerde toplanan veri türlerinden birisidir. Modern güç sisteminin gelişimi boyunca yük tahmini temel konu olmuştur. Uzun dönemli yük tahmini, güç sistemi alt yapısına ve planlanmasına yardımcı olmayı amaçlamaktadır. Orta ve kısa dönem yük tahmini sistem yönetimi için faydalı olabilir(Welcong Kong et al., 2017). Literatürde elektrik yük tahmini üzerine birçok çalışma vardır. Son zamanlarda popüler olan ve diğer modellere göre doğruluğu yüksek olan yapay sinir ağları modelleri çok tercih edilen modeller olarak karşılaşılmaktadır. Wenjie Lu ve arkadaşları (2020) yaptıkları çalışmada, CNN-LSTM tabanlı borsa tahmin fiyatlaması çalışması yapılmıştır. Bu çalışmada oluşturulan modelde veriler, ilk önce CNN katmanından, sonrasında LSTM katmanından geçirilmiştir. Çalışmada MLP (Multilayer Perceptron) CNN, RNN, LSTM, CNN-RNN, CNN-LSTN modelleri aynı veri üzerinde test edilmiş olup MAE (Mean absolute error ) ve RMSE (Root mean square error) doğruluk değerleri alınarak karşılaştırma yapılmıştır. Yapılan karşılaştırmada CNN-LSTM modeli, ortalama mutlak

değer hatası 27.564 ve karekök ortalama hatası 39.688 ile modeller arasında en düşük hata değerini alarak en iyi model olduğu saptanmıştır. Türkiye için yapılan çalışmalarda elektrik tüketim tahmini çalışmaları yapılmıştır. Hamzaçebi çalışmasında 1970'ten günümüze ülkenin büyümesiyle paralel elektrik tüketim değerlerinin arttığını göstermiş. Çalışmasında tüketim değerlerini endüstri, konut, tarım ve ulaşım olarak dört ana başlıkta toplamıştır. Oluşturduğu yapay sinir ağı modeli ile tüketim değerlerini tahmin etmiş gerçek değerleri ayırdığı dört ana başlıkta hata değerlerini göstermiştir(Coşkun Hamzaçebi, 2006).

## MATERYEL ve YÖNTEM


Yük tahmininde istatistiksel yöntemler, zaman serisi yöntemi ve son zamanlarda popüler olan ve yapay sinir ağları metodu kullanılmaktadır.

### Yapay sinir ağları

Yapay sinir ağları insan beyni çalışması örnek alınarak modellenmiştir. Bu bölümde veriler üzerinde uygulanan modeller açıklanmıştır.

### Evrişimsel sinir ağı (ESA)

ESA, sinir ağının ileri besleme türüdür. Görüntü işleme ve doğal dil işlemede iyi sonuçlar vermektedir( Y. Xue, C. Wang, and C. Miao, 2020). ESA çalışma yapısı şekil 1'de gösterilmiştir. ESA başlıca Evrişim katmanı ve havuzlama katmanı olarak iki bölümden oluşmaktadır.




Şekil 1. ESA çalışma biçimi

Şekil 1’den de görüleceği üzere, giriş olarak verilen resim standartlaştırılarak siyah–beyaz görüntü haline getiriliyor. Sonrasında, evrişim işlemi gerçekleştirilmektedir. Evrişim, rastgele değerlere sahip görüntü filtresinin giriş görüntüsün değerleri ile yapılan işleme denmektedir (Ali Arı ve ark., 2019). Evrişim işleminden sonra görüntünün belirgin ve önemli özellikleri çıkartılır. Sırasıyla yapılan evrişimsel işlemler arasında havuzlama yapılarak verinin boyutu azaltılarak daha hızlı ve sinir ağına gereksiz kısımların gitmesi engellenmiş olur (Berna Arı, 2017). Birkaç kez evrişim ve havuzlama işlemi yapıldıktan sonra elde edilen matrisi

vektör haline getirebilmek için düzeltme işlemi yapılır. Düzeltme işleminden sonra elde edilen vektör, yapay sinir ağına verilir ve tahmin değerleri ile gerçek değerler arasındaki hata miktarına göre ağırlıklar güncellenir.

#### Yenilemeli Yapay Sinir Ağları (YSA)

Yenilemeli sinir ağları, doğal dil işleme süreçleri, konuşmaların tanımlanması ve zaman serisi tahmininde güçlü bir yeteneğe sahip yapay sinir ağıdır (Chujie Tian ve ark., 2018). Yenilemeli sinir ağının çalışma yapısı şekil 2’de gösterilmiştir (Salah Bouktif ve ark., 2018).



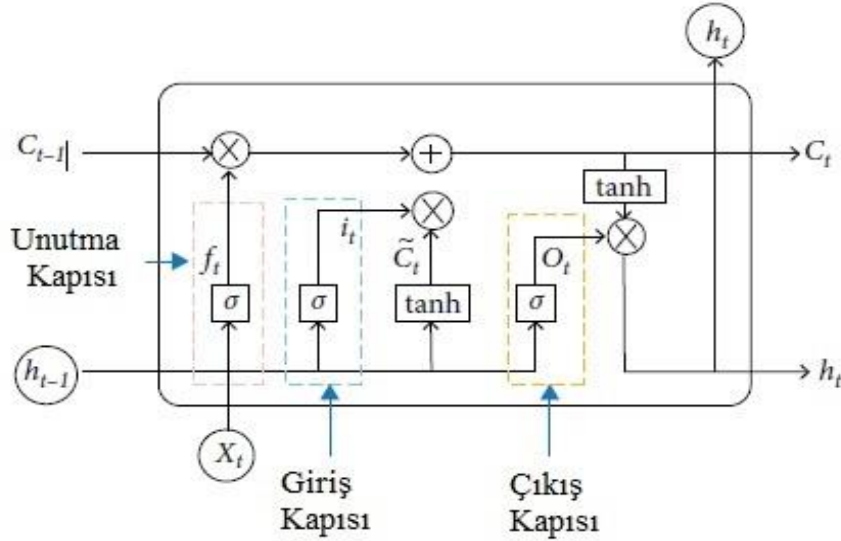
Şekil 2. Yenilemeli sinir ağı yapısı

Yenilemeli sinir ağı, benzer görevleri yerine getirmek için sıralanmış elemanlardan oluşmaktadır. Her bir elemanın girişi bir önceki dizinin elemanın çıkışından alınmaktadır. Yenilemeli sinir ağlarının önemli özelliği, kaydedilen bilginin bir sonraki elamana aktarılabilmesidir (Salah Bouktif ve ark., 2018). Yenilemeli sinir ağı geçmiş dönem değerlerinden sadece bir önceki verileri alması konusunda dezavantajının olmasının yanında geri yayılımda, türev işlemlerinde ve türevin sıfır olduğu durumlarda öğrenme

gerçekleşmemesi dezavantajlarına da sahiptir. Bu problemlerin üstesinden gelebilmek için yenilemeli sinir ağını temel alan kısa süreli bellek sinir ağı modeli oluşturulmuştur.

### Uzun-Kısa Süreli Bellek Yapay Sinir Ağları (UKSB)

Uzun Kısa süreli bellek (UKSB, “LSTM, Long Short Time”) modeli Schmidhuber tarafından 1997’de sunulmuştur (Wenjie Lu ve Ark., 2020). UKSB yapısı şekil 3’de gösterilmektedir (Wenjie Lu ve Ark., 2020).



Şekil 3. UKSB Yapısı

UKSB hafıza hücresi, Unutma geçiti, Çıkış geçiti, Güncelleme geçiti olmak üzere dört bölümden oluşmaktadır. Bir önceki elemandan çıkan çıkış değeri, yani  $h_{t-1}$  ile, giriş değeri  $X_t$  değeri

olarak formüle edilir. Unutma geçiti, Güncelleme geçiti ve Çıkış Geçidi'nin denklemleri (1), (2) ve (3) numaralı denklemlerle gösterilmektedir.

$$f_t = \sigma(W_f * [h_{t-1}, X_t] + b_f) \quad (1)$$

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

$$o_t = \sigma(W_o * [h_{t-1}, X_t] + b_o) \quad (3)$$

Aday değerin hesaplanması için de (4) numaralı denklem kullanılmaktadır.

$$\tilde{C}t = \tanh(Wf * [ht - 1, Xt] + bf) \quad (4)$$

Bir önceki değerin unutulacağı veya güncelleneceğine (5) numaralı denklem sonucunda karar verilmektedir.

$$Ct = Ut * \tilde{C}t + ft * Ct - 1 \quad (5)$$

UKSB'nin Çıkış değeri  $h(t)$  ise, çıkış kapısının değeri ile hücrenin çıkış değeri çarpılarak elde edilmektedir. Bu değer, (6) numaralı denklem ile gösterilmiştir.

$$ht = Ot * Ct \quad (6) \quad (\text{Salah Bouktif ve ark, 2018}).$$

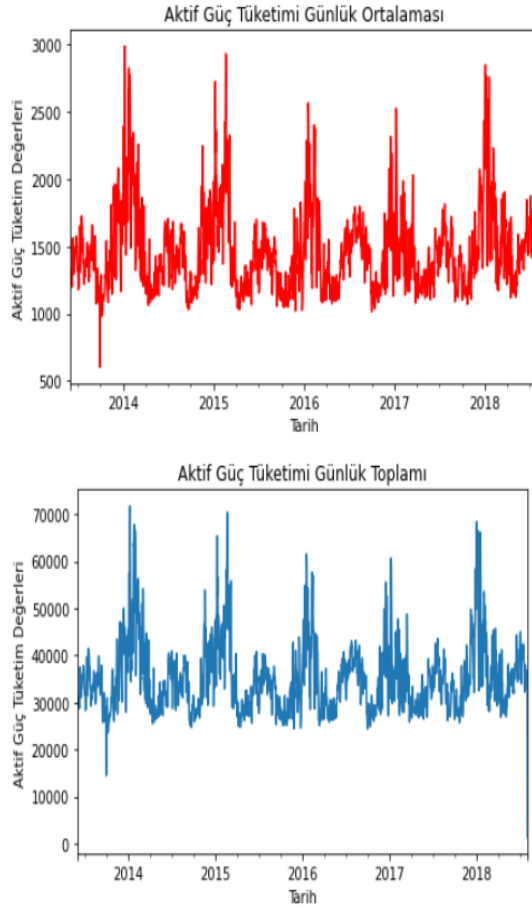
### Veri Paketi

Bu çalışmada kullanılan veriler, (<https://www.kaggle.com/robikscube/hourly-energy-consumption>, 1 Mart 2022)

web sayfasından alınmıştır. Amerika Birleşik Devletleri'nde enerji iletim organizasyonu olan PJM tarafından paylaşılan verilerde yer alan Eastern Kentucky eyaletinin enerji tüketim verileri kullanılmıştır. 31.12.2013 ile 02.01.2018 arasındaki tarihleri arasında yer alan günlerin her saatine ait tüketim verileri alınmış 45334 satırdan oluşmaktadır. 02.01.2017-02.01.2018 tarihleri arasındaki 13871 örnek, test veri seti; 31.12.2013-02.01.2017 arasındaki 31463 örnek ise eğitim veri seti olarak ikiye ayrılmıştır. Örnek olarak, veri setinin ilk 5 satırı Çizelge 1'de verilmiştir. Verilerin tüketilen güç değerlerinin günlük ortalaması ve toplamı şekil 4'te verilmiştir.

**Çizelge 1.** Tüketim verilerinin ilk beş satırı

	Datetime	EKPC_MW
0	2013-12-31 01:00:00	1861.0
1	2013-12-31 02:00:00	1835.0
2	2013-12-31 03:00:00	1841.0
3	2013-12-31 04:00:00	1872.0
4	2013-12-31 05:00:00	1934.0



Şekil 4. Tüketilen Güç Değerlerinin Günlük Ortalaması ve Toplamı

### Modelin Değerlendirilmesi

Model çıktılarından elde edilen sonuçların değerlendirilmesi için birçok performans ölçütü bulunmaktadır. Bu

çalışmada, ortalama mutlak hata (denk. 7) ve ortalama kare hatası (denk. 8) performans ölçütü olarak seçilmiştir.

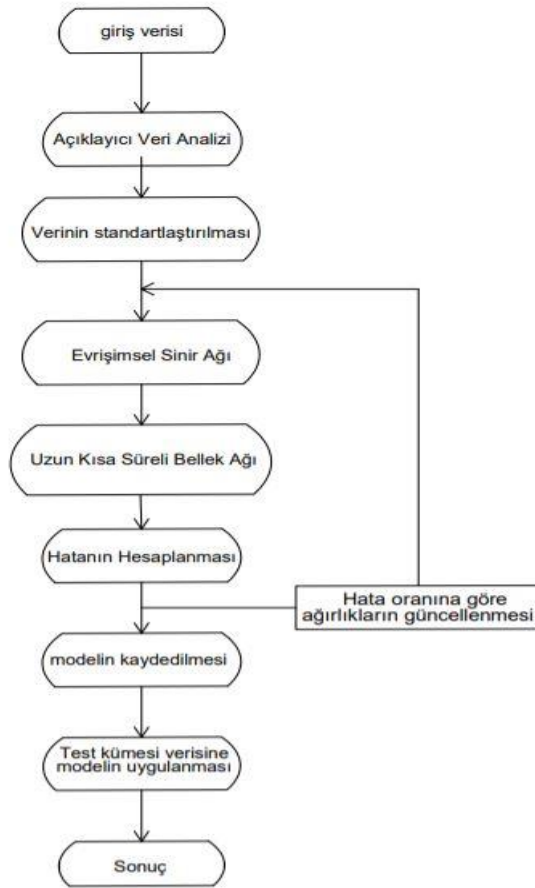
$$MAE = \frac{1}{N} * \sum_{L=1}^N |yp - yc| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} * \sum_{L=1}^N |(yp - yc)^2|} \quad (8) \quad (\text{Cagatay Catal, Ahmet Kaşif, 2021})$$

### Model geliştirme

Bu çalışmada, elektrik yük tahmini için Yenilemeli Sinir Ağı (YSA), Uzun Süreli Bellek (UKSB) ve UKSB ile Evrişimsel sinir ağının birlikte

kullanıldığı UKSB-ESA olmak üzere üç farklı model test edilmiştir. Modelleri geliştirmek için açık kaynaklı Python programlama dili kullanılmış olup model diyagramı şekil 5'te verilmiştir.




Şekil 5. ESA-UKSB Modelinin eğitim test ve tahmin süreçleri diyagramı

### Modellerden Elde Edilen Çıktılar

Yapay Sinir Ağları modelleri, her biri 50 dönüme (“epoch”) sahiptir. Kayıp fonksiyonu “Adam optimizer” kullanılırken tahmin edilen ve gerçek değerler arasında hata oranı hesaplanırken Ortalama kareler hatası (“mean squared error”) alınmıştır.


### Yenilemeli Sinir Ağı (YSA)

Yenilemeli Sinir Ağı modeli ile eğitim verileri eğitildiğinde kayıp fonksiyonun hızlı bir şekilde düşüşün olduğu ve beşinci dönemden sonra kayıp değerinin aynı kaldığı gözlenmiştir(Bkz. Şekil 6).



Şekil 6. RNN Kayıp fonksiyonun eğitim şeması



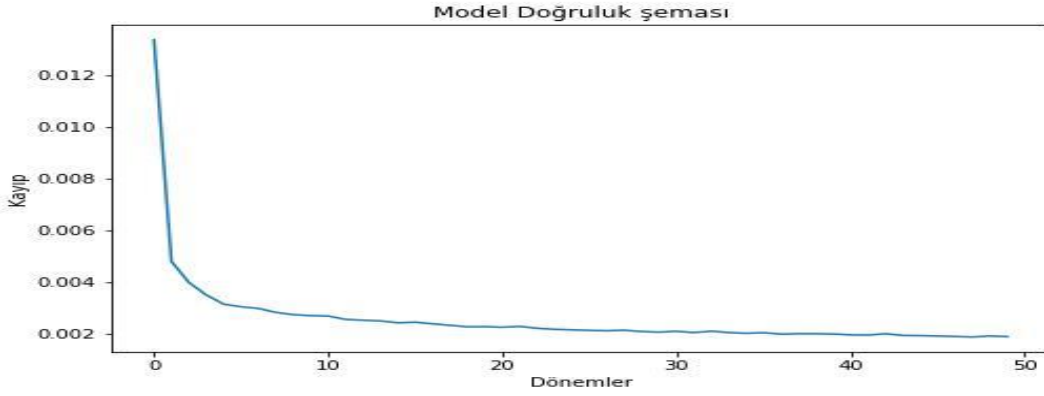


Şekil 7. RNN Test kümesi ve Tahmin edilen değerler

Tahminlerin Mutlak ortalama hatası 55.4059, karekök ortalama hatası ise 7288.7373 çıkmıştır. Tahmin ve Test grafikler şekil 7’de verilmiştir.


**Yenilemeli Sinir Ağı Tabanlı Uzun Kısa Süreli Bellek (USKB)**

Yenilemeli Sinir Ağı Tabanlı Uzun Kısa Süreli Bellek ile eğitim verileri eğitildiğinde kayıp fonksiyonunun yirmi beşinci dönemden sonra sabit kaldığı gözlenmektedir (Bkz. Şekil 8).



Şekil 8. Kayıp fonksiyonun eğim şeması






Şekil 9. UKSB Test kümesi ve Tahmin edilen değerler

Tahminlerin Mutlak ortalama hatası 40.9299 karekök ortalama hatası ise 4692.5205 çıkmıştır. Tahmin ve Test grafikler şekil 9’da verilmiştir.

**Evrşimsel Sinir Ağı – Yenilemeli Sinir Ağı (ESA-UKSB)**


Evrşimsel Sinir Ağı – Yenilemeli Sinir Ağı ile eğitim verileri eğitildiğinde kayıp fonksiyonunun kırkncı dönemden sonra sabit kaldığı gözlenmektedir. (Bkz. Şekil 10)



Şekil 10. Kayıp fonksiyonunun eğitim şeması

Yapılan çalışmada veriler, dört yıllık verilerle eğitildikten sonra son bir yılın verileri ile test edilmiştir. Son iki yıla ait


test verilerinin tahmin değerleri şekil 11’de gösterilmiştir.



Şekil 11. LSTM Test kümesi ve Tahmin edilen değerler

Tahminlerin Mutlak ortalama hatası 37.9985, karekök ortalama hatası ise 3891.7939 çıkmıştır. Tahmin ve Test grafikler şekil 11’de verilmiştir. Yenilemeli Sinir Ağı, Uzun Kısa Süreli Bellek, Ağı ve Uzun Kısa Süreli Bellek,-

Evrişimsel Sinir Ağı modelleri karşılaştırma yapıldığında USKB-ESA modelinin veri seti üzerindeki Ortalama Mutlak Hata değerinin en az olduğu gözlenmiştir.(Bkz. Şekil 12).



Şekil 12. Modellerin ortalama mutlak hata oranları ile karşılaştırılması

## SONUÇLAR

Yenilemeli Sinir Ağı (YSA), Uzun Kısa Süreli Bellek (UKSB) ve Evrişimsel Sinir Ağı (ESA) gibi derin öğrenme metotları bir çok alanda kullanılmaktadır. Uzun Kısa Süreli

bellek hafıza hücresi sayesinde daha önceki bilgileri yenilemeli sinir ağına göre hafızasında tutabilmektedir. Ayrıca işe yaramayan bilgileri ise unutmaya geçidinden geçerek unutulması gereken bilgiler unutulmaktadır. Uzun Kısa

Sürelî bellek ile Evrişimsel Sinir Ağı modeli birlikte kullanılarak modeller geliştirilmiştir. Bu modelde ise Evrişim işlemi katmanı ile verinin özellikleri çıkartılır ancak çıkartılan özellik boyutları çok yüksek olduğundan havuzlama katmanı sokularak eğitim maliyetinin azaltılır ve modelin hızlı çalışabilmesi sağlanır. Matris şeklinde edilen veriler vektör haline getirebilmek için düzleştirme işlemi yapılır. Düzleştirme işleminden sonra elde edilen vektör, Uzun Kısa Sürelî Bellek Modeline verilir. ESA-UKSB Modeli özellik çıkarımı sayesinde UKSB Modeline göre iyileştirilme sağlanmıştır. Bu çalışmada, elektrik enerjisi tüketim tahmininde yapay yenilemeli sinir ağı modellerinin (YSA, UKSB, UKSB-ESA) karşılaştırılması yapılmıştır. Veri olarak, Amerika Birleşik Devletleri Eastern Kentucky eyaletinin enerji tüketim değerleri kullanılmıştır. Modeler Veri seti üzerinde test edilmiştir. Ortalama Mutlak Hata değeri üzerinden modeller karşılaştırılmıştır. Karşılaştırmalardan, UKSB-ESA modelinin veri seti üzerindeki Ortalama Mutlak Hata değerinin en az olduğu gözlenmiştir.

#### KAYNAKÇA

- Ali Arı ve ark., Tumor detection in MR images of regional convolutional neural networks, Journal of the Faculty of Engineering and Architecture of Gazi University 34:3, 1395-1408,
- Berna Arı, Kayısı Yapraklarının Evrişimsel Sinir Ağları Kullanılarak Sınıflandırılması, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Teknolojileri Mühendisliği, Fırat Üniversitesi, 2017.
- Cagatay Catal, Ahmet Kaşif, Energy Load Forecasting Using a Dual-Stage Attention-Based Recurrent Neural Network, Sensors(Basel), October, 27;21(21):7115,2021.
- Chujie Tian, Jian Ma, Chunhong Zhang and Panpan Zhan , A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network, Energies, 2018.
- Çoşkun Hamzaçebi, Forecasting of Turkey's net electricity energy consumption on sectoral bases, 2017. <https://www.kaggle.com/robikscube/hourly-energy-consumption> <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>, Şekil 1)
- Salah Bouktif ve ark, Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches, Energies, 2018, Şekil 2).
- Y. Xue, C. Wang, and C. Miao, "Research on financial assets transaction prediction model based on LSTM neural network," Neural Computing and Applications, vol. 1, 2020.
- Welcong Kong, Yan Xu, David J. Hill, Short-Term Residential Load Forecasting based on LSTM Recurrent Neural Network, IEEE Transactions on Smart Grid · September 2017.
- Wenjie Lu, 1,2 Jiazheng Li, 3 Yifan Li, 3 Aijun Sun , 1 and Jingyang Wang, 3, A CNN-LSTM-Based Model to Forecast Stock Prices, Hindawi, Complexity, Volume 2020. 2019., Şekil 3)