

**ENERJİ SİSTEMLERİNDE MAKİNE ÖĞRENMESİ İLE
GÜÇ TÜKETİM TAHMİNİ**

YUSUF BERUS

HAZİRAN 2024

DIYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENERJİ SİSTEMLERİNDE MAKİNE ÖĞRENMESİ İLE
GÜÇ TÜKETİM TAHMİNİ**



YUSUF BERUS

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

HAZİRAN 2024

DİYARBAKIR

ENERJİ SİSTEMLERİNDE MAKİNE ÖĞRENMESİ İLE GÜÇ TÜKETİM TAHMİNİ

Yusuf BERUS tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik Elektronik Mühendisliği Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Dr.Öğr. Üyesi Yurdagül BENTEŞEN YAKUT
Danışman, **Elektrik Elektronik Mühendisliği Bölümü**
Dicle Üniversitesi

Sınav Jürisi:

Doç.Dr. Muhammet Ali ARSERİM (*)
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Dr. Öğr. Üyesi Yurdagül BENTEŞEN YAKUT (**)
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Doç.Dr. Temel ÖZDEMİR
Elektrik Elektronik Mühendisliği Bölümü,
Fırat Üniversitesi

ONAY

Savunma Tarihi: 26 / 06 / 2024

(*) Jüri Başkanı.

(**)Tez Danışmanı.



Anne ve Babama...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanıyla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Yusuf BERUS

İmza:

TEŞEKKÜR

Bu tez çalışmasında bana yardımcı olup yol gösteren, emeklerini esirgemeyen, süreci ilerletmeme sabırla destek olan ve öğrencisi olmaktan her zaman gurur duyacağım danışman hocam Sn. Dr. Öğr. Üyesi Yurdağül BENTEŞEN YAKUT' a en içten teşekkürlerimi sunarım.

Elektrik ve Elektronik Mühendisliği saha uygulamalarının yeni bilimsel gelişmeler perspektifinden ilerlemesi konusundaki etkin çaba ve emeklerinden ötürü Mühendislik Fakültesi Dekanı Prof.Dr. Mehmet Sıraç ÖZERDEM'e teşekkürü borç bilirim.

Çalışmamız Dicle Elektrik Dağıtım A.Ş. sorumluluk alanında bulunan Diyarbakır ilinde faaliyet gösteren bir AVM'nın tüketim verileri kullanılarak yapılmıştır. Dicle Elektrik şirketine verdiği izinlerden dolayı dolayı teşekkür ederim.

Akademik çalışmalara karşı yaptığı teşvik ve verdiği destekten dolayı Dicle Elektrik Yönetimine, akademik çalışmam esnasından desteklerini esirgemeyen her kademedeki Dicle Elektrik çalışan ailesine şükranlarımı sunarım.

Varlıkları ile gurur duyduğum tüm bu süreç boyunca bana inanıp motive eden sevgili aileme teşekkür ederim.

İÇİNDEKİLER

| | |
|--|------|
| TEŞEKKÜR..... | v |
| İÇİNDEKİLER | vi |
| TABLolar LİSTESİ..... | viii |
| GRAFİKLER LİSTESİ..... | ix |
| ŞEKİLLER LİSTESİ | xi |
| SİMGELER ve KISALTMALAR LİSTESİ..... | xii |
| ÖZET..... | xiii |
| ABSTRACT..... | xiv |
| 1. GİRİŞ | 1 |
| 1.1 Literatür Taraması..... | 2 |
| 1.2 Problemin Tanımı Ve Tezin Amacı..... | 7 |
| 1.3 Tezin Yapısı | 7 |
| 2. TÜRKİYE’DE GÜÇ SİSTEMLERİ VE ENERJİ PİYASASI İLE İLGİLİ GENEL BİLGİLER | 9 |
| 2.1 Türkiye’de Elektrik Enerji Üretimi..... | 9 |
| 2.2 Elektrik İletim Hatları | 9 |
| 2.3 Enterkonnekte Elektrik Sistemi..... | 10 |
| 2.4 Türkiye’de Elektrik Enerjisi Dağıtımı | 10 |
| 2.5 Türkiye’de Elektrik Enerjisi Talebi | 11 |
| 2.6 Elektrik Piyasası Kanunu | 14 |
| 2.7 Enerji Tahmini | 14 |
| 3. MATERYAL VE YÖNTEM..... | 16 |

| | | |
|-------|--|----|
| 3.1 | Veri Seti Ve Uygulanan Ön İşlemler | 16 |
| 3.2 | Yapay Zeka | 19 |
| 3.3 | Makine Öğrenmesi | 20 |
| 3.3.1 | Denetimli öğrenme | 21 |
| 3.3.2 | Denetimsiz öğrenme..... | 22 |
| 3.3.3 | Pekiştirmeli öğrenme | 22 |
| 3.4 | Derin Öğrenme..... | 23 |
| 3.5 | Evrışimli Sinir Ağları (CNN) Modeli | 26 |
| 3.6 | Yinelemeli Sinir Ağı (RNN) Modeli | 27 |
| 3.7 | Uzun Kısa Süreli Bellek Ağları (LSTM) Modeli..... | 27 |
| 3.8 | Çift Yönlü Uzun Kısa Süreli Bellek Ağları (BiLSTM) Modeli..... | 29 |
| 3.9 | Önerilen Derin Öğrenme Modelleri | 29 |
| 3.9.2 | Önerilen CNN modeli | 30 |
| 3.9.3 | Önerilen RNN modeli | 30 |
| 3.9.4 | Önerilen LSTM modeli | 31 |
| 3.9.5 | Önerilen BiLSTM modeli..... | 32 |
| 3.10 | Performans Metrikleri | 32 |
| 4. | BULGULAR..... | 34 |
| 4.1 | 1D-CNN Uygulaması İçin Bulgular..... | 34 |
| 4.2 | RNN Uygulaması İçin Bulgular..... | 37 |
| 4.3 | LSTM Uygulaması İçin Bulgular..... | 39 |
| 4.4 | BiLSTM Uygulaması İçin Bulgular..... | 42 |
| 5. | SONUÇLAR VE ÖNERİLER | 45 |
| | KAYNAKLAR | 47 |
| | ÖZGEÇMİŞ | 51 |

TABLULAR LİSTESİ

| | | |
|-----------|--|----|
| Tablo 1.1 | Enerji tahmini için yapay zeka tabanlı yapılan örnek çalışmalar..... | 6 |
| Tablo 2.1 | Türkiye'nin yıllara göre kurulu gücü (MW)..... | 11 |
| Tablo 3.1 | Çalışmada kullanılan very setinin istatistiksel bilgileri..... | 18 |
| Tablo 3.2 | Tasarlanan 3 farklı RNN model mimarisinin katmanları ve eğitilebilen parametre sayıları..... | 31 |
| Tablo 3.3 | Tasarlanan 3 farklı LSTM model mimarisinin katmanları ve eğitilebilen parametre sayıları..... | 31 |
| Tablo 3.4 | Tasarlanan 3 farklı BiLSTM model mimarisinin katmanları ve eğitilebilen parametre sayıları..... | 32 |
| Tablo 4.1 | Önerilen 1D-CNN modeli için elde edilen en iyi performans..... | 35 |
| Tablo 4.2 | Önerilen RNN modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar..... | 37 |
| Tablo 4.3 | Önerilen LSTM modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar..... | 39 |
| Tablo 4.4 | Önerilen BiLSTM modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar..... | 42 |

GRAFİKLER LİSTESİ

| | | |
|--------------|--|----|
| Grafik 2.1 | 2022 yılı kurulu gücünün birincil enerji kaynağına göre dağılımı (MW)..... | 12 |
| Grafik 2.2 | Türkiye Elektrik Kurulu güç ve üretim miktarları (MW)..... | 13 |
| Grafik 2.3 | Türkiye Elektrik Enerjisi İletim ve Dağıtım Kayıp oranları..... | 14 |
| Grafik 3.1.a | Diyarbakır il merkezinde yer alan bir alışveriş merkezinin 2027 günlük aktif tüketiminin zamanla değişimi..... | 17 |
| Grafik 3.1.b | Veri setini oluşturan örneklerin histogram değişimi..... | 17 |
| Grafik 4.1.a | 1D-CNN modelinin Ölçülen aktif tüketim ve model ile elde edilen tahmini değerleri..... | 35 |
| Grafik 4.1.b | 1D-CNN modelinin test verisinin son 500 örneğine ilişkin ölçülen aktif tüketim değerleri ve elde edilen tahmini değerleri..... | 35 |
| Grafik 4.1.c | 1D-CNN modelinin test veri setinde tahmin ve gerçek değer arasındaki ilişkiyi gösteren serpilme (scatterplot) diyagramı..... | 36 |
| Grafik 4.1.d | 1D-CNN modelinin eğitim sürecinde elde edilen epoch-mse değişimi..... | 36 |
| Grafik 4.2.a | RNN modelinin ünite-düğüm sayısı 50 olan mimarisi için eğitim ve test verileri için tahmini değerleri..... | 37 |
| Grafik 4.2.b | RNN modelinin ünite-düğüm sayısı 50 olan mimarisi test verisinin son 500 örneğinin tahmin grafiği..... | 38 |
| Grafik 4.2.c | RNN modelinin ünite-düğüm sayısı 50 olan mimarisi test tahmin ve gerçek verisinin serpilme (scatter plot) diyagramı..... | 38 |
| Grafik 4.2.d | RNN modelinin ünite-düğüm sayısı 50 olan mimarisi için eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi..... | 39 |

| | | |
|--------------|---|----|
| Grafik 4.3.a | LSTM modelinin ünite-düğüm sayısı 100 olan mimarisi için eğitim ve test verileri için öngörüler..... | 40 |
| Grafik 4.3.b | LSTM modelinin ünite-düğüm sayısı 100 olan mimarisi test verisinin son 500 örneğinin tahmin grafiği..... | 40 |
| Grafik 4.3.c | LSTM modelinin ünite-düğüm sayısı 100 olan mimarisi için test tahmin ve gerçek verisinin serpilme (scatter plot) grafiği..... | 41 |
| Grafik 4.3.d | LSTM modelinin ünite-düğüm sayısı 100 olan mimarisi eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi..... | 41 |
| Grafik 4.4.a | BiLSTM modelinin ünite-düğüm sayısı 100 olan mimarisi için Eğitim ve test verileri için öngörüler..... | 43 |
| Grafik 4.4.b | BiLSTM modelinin ünite-düğüm sayısı 100 olan mimarisi test verisinin son 500 örneğinin tahmin grafiği..... | 43 |
| Grafik 4.4.c | BiLSTM modelinin ünite-düğüm sayısı 100 olan mimarisi test tahmin ve gerçek verisinin serpilme (scatter plot) diyagramı..... | 44 |
| Grafik 4.4.d | BiLSTM modelinin ünite-düğüm sayısı 100 olan mimarisi eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi..... | 44 |

ŞEKİLLER LİSTESİ

| | | |
|------------|---|----|
| Şekil 3.1 | Oluşturulan veri setinin zaman akışı..... | 19 |
| Şekil 3.2 | Yapay Zeka kavramının gelişim süreci..... | 20 |
| Şekil 3.3 | Denetimli Öğrenme Şeması..... | 21 |
| Şekil 3.4 | Denetimsiz Öğrenme Şeması..... | 22 |
| Şekil 3.5 | Pekiştirmeli Öğrenme Şeması..... | 23 |
| Şekil 3.6 | Yapay sinir hücresinin örnek şeması..... | 24 |
| Şekil 3.7 | Örnek bir CNN mimarisinin yapısı..... | 26 |
| Şekil 3.8 | RNN Ünitesi..... | 27 |
| Şekil 3.9 | LSTM Ünitesi..... | 28 |
| Şekil 3.10 | BiLSTM Ünitesi..... | 29 |
| Şekil 3.11 | Tasarlanan 1D-CNN model katmanları..... | 30 |

SİMGELER VE KISALTMALAR LİSTESİ

Simge

w

b

x

h

Σ

θ

\tanh

Açıklama

Ağırlık

Bias

Girdi verileri

Çıktı verileri

Aktivasyon fonksiyonu

Kontak Açısı

Hiperbolik tanjant

Kısaltma

1D-CNN

RNN

LSTM

BiLSTM

FC

NN

MAE

MAPE

RMSE

Açıklama

1D-Convolutional neural network

Recurrent Neural Networks

Long Short-Term Memory

Bidirectional Long Short Term Memory

Fully Connected

Neural Network

Mean Absolute Error

Mean Absolute Percentage Error

Root Mean Square Error

ÖZET

ENERJİ SİSTEMLERİNDE MAKİNE ÖĞRENMESİ İLE GÜÇ TÜKETİM TAHMİNİ

BERUS, Yusuf

Yüksek Lisans, Elektrik Elektronik Mühendisliği Bölümü

Danışman: Dr. Öğr. Üyesi Yurdagül BENTEŞEN YAKUT

Haziran 2024, 66 sayfa

Türkiye’de artış gösteren nüfus ve üretime dayalı ekonomik faaliyetlerin yanında yüksek teknolojik araçların kullanımında gerekli olan enerji talepleri hızla artmaktadır. Bu talepleri karşılamak için, tüm dünyada olduğu gibi Türkiye’de de elektrik enerjisi öne çıkmaktadır. Tüketicilere ulaştırılma kolaylığı, çevreyle ilgili zararlarının daha az olması nedeniyle tercih edilen bu enerji türündeki depolama sorunları nedeniyle arz-talep dengesi dikkate alınarak doğru planlanmış miktarda üretiminin yapılma zarureti bulunmaktadır. Elektrik enerjisi talebinin eş zamanlı ve kesintisiz olarak karşılanma gerekliliğinden dolayı elektrik arzı üzerine yapılan geleneksel tahminleme modellerine alternatif olarak veri madenciliği teknikleri kullanılmaya başlamıştır. Veri madenciliği sayesinde elde edilen verilerden daha anlamlı bilgiye ulaşıldığı birçok çalışmada görülmüştür.

Bu tez çalışmasında farklı 4 makine öğrenmesi yöntemi kullanılarak Diyarbakır il merkezinde yer alan alışveriş merkezinin elektrik enerjisi tüketim tahmini amaçlanmıştır. Çalışmamıza konu olan 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 $2027 \times 24 = 48648$ 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 [92,17%, 93,63%] bant aralığında olduğu ve önerilen modeller ile belirli düzeyde başarımların 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 başarımlarının artırılacağı düşünülmektedir.

Anahtar Kelimeler: Makine Öğrenmesi, Enerji tüketimi tahmini, CNN, RNN, LSTM, BiLSTM

ABSTRACT

POWER CONSUMPTION PREDICTION WITH MACHINE LEARNING IN ENERGY SYSTEMS

BERUS, Yusuf

Master of Science in Department of Electrical Electronic Engineering

Supervisor: Assist.Prof.Dr. Yurdagül BENTEŞEN YAKUT

June 2024, 66 pages

In addition to the increasing population and production-based economic systems in Turkey, the energy demands required for the use of high-tech tools are increasing rapidly. To meet this outage, electrical energy comes to the fore in Turkey, as in the rest of the world. Due to storage problems in this type of energy, which is preferred due to its ease of delivery to the consumer and less environmental damage, there is a necessity to not record the supply-demand distribution and not to produce correctly planned amounts. Due to the need to constantly and continuously meet the demand for electrical energy, data mining techniques have begun to be applied as an alternative to traditional forecasting models on electricity supply. Thanks to data mining, many signs of more meaningful impacts were seen from the data available.

In this thesis study, it is aimed to estimate the electrical energy consumption of a shopping center located in Diyarbakır city center using 4 different machine learning methods. It was aimed to estimate the change in energy consumption with machine learning methods, using a total of 2027 days (5 years, 6 months, 19 days) of active consumption data of the shopping center that is the subject of our study. The active consumption amount used in the study was measured hourly and $2027 \times 24 = 48648$ data set was obtained and the necessary approvals were obtained from Dicle Electricity Distribution Inc. Four different deep network models have been developed for the prediction of energy active consumption: 1D-CNN, RNN, LSTM and BiLSTM. The performance values of the developed models in question, especially those with a recurrent neural network structure, were trained with the same criteria and their performance values were compared. All applications were repeated 10 times and the highest performance values were recorded. The performance of the proposed models was evaluated according to RMSE, MAE and R^2 criteria. In the study where different architectures were proposed, it was observed that the performance performance range of recurrent neural networks was in the band range of [92,17%, 93,63%] and was within a certain range, considering the coefficient of determination according to the test data set. The performance level has been reached with the proposed models. It has been observed that the performances in recurrent neural networks are close to each other and the best performance among them is obtained in the 100-unit node architecture in the BiLSTM model. According to the proposed architectures, it has been observed that 1D-CNN has lower performance than recurrent neural networks. It is thought that performance can be increased by improving the 1D-CNN architecture.

Keywords: Machine Learning, Energy consumption prediction, CNN, RNN, LSTM, BiLSTM

1. GİRİŞ

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 sağlıklı kullanılabilmesi için gerekli miktarda üretilmesi ve dağıtılması gerekmektedir. Dolayısıyla enerji sektöründe planlama çok önemlidir ve yük talebi tahmini bunun temelini oluşturur. Ülke ekonomisi, hatalı enerji talebi tahminlerinden ve bunun sonucunda ortaya çıkan arz ve talep arasındaki farklılıklardan olumsuz etkilenebilir [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. Ülkemizde mevcut durumda tahmini ilk okuma tarihi ile en son okuma yapılan tarihin fark alınarak EPDK tahminleme yapmaktadır. Güç değeri değişim katsayısının endeks ilerleme trendi ve mevsimsellik katsayısı ile çarpılmasıyla ilgili aya ait tahmini tüketim değeri hesaplanır [5]. Zaman zaman kullanılan tahminleme yöntemi de her zaman doğru sonuçlar ortaya çıkarmayabilmektedir. 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 zekânın 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 Öğrenmenin otonom sürüşten tıbbi cihazlara kadar pek çok sektörde uygulandığı görülmektedir [4].

1.1 Literatür Taraması

Dünya genelinde enerji ihtiyacının her yıl artış göstermesinden ötürü [1] talep tahminlerinin doğruluğu yatırım planlaması için önem arz etmektedir. Enerji talep tahmini için 1990'lardan bu yana birçok benzetim yöntemi geliştirilmiştir [2] ve literatürde birçok farklı tahmin yönteminin ve değişkenin kullanıldığı görülmektedir [3]. Yapılan çalışmalarda ortaya çıkan sonuçlar bazı belirsizliklerden ötürü yanlış tahminlere yol açıyor ki bu da yüksek doğrulukta sağlam bir enerji tahmin modelinin kurulması gerekliliğini ortaya çıkarmıştır [4]. Genetik algoritmalar, nöral ağlar, Otoregresif (AR), Otoregresif Hareketli Ortalamalar (ARMA), Otoregresif Hareketlilik Ortalamaları (ARIMA), Çoklu En Az Kare Metodu (EKM), iteratif teknikler ve nöral ağların talep tahmin yaklaşımı da dahil olmak üzere birçok yöntem tahminlemede kullanılmaktadır [5]. Bu tahminlemeler mühendislik, yapay zeka (Artificial Intelligence, AI) tabanlı ve hibrit yöntemler olarak üçe ayrılabilir. [2]

Yapay Sinir Ağları (YSA) olarak bilinen bilgisayar sistemlerinde; insan beyninin ağ mimarisi, hafıza ve öğrenme özellikleri örnek alınarak geliştirilen matematiksel modellerden yararlanılmaktadır [6]. Yapay zeka (AI) yöntemleri olarak da bilinen veri

yöntemi, önceki enerji tüketim dönemlerinde toplanan tarihi verilere dayanır [7]. Yapay Sinir Ağları Makine Öğrenmesi ile enerji tahmini yaptığımız çalışmamız için bu konuda yaptığımız araştırmada, K.Ç.Gezmez (2022) bir ilin enerji talep tahminini yaparken çalışmasında LSTM modelini öne çıkarmış ve başarı kriteri olarak RMSE (Root Mean Square Error) kullanmayı tercih etmiştir. Kullanılan yöntemlerden en başarılı sonucun doğrusal regresyon analizinde sağlandığını söylemiştir [8]. H.Yurdođlu (2023), bir tekstil fabrikasına ait geçmiş elektrik enerjisi tüketim verilerini kullanarak gelecek elektrik enerjisi talep tahminini yaptığı çalışmada YSA LSTM modelini tercih etmiştir [9]. R.F.Berriel (2017) Brezilya San Antonia'daki dört konuttan topladığı elektrik enerjisi tüketim verilerini Derin Öğrenme tekniklerini kullanarak gelecek aylık enerji tüketimini tahmin etmiştir. Bu çalışmada YSA Derin Öğrenme Modellerinden FC, NN ve LSTM kullanmış ve çıkan sonuçların mevcut şirket tahmininden daha iyi olduğuna vurgu yapmıştır [1]. Elektrik talebi tahminine dayalı derin öğrenme çalışmasında J. Bedi ve D. Toshniwal (2018) Chandigarh şehrinin elektrik tüketim verilerini RNN, LSTM ve EMD tabanlı RNN (EMD+RNN) modelleriyle karşılaştırarak değerlendiriliyor [10]. Q.Wang ve arkadaşları (2021) hazırladıkları makalede, CNN ve LSTM derin öğrenme yapılarının birleştirilmesi üzerine yeni bir sinir ağı modeli öneriyor [11]. B. İbrahim (2022) ve arkadaşları, Panama'da kısa vadede elektrik tahmini için önceki haftanın yükü, önceki günün yükü ve sıcaklığı verilerini kullanarak derin öğrenme regresyon modelinin performansını değerlendiriyorlar. Bu modelde 0,93'lik R^2 ve 2,9% ortalama mutlak yüzde hata (MAPE) veriyorken, AdaBoost modeli 0,75'lik R^2 ve 5,70% MAPE ile performansını elde ediyorlar [12]. P.L.Seabe ve arkadaşları (2023) kripto para birimi fiyat tahminleri için Uzun Kısa Zamanlı Hafıza (LSTM), Gated Tekrarlı Birim (GRU) ve İki Yönlü LSTM (Bi-LSTM) metodu öneriyor. Root Mean Square Error (RMSE) ve Mean Absolute Percentage Error'ı (MAPE) kullanarak elde ettiği deneysel sonuçlar, Bi-LSTM'nin LSTM ve GRU'dan daha iyi çıkan sonuçları paylaşıyorlar [13]. İ.Kiprijanovska ve arkadaşları Pecan Caddesi'ndeki evlerin yaklaşık dört yıllık elektrik enerjisi tüketimi verilerini Short-term Load Forecasting (STLF) yöntemiyle analiz ederek yük tahmininden bulunmuşlardır [14]. K.Baysal ve arkadaşları Türkiye'nin kısa vadeli elektrik yükü talebini tahmin etmek amacıyla, saatlik frekansta elde edilen bir yıllık veri seti ile bir saatlik ileri tahminler oluşturmak için Yapay Sinir Ağları (YSA) ile Ridge, Lasso ve Support Vector Regression kullanmışlar [15].

D.Solyalı (2020), 2016 ve 2017 yıllarına ait Kıbrıs elektrik arzı verilerinin uzun ve kısa vadeli analizlerle uyumlu hale getirilerek makine öğrenmesi ile elektrik talep tahminini gerçekleştirmiştir [16]. S.Belagoune ve arkadaşları (2021), güç sistemlerindeki iletim hatlarında oluşan kesinti bölgesi tanımı, arıza türü belirleme ve konum tahminlemesi için derin öğrenme RNN (Tekrarlayan Sinir Ağları) yöntemiyle çalışmışlardır [17]. S.Wen ve arkadaşları (2019) Long Short-Term Memory (LSTM) sinir ağına dayalı olarak Singapur güç sistemindeki aktif güç dalgalanmalarını gerçek zamanlı olarak dağılım için derin öğrenme yöntemini araştırıyor [18]. M.Alazab ve arkadaşları (2020) akıllı şebekelerde istikrar tahmini için yeni bir Çok Yönlü Uzun Kısa Süreli Bellek (MLSTM) tekniği öneriyor [19]. J.Tulensalo ve arkadaşları (2020), Finlandiya’ da yaptıkları çalışmada güç kaybı tahminleri için Uzun Kısa Süreli Bellek (LSTM) tekrarlayan sinir ağ modelini öneriyorlar [20]. T.M. Al-Jaafreh ve arkadaşları (2022), LSTM Derin öğrenme tekniğini güneş fotovoltaik (PV) enerji santrallerinin ürettikleri gücü tahmin için kullanıyorlar [21]. J.F.Torres ve arkadaşları (2022), İspanya’nın elektrik tüketimini tahmin etmek için kullandıkları Derin Öğrenme LSTM sinir ağı tekniğini geleneksel Makine Öğrenme teknikleri ile karşılaştırıyor ve en küçük tahmin hatasını 1,5% altında ölçümlüyorlar [22]. E.Mocanu ve arkadaşları (2016), Derin Öğrenme teknikleri ile bina enerji tüketim tahmin çalışması yapmışlardır [23]. J.Bedi ve arkadaşı (2019), Hindistan’ın Chandigarh Birliği bölgesi elektrik enerjisi tüketimine ilişkin olarak yapılan tahmin performansını YSA, RNN ve Destek Vektörü Regresyonu (Support Vector Regression) modelleri ile karşılaştırmışlardır [24]. A.Agga ve arkadaşları (2022), fotovoltaik enerji tahminleri için Fas’ın başkenti Rabat veri tabanından yararlanarak Derin Öğrenme mimarilerinden CNN ve LSTM kullanmış hata geliştirmeleri için MAE, MAPE ve RMSE’den yararlanmışlardır [25]. K.Padma ve arkadaşları (2022), Makine Öğrenme yöntemlerini kullanarak kısa süreli yük talep tahmininde bulunmuşlardır [26]. T.Vantuch ve arkadaşları (2016), uzun ve kısa vadeli Makine Öğrenme tabanlı tahminlerini 3 farklı regresyon temelli kriterle karşılaştırarak sonuçları paylaşmışlardır [27]. T.M. Ghazal ve arkadaşları (2022), IoT tabanlı akıllı ölçümlü enerji yönetiminde destek vektör makinesi ve derin makine öğrenme teknikleri ile metrekare başına güç tüketimini tahmin etmek üzere model oluşturmuşlardır [28]. R.Olu-Ajayi ve arkadaşları (2022), bir bina tasarımının anahtar özelliklerine ve geliştirmenin ilk aşamasında yıllık ortalama enerji tüketim tahmini için Makine Öğrenme tekniklerini kullanmışlardır [29]. C.Chen ve arkadaşları (2018),

Elektrik Ark Fırını Çelik santralının elektrik enerjisi tüketim verilerinin Derin Öğrenme modelleri ile yük tahmin modeli oluşturmuşlardır [30]. A.J.M.Kell ve arkadaşları (2021), Makine Öğrenme metotları ile enerji talep tahminlemesi üzerinden uzun vadeli yatırım kararları konusunda çalışma yapmışlardır [31].

Makine öğrenme modellerinin, geleneksel zaman serisi analizi ve regresyon yaklaşımlarından daha iyi performans gösteriyor olmasına rağmen, lineer olmayan enerji tüketim şekillerinin yüksek doğruluk gösteren tahmin istikrarı için hâlâ önemli bir iyileştirilme ihtiyacı var [7]. Günümüzde her türlü verinin dijital ortamda kayıt altında tutuluyor olması derin öğrenme modelleri için kaynak oluşturuyor. Elektrik tüketiminin tahmini için kısa, orta ve uzun vadeli olarak yapıldığı görülmekte olup yapı olarak benzer yöntemlerin izlendiği görülmektedir. Bu tür çalışmaların çoğalması sonucu daha doğru sonuçlar üreten modellerin ortaya çıkacağı kanaatimizi paylaşıyoruz. Bu amaçla yaptığımız çalışmada enerji aktif tüketiminin tahmini için 1D-CNN, RNN, LSTM ve BiLSTM olmak üzere dört farklı derin ağ modeli geliştirilmiştir. Önerdiğimiz modellerin geliştirilerek farklı sektör tüketim verilerine uygulanması gelecek çalışmalar kapsamında değerlendirilmektedir.

Güç sistemlerinde enerji tahmini için makine öğrenmesi yöntemlerinin kullanıldığı birçok bilimsel çalışmada görülmektedir. Tablo 1.1’de enerji tahminleme ile ilgili çeşitli çalışmaların içeriği ve kullanılan yöntemler verilmiştir.

Tablo 1.1 incelendiğinde geniş bir vizyonda çalışmaların yapıldığı görülmektedir. 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.

Tablo 1.1 Enerji tahmini için yapay zeka tabanlı yapılan örnek çalışmalar

| Kaynakça | Yöntem | Performans ölçütü / Başarımı | Çalışmanın içeriği |
|----------|---|--|--|
| [7] | LSTM, GRU, RNN, Otopregresif 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. | Çok fazla elektrik enerjisi kullanılmasını engellemek için tekstil endüstrisi makinelerinin bekleme durumunda derin öğrenme destekli bir elektrik tahmin modeli ile geliştirildi. |
| [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 tahminini yapmıştır. |
| [15] | Yapay sinir ağları (ANN) | Korelasyon katsayısı, R^2 / Farklı ANN mimarisinde geliştirilen modeller karşılaştırılmıştır. | Hattın uzunluğu, yolcu sayısı ve son 43 yıla ait yük miktarı değerleri esas alınarak Türk demiryolu araçlarının toplam enerji tüketim miktarları araştırıldı. |
| [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. |

1.2 Problemin Tanımı Ve Tezin Amacı

Enerji sistemlerinin verimli ve güvenilir bir şekilde çalışmasını sağlaması için enerji tahmini oldukça önemli bir rol oynar. Enerji tahmini için makine öğrenmesi yöntemlerinin kullanıldığı birçok bilimsel çalışmanın destekleyici akademik çalışmalar olduğu açıktır. 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 tez 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. 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.

1.3 Tezin Yapısı

Tez çalışması 5 bölümden oluşmaktadır;

- Birinci bölümde neden bu tez çalışmasının yapıldığı literatür çalışması ile anlatılmaktadır.
- İkinci bölümde Türkiye'deki enterkonnekte elektrik sistemi ve enerji piyasası hakkında bilgi verilmiştir.
- Üçüncü bölüm metaryal metod bölümünden oluşmaktadır. Tezde Diyarbakır ilinde bir AVM elektrik tüketim verileri kullanılmıştır. Öncelikle veri seti hakkında bilgi verilmiştir. Devamında ise yapay zeka, derin öğrenme, makine

öğrenmesi konuları anlatılarak. Tezde kullanılan makine öğrenmesi yöntemleri hakkında bilgiler verilmiştir.

- Dördüncü bölümde; tez çalışmasında çeşitli makine öğrenmesi yöntemleri kullanılarak elde edilen bulgular hakkında bilgiler verilmiştir.
- Beşinci bölüm olan son bölümde ise tez çalışmasında elde edilen sonuçlar paylaşılmıştır.



2. TÜRKİYE'DE GÜÇ SİSTEMLERİ VE ENERJİ PİYASASI İLE İLGİLİ GENEL BİLGİLER

Tezin bu bölümünde; Türkiye'deki elektrik üretimi, elektrik iletim hatları, enterkonnekte elektrik sistemleri, Türkiye'de elektrik enerjisi talebi, elektrik piyasası kanunu, Enerji piyasaları işletme anonim şirketi (EPIAŞ) ve elektrik piyasası hakkında genel bilgiler ışığında enerji tahminin önemine yer verilmiştir.

2.1 Türkiye'de Elektrik Enerji Üretimi

Türkiye'de elektrik üretimi büyük ölçüde Elektrik Üretim Anonim Şirketi (EÜAŞ) tarafından yürütülmektedir. EÜAŞ verilerine göre ülkemizde 2023 yılında elektrik üretimimizin, %36,3'ü kömürden, %21,4'ü doğal gazdan, %19,6'sı hidrolik enerjiden, %10,4'ü rüzgardan, %5,7'si güneşten, %3,4'ü jeotermal enerjiden ve %3,2'si diğer kaynaklardan elektrik üretmektedir [32].

2.2 Elektrik İletim Hatları

Elektrik iletim hatları, elektrik üretim tesislerinde üretilen elektrik enerjisinin bu tesislerden dağıtım hatlarına aktarılmasını sağlar. Diğer bir deyişle, elektrik iletim hatları, elektriğin enerji üretim tesislerinden yerleşim yerlerinin yakınındaki trafo merkezlerine taşınmasından ve daha sonra tüketicilere dağıtılmasından sorumlu olan elektrik enerjisi dağıtım sisteminin omurgasıdır. Bu hatlar, santrallerde üretilen elektrik enerjisinin son kullanıcıya verimli ve güvenilir bir şekilde ulaşması açısından büyük önem taşır. İletken hat kayıplarının minimum seviyede olmasını sağlarken, enerjinin uzun hatlar boyunca taşınması için bilinen en önemli prensip; yüksek gerilim ve düşük akım değerleri ile çalışılmasıdır. Dolayısıyla, elektrik enerjisi üretim tesislerinden şebekeye yüksek gerilimli olarak iletilir. Gerilim düşürücü trafo merkezlerinde sanayi tesislerinden çıkan yüksek gerilim enerjisi orta gerilime düşürülür. Orta gerilim değerleri daha sonra iletiildiği daha düşük güç kapasiteli trafo merkezleri tarafından alçak gerilim değerlerine dönüştürülür. Böylelikle üretilen enerji son kullanıcılara alçak gerilim seviyesinde iletilmiş olur. Elektrik iletim hatları taşıdıkları gerilim seviyesine göre dört grupta değerlendirilebilir.

- a) Alçak gerilim iletim hatları (AG , gerilim seviyeleri ≤ 1 kV)
- b) Orta gerilim iletim hatları (OG , $1\text{kV} < \text{gerilim seviyeleri} < 35$ kV)
- c) Yüksek gerilim iletim hatları (YG , $35\text{kV} < \text{gerilim seviyeleri} < 154$ kV)
- d) Çok yüksek gerilim iletim hatları (ÇYG, Gerilim seviyeleri ≥ 154 kV)

Havai iletim hatları ile kablolar yüksek gerilim enerjisini uzak mesafelere taşımak için kullanılır. Yüksek gerilimlerinden dolayı Enerji Nakil Hatları (ENH) olarak bilinirler. Alçak gerilim iletim hatları, özellikle son tüketicilere yakın olanlar, enerji iletim hatlarının yer altı formlarıdır. Türkiye Elektrik İletim A.Ş. (TEİAŞ), çok yüksek gerilim (YG) ve alçak gerilim (AG) iletim hatlarının kurulum, bakım ve diğer görevlerinden sorumludur. Buna karşılık, orta gerilim (OG) ve alçak gerilim (AG) iletim hatları diğer kuruluşların kontrolü altındadır. Her ne kadar TEDAŞ'ın (Türkiye Elektrik Dağıtım A.Ş.) sahibi olsa da, Bölge Müdürlükleri yakın zamanda özelleştirildi ve halen farklı kimlikler altında faaliyet göstermektedir [33].

2.3 Enterkonnekte Elektrik Sistemi

Enterkonnekte sistem, iki ve daha fazla sistem ya da şebeke arasında bölgeler arası ya da uluslararası bağlantı olanağını sağlayan sisteme enterkonnekte şebeke olarak tanımlanabilir. Başka bir ifade ile kesintisiz bir enerji ile mevcut enerji ihtiyacını karşılamak için, elektrik santrallerini ve bütün şebekeleri birbirine bağlayan sistem bütünüdür.

2.4 Türkiye’de Elektrik Enerjisi Dağıtımı

Ülkemizde elektrik dağıtımı çeşitli özel ve kamu şirketleri tarafından gerçekleştirilmektedir. Bu şirketler, elektrik dağıtım merkezlerinden son kullanıcılara kadar elektrik enerjisinin güvenli ve verimli bir şekilde ulaşmasını sağlamakla yükümlüdürler. Türkiye’de 21 elektrik dağıtım şirketi bulunmaktadır. Bu şirketler, ülkenin farklı bölgelerinde elektrik dağıtım hizmetleri sunmaktadır. Bu tez çalışmasında kullanılan veriler Dicle Elektrik Dağıtım Şirketi (DEDAŞ) ile Diyarbakır iline ait trafo bilgileri alınarak elde edilmiştir [33].


2.5 Türkiye’de Elektrik Enerjisi Talebi

Ülkemizde taleplere karşın kaliteli enerji arzı ekonomik büyümede büyük öneme sahiptir. Elektrik Enerjisine ihtiyacının sürekli artması sonucu bu alana yapılan yatırımların, planlama faaliyetlerinin ve ticaretin de artırmasına neden olmaktadır. Bu gelişmeler sektörü daha da önemli hale getirmiş ve üzerinde yapılan çalışmaların artmasına sebep olmuştur. Türkiye’nin yıllara göre kurulu güç miktarları Tablo 2.1’de verilmiştir. Nüfus artışı ve buna paralel olarak artan ekonomik aktivite nedeniyle elektrik enerjisine olan ihtiyaç artmış, bu da sanayi yatırımlarını artırmıştır. 1923 yılında 32,80 MW olan kurulu güç 2022 yılında 103.809,23 MW’a yükselmiştir [34].

Tablo 2.1 Türkiye’nin yıllara göre kurulu gücü (MW) [34]

| TÜRKİYE KURULU GÜCÜNÜN YILLAR İTİBARIYLA GELİŞİMİ | | | | | | | | | | | |
|---|--------|----------|------|----------|----------|------|-----------|----------|------|------------|------|
| ANNUAL DEVELOPMENT OF TURKEY'S INSTALLED CAPACITY | | | | | | | | | | | |
| (1923 – 2022) | | | | | | | | | | | |
| Birim(Unit) : MW | | | | | | | | | | | |
| YIL | TOPLAM | ARTIŞ | YIL | TOPLAM | ARTIŞ | YIL | TOPLAM | ARTIŞ | | | |
| YEAR | TOTAL | INCREASE | YEAR | TOTAL | INCREASE | YEAR | TOTAL | INCREASE | | | |
| | | % | | | % | | | % | | | |
| 1923 | 32,80 | 89,6 | 1948 | 305,50 | 21,5 | 1973 | 3.192,50 | 17,7 | 1998 | 23.354,00 | 6,7 |
| 1924 | 32,90 | 0,3 | 1949 | 381,80 | 25,0 | 1974 | 3.732,10 | 16,9 | 1999 | 26.119,30 | 11,8 |
| 1925 | 33,40 | 1,5 | 1950 | 407,80 | 6,8 | 1975 | 4.186,60 | 12,2 | 2000 | 27.264,10 | 4,4 |
| 1926 | 48,60 | 45,5 | 1951 | 423,20 | 3,8 | 1976 | 4.364,20 | 4,2 | 2001 | 28.332,40 | 3,9 |
| 1927 | 51,90 | 6,8 | 1952 | 437,80 | 3,4 | 1977 | 4.727,20 | 8,3 | 2002 | 31.845,80 | 12,4 |
| 1928 | 65,90 | 27,0 | 1953 | 499,50 | 14,1 | 1978 | 4.868,70 | 3,0 | 2003 | 35.587,00 | 11,7 |
| 1929 | 72,10 | 9,4 | 1954 | 516,90 | 3,5 | 1979 | 5.118,70 | 5,1 | 2004 | 36.824,00 | 3,5 |
| 1930 | 78,00 | 8,2 | 1955 | 611,60 | 18,3 | 1980 | 5.118,70 | 0,0 | 2005 | 38.843,50 | 5,5 |
| 1931 | 101,90 | 30,6 | 1956 | 886,10 | 44,9 | 1981 | 5.537,60 | 8,2 | 2006 | 40.564,80 | 4,4 |
| 1932 | 103,30 | 1,4 | 1957 | 939,40 | 6,0 | 1982 | 6.638,60 | 19,9 | 2007 | 40.835,70 | 0,7 |
| 1933 | 107,80 | 4,4 | 1958 | 1.030,00 | 9,6 | 1983 | 6.935,10 | 4,5 | 2008 | 41.817,20 | 2,4 |
| 1934 | 117,40 | 8,9 | 1959 | 1.161,00 | 12,7 | 1984 | 8.461,60 | 22,0 | 2009 | 44.761,20 | 7,0 |
| 1935 | 126,20 | 7,5 | 1960 | 1.272,40 | 9,6 | 1985 | 9.121,60 | 7,8 | 2010 | 49.524,10 | 10,6 |
| 1936 | 138,50 | 9,7 | 1961 | 1.323,90 | 4,0 | 1986 | 10.115,20 | 10,9 | 2011 | 52.911,10 | 6,8 |
| 1937 | 167,10 | 20,6 | 1962 | 1.370,80 | 3,5 | 1987 | 12.495,10 | 23,5 | 2012 | 57.059,40 | 7,8 |
| 1938 | 178,50 | 6,8 | 1963 | 1.381,10 | 0,8 | 1988 | 14.520,60 | 16,2 | 2013 | 64.007,50 | 12,2 |
| 1939 | 215,60 | 20,8 | 1964 | 1.418,30 | 2,7 | 1989 | 15.808,20 | 8,9 | 2014 | 69.519,80 | 8,6 |
| 1940 | 217,00 | 0,6 | 1965 | 1.490,50 | 5,1 | 1990 | 16.317,60 | 3,2 | 2015 | 73.146,74 | 5,2 |
| 1941 | 222,00 | 2,3 | 1966 | 1.644,30 | 10,3 | 1991 | 17.209,10 | 5,5 | 2016 | 78.497,38 | 7,3 |
| 1942 | 226,70 | 2,1 | 1967 | 1.959,10 | 19,1 | 1992 | 18.716,10 | 8,8 | 2017 | 85.200,00 | 8,5 |
| 1943 | 236,40 | 4,3 | 1968 | 1.966,60 | 0,4 | 1993 | 20.337,60 | 8,7 | 2018 | 88.550,76 | 3,9 |
| 1944 | 241,90 | 2,3 | 1969 | 1.967,20 | 0,0 | 1994 | 20.859,80 | 2,6 | 2019 | 91.266,99 | 3,1 |
| 1945 | 245,90 | 1,7 | 1970 | 2.234,90 | 13,6 | 1995 | 20.954,30 | 0,5 | 2020 | 95.890,61 | 5,1 |
| 1946 | 247,50 | 0,7 | 1971 | 2.577,90 | 15,3 | 1996 | 21.249,40 | 1,4 | 2021 | 99.819,61 | 4,1 |
| 1947 | 251,40 | 1,6 | 1972 | 2.711,30 | 5,2 | 1997 | 21.891,90 | 3,0 | 2022 | 103.809,26 | 4,0 |

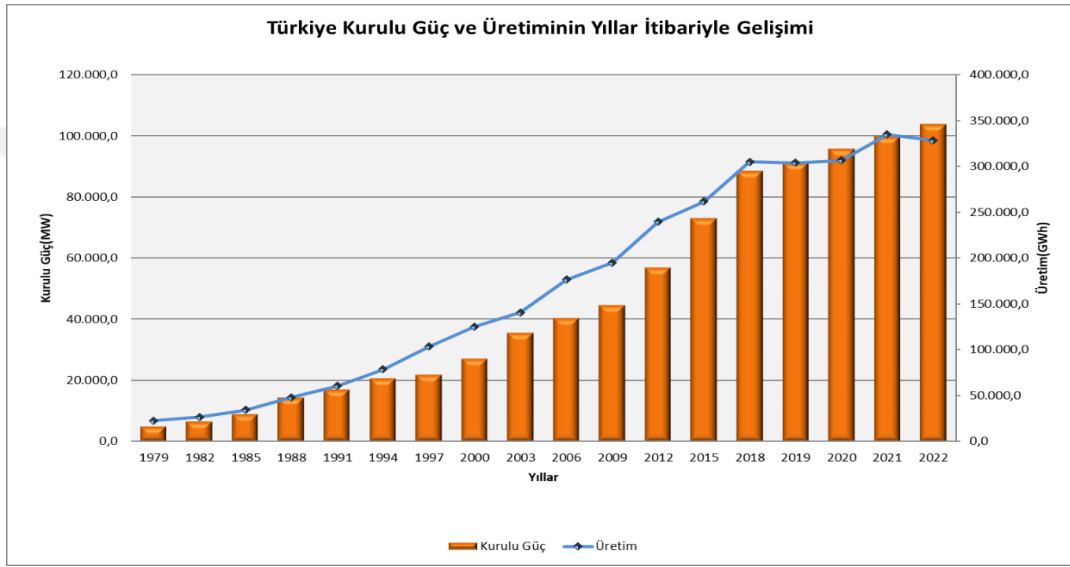
Elektrik Enerjisi üretiminde kullanılan birincil kaynakların çeşitliliği, enerji olarak dışa bağımlı olan ülkemizin [35] stratejik ve ekonomik değişimler karşısındaki hareket alanını genişletir. Grafik 1’de [34] 2022 yılına ait kurulu güçlerin birincil enerji kaynağına göre dağılımını verilmiştir. 2022 yılı içindeki kurulu gücün içindeki ithal kaynaklı kurulu gücün payı %35,6’dır. Bu orana çok yakıtlı santrallerin kurulu gücü dâhil değildir.



Grafik 2.1 2022 yılı kurulu gücünün birincil enerji kaynağına göre dağılımı (MW)


Grafik 2.2’ye bakıldığında 1979-2022 yılların arasındaki Türkiye elektrik kurulu güç ve üretim miktarları görülmektedir. 1979 yılında 22.521,9 MW olan elektrik üretimi

2022 yılında ise 328.379,3 MW olarak kayıtlara geçmiştir [34]. Elektrik tüketimi 2001 ve 2009 yılları dışında artış trendindedir. Ülkemizde meydana gelen 2001 ve 2009 yılları arasındaki ekonomik kriz ile elektrik tüketimi önemli ölçüde düşmüştür. 2018 yılı Mayıs ayı sonu ile elektrik enerjisi üretimimiz 118 bin GWh, tüketimimiz 120 bin GWh'dir (EPİAŞ, 2018) [34].



Grafik 2.2 Türkiye Elektrik Kurulu güç ve üretim miktarları (MW) [34]

Elektrik enerjisi güç sistemlerinde, iletim ve dağıtım sürecinde şebekede elektrik enerjisi kayıpları oluşur. İletim sürecinde oluşan kayıpların tamamına yakını teknik kayıplar olarak görülebilir. Ancak dağıtım sürecindeki kayıplar teknik kayıpların yanında çeşitli nedenlerle tahakkuka bağlanamayan abone tüketimleri de kapsamaktadır. Grafik 2.3'de 2012-2022 yılları arasındaki Türkiye Elektrik Enerjisi İletim ve Dağıtım Kayıp oranları verilmiştir [34].



* Kaynak: Türkiye Elektrik Dağıtım ve Tüketim İstatistikleri, 1995-2021 EPIAŞ (Elektrik Piyasaları İşletme A.Ş.) ** Dağıtım Kaybı Değeri Geçicidir.

Grafik 2.3 Türkiye Elektrik Enerjisi İletim ve Dağıtım Kayıp oranları [34]

2.6 Elektrik Piyasası Kanunu

6446 numaralı Elektrik Piyasası Kanunu, 14.03.2013 tarihinde kabul edilerek 30.03.2013 tarihli Türkiye Cumhuriyeti Resmi Gazete yayımlanmıştır. Bu kanunla, tüketicilerin elektrik enerjisinin; yeterli, yüksek kalitede alabilmelerini sağlamak amacıyla, bağımsız düzenlemelerle birlikte, rekabet ortamında, özel hukuk hükümlerine uygun olarak faaliyet gösteren, mali açıdan güçlü, istikrarlı, şeffaf bir elektrik enerjisi piyasası oluşturmak ve kaliteli, sürekli, uygun fiyatlı, çevreye duyarlı bir şekilde kanun ile kontrolün uygulandığını garanti etmeyi amaçlanmaktadır.

2.7 Enerji Tahmini

İnsan oğlunun değişen yaşam döngüsünde enerjiye olan talebinin değişiminin hızla arttığını Türkiye'deki üretim, iletim ve dağıtımını içeren enerji güç sistemi incelendiğinde görmekteyiz. Bu sebeple enerji ihtiyacına olan talebin tahmininin oldukça önemli olduğu görülmektedir. Enerji planlaması ve yönetiminde; Yenilenebilir Enerji Entegrasyonu, Akıllı Enerji Sistemleri, İklim Değişikliği ve Sürdürülebilirlik gibi parametrelerin dikkate alınması gerekmektedir [36]. Akıllı enerji sistemleri kullanılarak; enerji tüketimi optimize etmek ve enerji israfını azaltmak için

gelişmiş tahmin tekniklerini kullanılmaktadır. Bu sistemler, geçmiş enerji tüketim verilerini ve çevresel faktörleri analiz ederek gelecekteki enerji ihtiyacını tahmin eder ve enerji dağıtımını buna göre düzenler. Elektrik güç sisteminin işletimi, güvenli bir aralıkta çalışması ve elektrik hizmetinin kaliteli ve kesintisiz olarak sunulması için enerji santrallerinden dağıtım merkezlerine kadar gerçek zamanlı koordinasyon gerektiren sürekli bir çalışmadır. Tahminleme yapılırken gerçek zamanlı verilere ihtiyaç duyulmaktadır. Gerçek zamanlı veriler ile enterkonnekte şebekenin zarar görmesini önlemek için enerji üretimi ile yük arasındaki gerçek zamanlı denge sürdürülmelidir [37].

Tez çalışmasında Dicle EDAŞ'tan Diyarbakır ilinde bulunan aktif bir Alışveriş Merkezine ait gerçek zamanlı güç tüketim verileri alınmıştır. Alınan veriler kullanılarak Diyarbakır ilinde bulunan 21TR-00380 numaralı Trafo'ya ait enerji tahmini çeşitli makine öğrenmesi yöntemleri ile yapılmıştır.


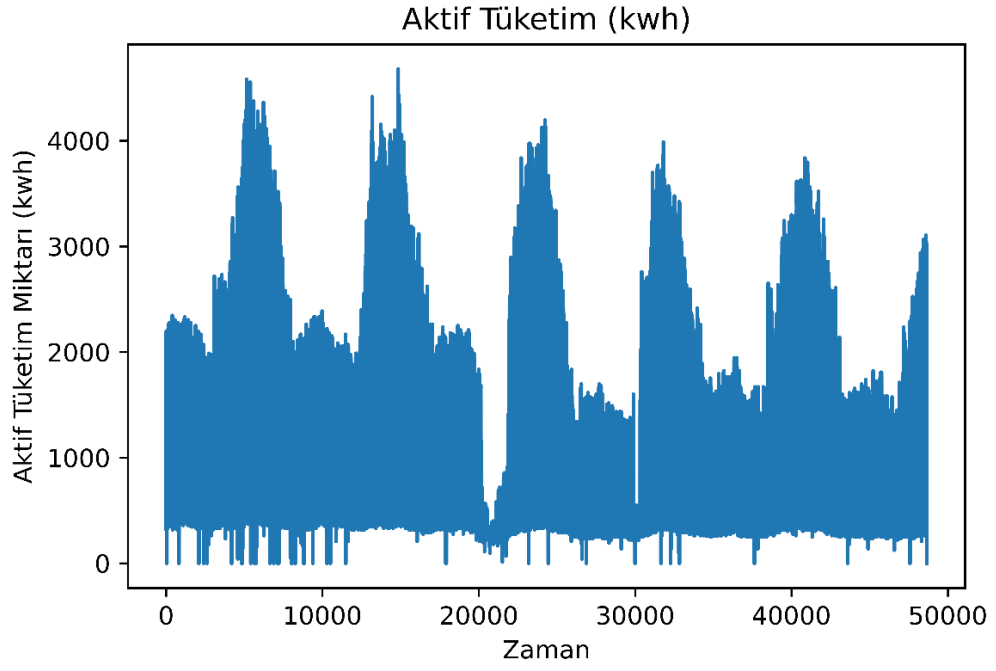
3. MATERYAL VE YÖNTEM

Bu tez 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. Belirtilen amaç doğrultusunda, çalışmada kullanılan veri seti ve tahmin için önerilen yöntemlerin detayları bu bölümde açıklanmıştır.

3.1 Veri Seti Ve Uygulanan Ön İşlemler

Tez kapsamında kullanılan veri seti, 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, bu tez kapsamında kullanılmıştır. Her saat başı tüketim miktarı ölçüldüğünden, veri seti boyutunun $2027 \times 24 = 48648$ olduğu görülmüştür. Enerji aktif tüketiminin saat çözünürlüğünde değişimi Grafik 3.1(a)'da ve veri setinde yer alan örneklerin hangi ölçüde tekrar ediyor olduğunu gösteren histogram değişimi Grafik 3.1(b)'de gösterilmiştir.



Grafik 3.1 (a) Diyarbakır il merkezinde yer alan bir alışveriş merkezinin 2027 günlük aktif tüketiminin zamanla değişimi (b) Veri setini oluşturan örneklerin histogram değişimi

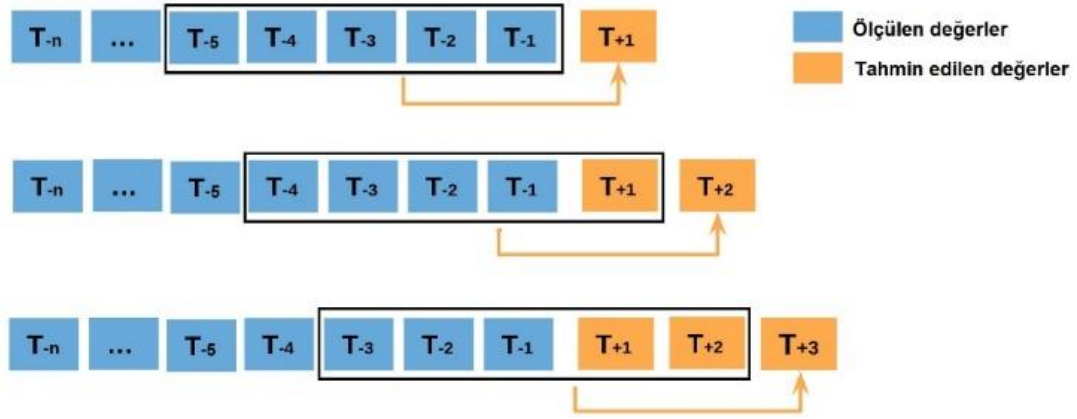
Veri setinin bulunduğu uzaydaki dağılımının tespiti için istatistiksel değerler hesaplanmış ve elde edilen bilgiler Tablo 3.1’de verilmiştir.

Tablo 3.1 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 |

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 3.1’de gösterilmiştir.




Şekil 3.1 Oluşturulan veri setinin zaman akışı

3.2 Yapay Zeka

İnsanoğlu, hayatta kalabilme dürtüsüyle çevresinden elde ettiği tecrübeler ışığında tarih boyunca yaşayışını kolaylaştırıcı yenilikçi çözüm yolları üretmiştir. İcat edilen toprak kaplar, taş silahlar, tekerlerler, yazını icadı, gemiler v.s. insan iradesi ile kullanılan hayatı kolaylaştırıcı araçlar olmuşlardır. İnsanoğlu konfor gelişiminde bu araçları kullanırken zaman zaman kendi iradesi ile hareket edebilen akıllı araçların varlıklarını düşünmüşlerdir; “Uçan halı”, “Sihirli Lamba”, “Mjollnir (savaş çekici)”, “Ekskalibur (kayadaki kılıç)” bu durumu ortaya koyan farklı kültürlerden bazı örneklerdir. Yapay Zeka (YZ, Artificial Intelligence - AI) ifadesi, idealize edilmiş bir perspektif doğrultusunda canlı zekası davranışı sergilemek üzere kurgulanmış yapay işletim sistemi olarak görülebilir. İnsanlık tarihi boyunca makinelerin de canlılara özgü olan öğrenme ve edindiği tecrübelerle karar alabilmesinin mümkün olup olmayacağı tartışmaları günümüz AI kavramının temellerini oluşturur. Ancak bilimsel olarak yapay zekâ kavramı, bilgisayar kullanımının arttığı 1940 yılına gelindiğinde oluşmaya başlamıştır [8]. Alan Turing, John Von Neumann ve Norbert Wiener gibi isimler bu fikirler çevresinde zekâ taklit özelliği taşıyan yazılımlar ile makinelerin insan beynini taklit eden öğrenme ve çevre kontrolü sağlama becerileri üzerine çalışmalar yapmışlardır [9]. Yapay zeka ismi ilk kez 1956 yılında Dartmouth Konferansında J. McCarthy tarafından dile getirilmiş ve 1957 yılında geliştirdiği yazılım dili olan LISP ile uzun yıllar programlama yapılmıştır [8]. 1950-1970 yılları arasında Nöral ağlar ile yapılan ilk modern çalışmalarda düşünen makinalar olgusu heyecan uyandırmışken,

1980-2010 yılları arasında Makine öğrenmesi popülerleşmiş ve 2010 sonrasında Derin öğrenme kavramı ile bu süreç devam etmektedir (Şekil 3.2).



Şekil 3.2 Yapay Zeka kavramının gelişim süreci

3.3 Makine Öğrenmesi

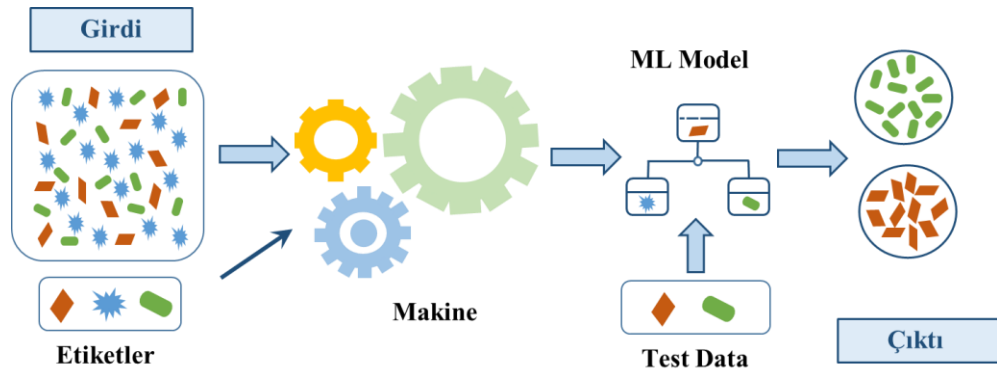
Makine öğrenimi (Machine Learning - ML), tükettiği verilere göre öğrenerek performansını iyileştiren sistemler oluşturmak için odaklanmış yapay zeka (AI) alt kümesi olarak tanımlanabilir. Kimi zaman birbiri yerine kullanılıyor ise de aynı anlamı taşımazlar. Tüm makine öğrenimi çözümleri öyle olsa bile, tüm yapay zeka çözümlerinin makine öğrenimi olmadığı gerçeği çok önemli bir ayrımdır [38]. Makine öğrenmesi algoritmalarla geliştirdiği eğitimlerinden yararlanarak doğruluğunu artırma yoluna gider. Bu algoritmaların performans anlamında verimliliğini arttırmak için yeni verilerle desteklenmesi ve bu sayede tahminleme, sınıflandırma başarılarının ortaya çıkması hedeflenir [8]. Başka bir ifade ile tekrar etmek gerekirse Makine öğrenimi, insanlar gibi makinelerin de nasıl öğrendiğinin incelenmesidir. Öğrenme süreci veri analizi ile başlar, veri işleme ile devam eder ve daha önce değerlendirilmiş

verilere dayanarak karar verme ile son bulur [9]. Açık programlama talimatları olmadan doğru bir model oluşturarak makine öğrenimi, sistemin özerk bir şekilde öğrenmesini sağlar. Özellikle kümeleme, optimizasyon ve sınıflandırma dahil IoT sorunlarını çözmek için makine öğrenmesi teknikleri uygulanır [9].

Denetimli Öğrenme (Supervised Learning), Denetimsiz Öğrenme (Unsupervised Learning) ve Pekiştirmeli Öğrenme (Reinforcement Learning) makine öğrenmesi algoritmaları olarak 3 sınıfa ayrılmaktadır [9].

3.3.1 Denetimli öğrenme

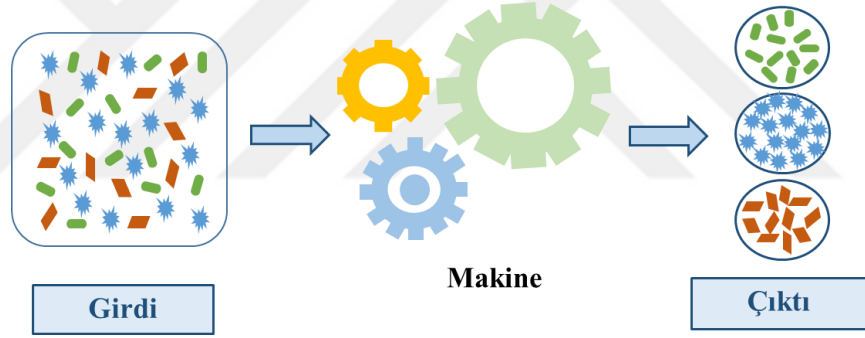
Denetimli Öğrenme, var olan bir veri kümesine ihtiyaç duyar bu veri kümesi eğitim aşamasında kullanılır. Eğitimler sonucunda çeşitli makine öğrenimi algoritmaları ile deneyim kazanan istenilen tahminleme yöntemi için kullanılır [8]. Bu süreçte giriş ve çıkış verileri etiketlenerek belirlenir. Bu yöntem, model etiketli verilerin işlevinden eğitilirken öğrenme aşamasında uzman deneyimine ihtiyaç duyar. Öğrenme süreci yüksek doğrulukta veri modelleri üretir ancak büyük veri kümeleri için etiketleme işlemi maliyetli ve zordur. Regresyon Analizi (Regression Analysis), Destek Vektör Makineleri (Support Vector Machines), Karar Ağaçları (Decision Trees), Rastgele Orman (Random Forest), Doğrusal Regresyon (Linear Regression) ve Lojistik Regresyon (Logistic Regression) algoritmaları Denetimli Öğrenme yöntemlerinden bazılarıdır. Denetimli öğrenme şeması Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Denetimli Öğrenme Şeması

3.3.2 Denetimsiz öğrenme

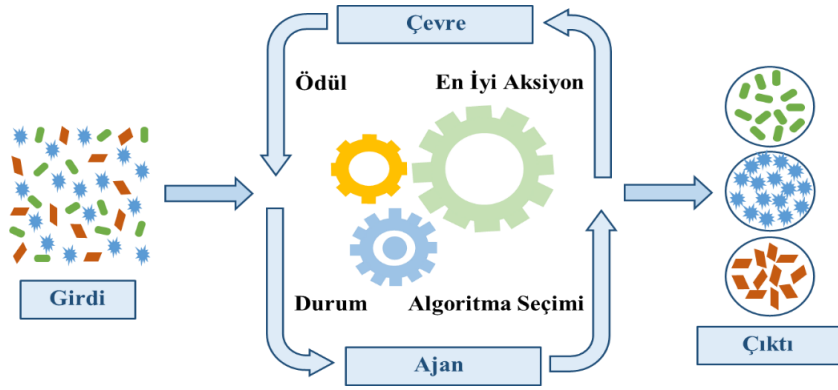
Denetimsiz öğrenme modelinde verilerin etiketlenmesinde ve modeli izlemesine gerek duyulmaz. Denetimsiz öğrenme modelinde; model veri kümesi kendi veri desenini ve bilgisini keşfetmeye çalışır. Özellikle kümelemede kullanılan bu modelin karmaşıklığı düşük olduğundan uygulanabilirliği yüksektir. Ancak bu yöntemde giriş bilgisi olmadığından çıkış verilerinin ve modelin doğruluğu düşüktür [9]. K-Ortalamalar Kümelemesi (K-Means Clustering), Hiyerarşik Kümeleme Analizi (Hierarchical Cluster Analysis), Kendi Kendine Organize Haritalar (Self Organizing Maps) ve Temel Bileşen Analizi (Principal Component Analysis) Denetimsiz Öğrenme yöntemlerinden bazılarıdır. Denetimsiz öğrenme şeması şekil 3.4’de gösterilmiştir.



Şekil 3.4 Denetimsiz Öğrenme Şeması

3.3.3 Pekiştirmeli öğrenme

Pekiştirmeli öğrenme modeli, model ile çevresi arasındaki etkileşim ilişkisini içerir. Bu öğrenme modeli, ödül ve ceza ilkelerini içerdiğinden deneme yanılma yoluyla öğrenme yoluyla verimliliği en üst düzeye çıkarır. Programcı makinenin uyması gereken yönergeleri oluştururken, çözüme nasıl ulaşılacağı konusunda rehberlik sunmaz; bunun yerine programın deneme yanılma yoluyla bir sonuca varacağını varsayıyorlar. Makine deneyerek ve hatalarından ders alarak faaliyetlerinden öğrenir ve sonunda doğru yolu bulur.. Pekiştirmeli Öğrenme Şeması şekil 3.5’te gösterilmiştir.




Şekil 3.5 Pekiştirmeli Öğrenme Şeması

3.4 Derin Öğrenme

Derin öğrenme yaklaşımının temelinde Yapay Sinir Ağları (YSA) yöntemi olup, Alexander Morton (1990) tarafından basit işlemci ünitelerinden oluşmuş, çok yoğun paralel ve dağılmış düzende çalışan işlemci olarak tanımlanmıştır. Basit işlemci ünitesini sinir hücrelerine benzeterek bilginin ortamdan öğrenme yolu ile elde edildiğini ve gerekli bilginin depolandığı yerleri basit işlemci üniteleri arasındaki bağlantılar olarak tanımlar. K. Kaysal [15], insan beyninin katmanlı yapısını taklit edebilen ve bir bilgisayarın tüm görevleri sayısal olarak yapmasını sağlayan bir modeldir. Ağın en önemli özelliğinin, modele verilen veri setini öğrenme ve amaçlanan sonuca uygun tahminler veya sınıflandırmalar sağlama, ağın yapısı ile biyolojik sinir ağının yapısı arasında karşılaştırmalar yapma yeteneği olduğunu iddia etti.

Yapay Sinir ağları beynin ağ yapısının hatırlama ve öğrenme özelliklerini örnek alarak oluşturulan matematiksel modellemesidir [39]. Güncel verilerden yararlanılarak yeni çıktılar oluşturabileceği için analiz, kategorize etme, tahmine dayalı tanıma, yorumlama ve ilişkilendirme gibi alanlarda faydalı olduğu söylenmektedir [40]. Haykin (1999) yapay sinir ağı hücresinin; girdiler (x_1, x_2, \dots, x_n), ağırlıklar (w_1, w_2, \dots, w_n), toplama işlemi (\sum), aktivasyon fonksiyonu (f) ve çıktı (y) olmak üzere beş temel bileşenden oluştuğu söyler. Yapay sinir hücresi örnek şeması Şekil 3.6'da gösterilmiştir.



Şekil 3.6 Yapay sinir hücresinin örnek şeması

Sundar.G (2016), derin öğrenme, bilgisayarların verilerdeki karmaşık yapıları ve kalıpları tanımasına ve bunlarla çalışmasına yardımcı olmak için YSA tabanlı öğrenme algoritmalarını kullanan bir tür makine öğrenimi olarak tanımlamıştır [41]. Ancak Derin öğrenme (Deep Learning) bir veya daha fazla katman içeren YSA ve makine öğrenme algoritmaları içeren bir teknoloji olduğundan [9] ya da başka bir deyişle yapay sinir ağlarının büyük miktarda veriden öğrendiği Makine öğreniminin bir alt kümesidir [42]. İnsan beyninin yapısını taklit ederek karmaşık sorunları çözebilen bir dizi algoritma olarak tanımlamıştır. Yapay sinir ağları gibi birçok derin öğrenme algoritması benzer mimariye sahiptir.

Buna bağlı olarak derin yapay sinir ağları, derin öğrenmenin diğer adı olarak tanımlanır. Yapay sinir ağının zaman içindeki çeşitli katmanları, bu öğrenme yönteminin "derin" kalitesini açıklamaktadır. Başka bir deyişle ağın derinliği rutinlerin ne kadar verimli olduğunu doğrudan etkiler. Derin öğrenmedeki temel doğrusal olmayan modüller, en iyi sonucu keşfetmek için düşük seviyeli verileri yüksek seviyeli verilere dönüştürür. [9] Ivakhnenko ve Lapa, 1965 yılında genel bir öğrenme algoritmasının temel temellerini geliştirmişlerdir. Bu çalışmada geri bildirim yöntemi yerine en küçük kareler yöntemi uygulanmıştır. Ivankhnenko'nun ardından Kunihiko Fukushima da 1979 yılında ilk derin öğrenme mimarisi olan "Neokognitron" yaklaşımını sunmuştur. Canlıların sinir sistemleri bu yapı için örnek model oluşturmuş ve "denetimsiz öğrenme" kendi kendini organize eden bir ağın gelişmesine olanak sağlamıştır. Ancak süreç içerisinde, daha öncelardan ortaya atılmış olsa da, geri beslemeli bir ağ yapısı algoritmasının daha performanslı olduğu ortaya çıkmıştır. Bir başka çalışmada bu performansı ispatlayan Yann LeCun ve arkadaşları, posta kutusu yazıları üzerinde çalışmışlardır. Yaptıkları çalışmalar sonucunda ağ başarılı olmuş

ancak eğitimin üç gün gibi kısa bir sürede gerçekleşmesi performansı açısından soru işaretleri bırakmış ve neticede pratik açıdan uygun olmadığı kararlaştırılmıştır [43].

1980’lerde Geoffrey Hinton tarafından Derin öğrenme modelleri kavramsallaştırılarak makine öğrenimi tekniklerinin insan beynine olan benzerliğini karşılaştırması ile derin öğrenmeye yöntemlerine büyük katkısı olmuştur. Hinton, beyindeki nöronların yapısına benzer şekilde yapılandırılmış bir derin öğrenme algoritması olan “sinir ağı” konseptini oluşturmuş o yıllar da teknolojik yetersizliklerin olması ve veri yetersizliği derin öğrenmenin kuramsallıktan öteye geçememiştir. Derin öğrenme kavramının yıllar önce ortaya çıkmasına rağmen, günümüze geldiğinde ivme kazanmasının en büyük sebebi teknolojik gelişmelerin yaşanmasıdır [44].

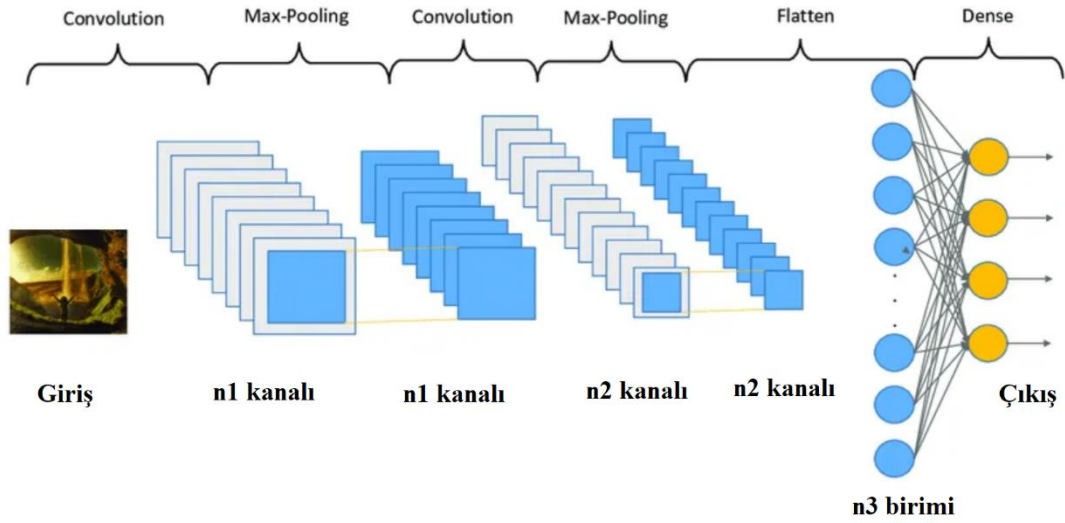
Derin öğrenme yapısı ile standart yapay zeka algoritması arasındaki temel farklardan biri, yapay zekanın programcının müdahale etmesini ve program yanlış bir tahmin yaptığında gerekli ayarlamaları yaparak işlemleri sürdürmesine yardımcı olmasını gerektirmesidir. Ancak derin öğrenme modeli kullanan bir algoritma, bir tahminin doğruluğunu değerlendirmek için sinir ağını kullanabilir. Yazılımın performansı ve doğruluğu, derin öğrenme algoritmasının işlediği veri miktarıyla birlikte artar. Makine öğrenmesi ile derin öğrenme arasında farklılık bulunur. Makine öğreniminde yazılım eninde sonunda ilerleme kaydetmeyi bırakır ve sabit bir öğrenme yolunu benimser; oysa derin öğrenmede veri hacmi arttıkça performans da artar [9].

Makine öğreniminin daha gelişmiş bir türüne Derin Öğrenme adı verilir. Makine öğreniminin ilk adımı, kullanıcı tarafından verinin özelliklerini manuel olarak çıkarılmasıdır. Verilerdeki nesnelere bu özellikleri kullanılarak kategorize edilir. Derin Öğrenmede ilgili özellikler verilerden otomatik olarak çıkarılır [45].

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

3.5 Evrişimli Sinir Ağları (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 [21]. 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 (Şekil 3.7). 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.



Şekil 3.7 Örnek bir CNN mimarisinin yapısı


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

3.6 Yinelemeli Sinir Ağı (RNN) Modeli

Tekrarlayan sinir ağları veya RNN'ler, zaman serilerini veya sıralı verileri tahmin etmek için kullanılabilen bir tür yapay sinir ağıdır. RNN ağları, tıpkı yapay sinir ağları gibi, gradyan inişi (gradient descent) ve geri yayılım yöntemleri kullanılarak eğitilir. Şekil 3.8'de gösterilen bir RNN ünitesi için çıkış ifadesi denklem (3.1)'de verilmiştir.

$$h_t = f(W_h h_{t-1} + W_x x_t + b) \quad (3.1)$$

Denklemden yer alan W ağırlık, b bias, h_t hücrenin t zamanındaki çıktı verisi, x_t ise t zamanındaki girdi verisini ifade eder [21].




Şekil 3.8 RNN Ünitesi

3.7 Uzun Kısa Süreli Bellek Ağları (LSTM) Modeli

Zaman geriye yayılım tekniğindeki birimlerin sayısı çok fazlaysa, bu, RNN hücrelerinde gradyan zorluklarının kaybolmasına veya patlamasına neden olur. RNN'in eksikliği, kaybolan gradyan problemi nedeniyle uzun vadeli bağımlılıkları

hatırlayamamalarıdır [12]. LSTM, uzun vadeli bağımlılık sorunlarına çözüm sunmak amacıyla geliştirilmiştir [22]. LSTM farklı fonksiyonlara sahip kapılardan oluşmaktadır. Örneğin LSTM, farklı zaman aralığındaki 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 [23].



Şekil 3.9 LSTM Ünitesi

Şekil 3.9’da gösterilen bir LSTM ünitesi için giriş kapısı ifadesi Denklem (3.2)’de verilmiştir. Denklem (3.3)’de unutmaya kapısı, Denklem (3.4)’de çıkış kapısı verilmiştir. Denklem (3.5)’de h_t ve Denklem (3.6)’da C_t verilmiştir.

$$\text{Giriş kapısı } i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (3.2)$$

$$\text{Unutmaya kapısı } f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (3.3)$$

$$\text{Çıkış kapısı } o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (3.4)$$


$$h_t = o_t * \tanh(C_t) \quad (3.5)$$

$$\text{Hücre durumu } C_t = f_t * C_{t-1} + i_t * \tanh(W_C * [h_{t-1}, x_t] + b_C) \quad (3.6)$$

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.

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

Hem RNN hem de LSTM modeli, bilginin yalnızca zaman içinde ileriye doğru yayılmasına izin verir [25]. Bağlam bilgisini geçmiş ve gelecek zamandan aynı anda yakalamak için çift yönlü RNN geliştirilmiştir. Bu aşamadan sonra Şekil 3.10'da gösterildiği gibi geçmiş ve gelecek bilgilerin etkin kullanımını sağlamak için çift yönlü RNN ve LSTM birimleri birleştirilerek BiLSTM modeli geliştirilmiştir [22]. İleri ve geri katmanlardan gelen girdiler, çıktı katmanı tarafından eş zamanlı olarak işlenir [28].




Şekil 3.10 BiLSTM Ünitesi

3.9 Önerilen Derin Öğrenme Modelleri

Tez kapsamında elektrik tüketiminin tahmini için önerilen makine öğrenmesi modelleri aşağıda açıklanmıştır.

3.9.2 Önerilen CNN modeli

Enerji aktif tüketim verileri bir boyutlu olması nedeniyle çalışma kapsamında 1D-CNN ağı tercih edilmiştir. Tasarlanan derin ağ modelinin detayları Şekil 3.11’de gösterilmiştir. Birinci CNN katmanında (3,) boyutunda 256 filtre ve aktivasyon fonksiyonu olarak ReLU kullanılmıştır. İkinci CNN katmanında ise (1,) 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 3.11 Tasarlanan 1D-CNN model katmanları

3.9.3 Önerilen RNN modeli

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 için tek bir çıktı oluşmasıdır (Tablo 3.2). Her 3 uygulama için oluşturulan mimaride eğitilebilir parametre sayısı Tablo 3.2’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 | Total params: 10,701 | | Total params: 253,501 | |
| | | Trainable params: 2,851 | Trainable params: 10,701 | | Trainable params: 253,501 | |
| | | Non-trainable params: 0 | Non-trainable params: 0 | | Non-trainable params: 0 | |

Tablo 3.2 Tasarılan 3 farklı RNN model mimarisinin katmanları ve eğitilebilen parametre sayıları

3.9.4 Önerilen LSTM modeli

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 Tablo 3.3’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 | |

Tablo 3.3 Tasarılan 3 farklı LSTM model mimarisinin katmanları ve eğitilebilen parametre sayıları

3.9.5 Önerilen BiLSTM modeli

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 Tablo 4'de gösterilmiştir. BiLSTM 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 # |
| 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 | | |

Tablo 3.4 Tasarlanan 3 farklı BiLSTM model mimarisinin katmanları ve eğitilebilen parametre sayıları

3.10 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, beklenen değer ile gerçek değerlerin sırasıyla benzer ve farklı olma derecesini değerlendirerek pozitif ve negatif tahmin hatalarının karşılaştırılmasını önler [28]. R^2 , bağımlı değişkendeki değişikliklerin hangi ölçüde bağımsız değişkendeki değişikliklerden kaynaklandığını ifade eder. R^2 değeri [0 - 1] aralığında yer alır ve değerinin 1'e yakınsaması, modelin doğruluğunun artması anlamına

gelmektedir. Aşağıda sırasıyla Denklem (3.7)'de RMSE, Denklem (3.8)'de MAE ve Denklem (3.9)'da R^2 metriklerine ilişkin denklemler verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^* - x_i)^2} \quad (3.7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (3.8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - x_i^*)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{ve} \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.9)$$

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.

4. BULGULAR

Bu tez 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.

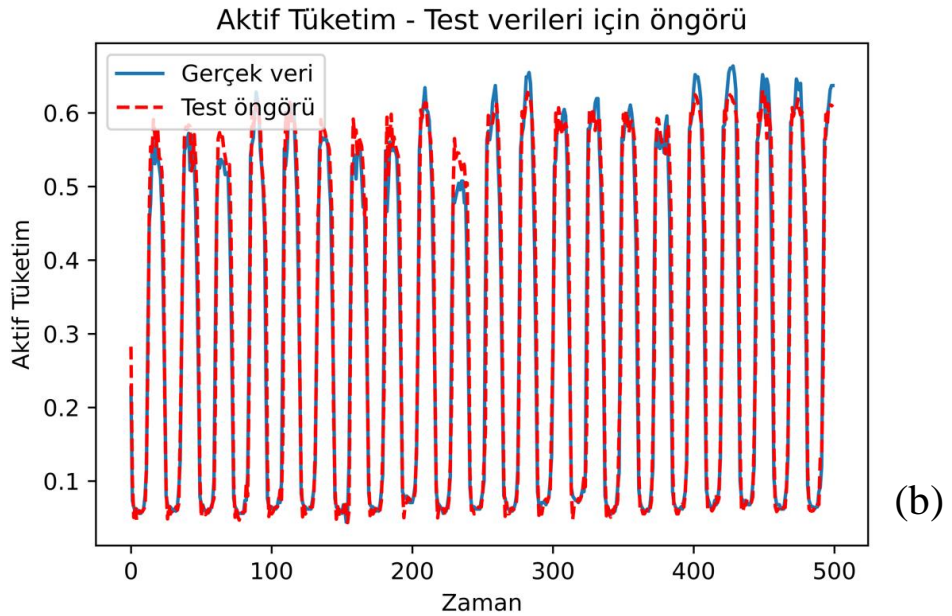

Modellerin derlenmesinde kullanılan parametreler; kayıp (loss) fonksiyonu olarak ortalama karesel hata (mean squared error- MSE), optimizasyon algoritması olarak Adam, her bir iterasyonda dikkate alınan örnek sayısı (batch_size) 32 ve eğitim için tam bir tur sayısı (epochs) olarak 50 alınmıştır. Tüm 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.



4.1 1D-CNN Uygulaması İçin Bulgular

1D-CNN modeli için belirlenen mimari ile elde edilen en yüksek başarı performansı Tablo 4.1’de gösterilmiştir. Tabloda önerilen mimari ile elde edilen metrik değerleri gösterilmiştir. Önerilen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri Grafik 4.1’da gösterilmiştir. Grafik 4.1 (a)’da ham veri, eğitim verisi, test verisi ve elde edilen öngörü değişimleri gösterilmiştir. Elde edilen sonucun daha iyi görülebilmesi için Grafik 4.1 (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 Grafik 4.1 (c)’de gösterilmiştir. Grafik 4.1 (d)’de ise eğitim sürecinde iterasyon ile ortalama karesel hatanın değişimi gösterilmiştir.

Tablo 4.1 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 |





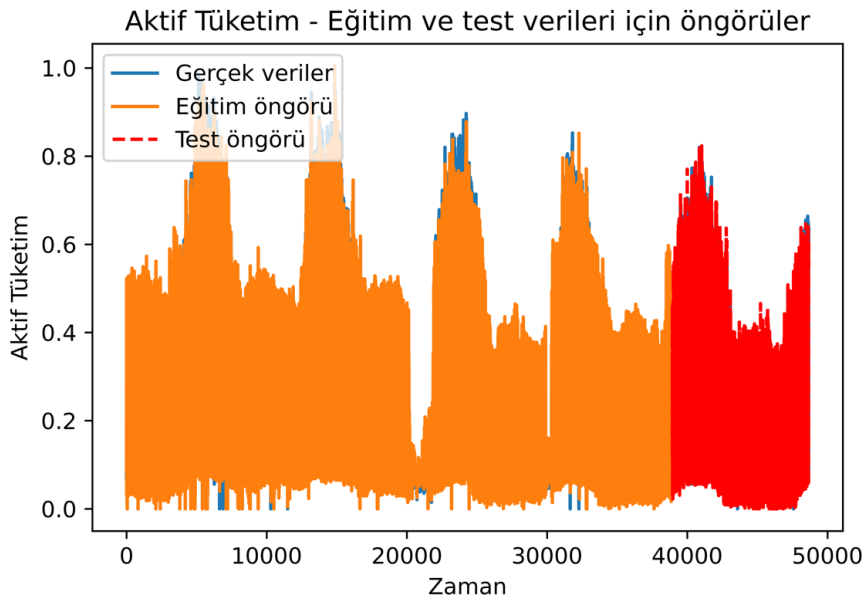
Grafik 4.1 Enerji t¼kretim tahmini iin saatlik öz¼n¼rl¼kte 1D-CNN modelinin tahmin grafikleri: (a) l¼len aktif t¼kretim ve model ile elde edilen tahmini deęerler, (b) Test verisinin son 500 rneęine iliřkin l¼len aktif t¼kretim deęerleri ve elde edilen tahmini deęerler, (c) test veri setinde tahmin ve gerek deęer arasındaki iliřkiyi gsteren serpilme (scatterplot) diyagramı, (d) Eđitim s¼recinde elde edilen epoch-mse deęiřimi.


4.2 RNN Uygulaması İçin Bulgular

Uygulamada ünite-düğüm sayısı =50, 100 ve 500 için elde edilen en yüksek başarımların performansları Tablo 4.2’de gösterilmiştir. Tabloda 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 Grafik 4.2’de (a,b,c,d) gösterilmiştir.


Tablo 4.2 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 |

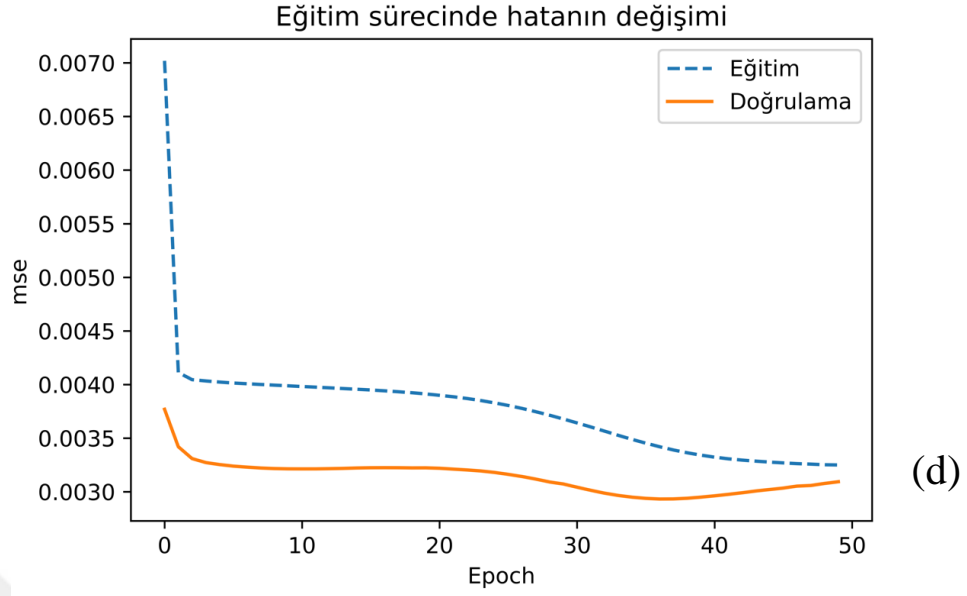




(b)



(c)




Grafik 4.2 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.

4.3 LSTM Uygulaması İçin Bulgular

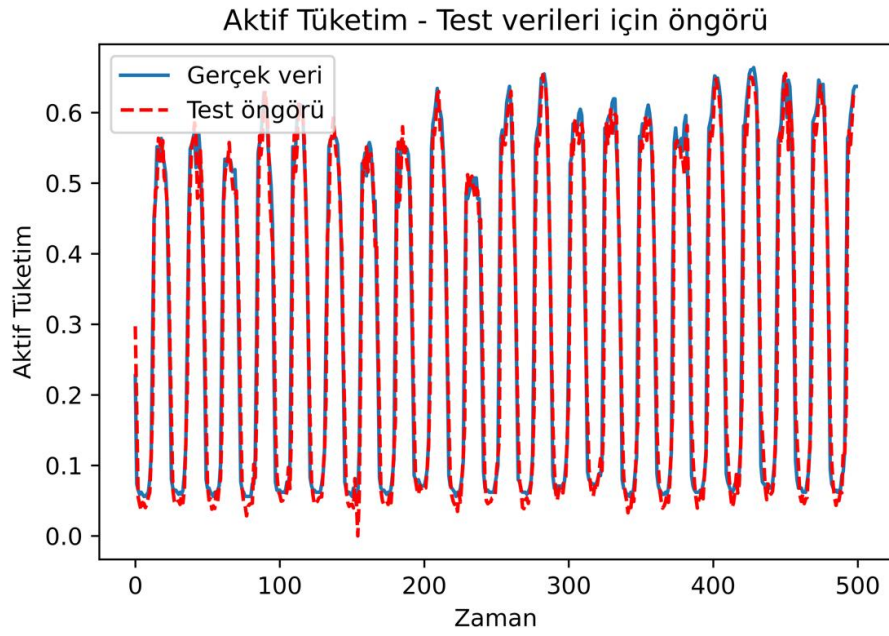
Uygulamada ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en yüksek başarımların performansları Tablo 4.3’de gösterilmiştir. Tabloda sonuçları verilmiş olan mimarilere ilişkin başarımların bir önceki uygulamada olduğu gibi birbirine yakın olduğu ve en iyi performansın ünite-düğüm sayısı 100 olan mimaride elde edildiği görülmektedir. Daha iyi başarımlar sergileyen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri Grafik 4.3’de gösterilmiştir.

Tablo 4.3 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 |



(a)




(b)



(c)

Eğitim sürecinde hatanın değişimi



(d)


Grafik 4.3 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.

4.4 BiLSTM Uygulaması İçin Bulgular


Uygulamada yine ünite-düğüm sayısı=50, 100 ve 500 için denenmiş ve elde edilen en yüksek başarımların performansları Tablo 4.4'te gösterilmiştir. Tabloda 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 başarımların sergileyen mimarinin eğitim süreci ile elde edilen tahmin ve gerçek değer ilişkileri Grafik 4.4'de gösterilmiştir.

Tablo 4.4 Önerilen BiLSTM modelinde ünite-düğüm sayısı 50, 100 ve 500 için elde edilen en iyi performanslar.

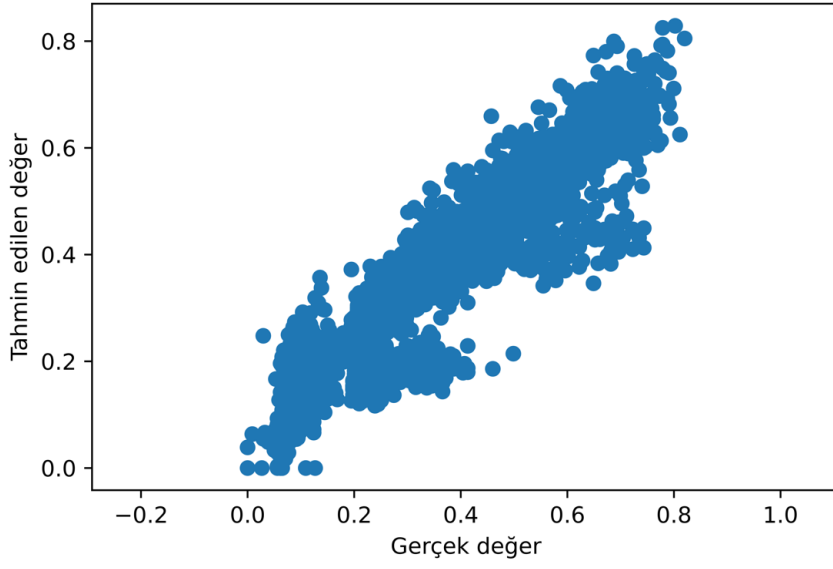
| BiLSTM Ağ Mimarisi | Ünite- düğüm sayısı | RMSE | | MAE | | R^2 | |
|--------------------------|---------------------------|---------------|---------------|---------------|---------------|---------------|---------------|
| | | Eğitim | Test | Eğitim | Test | Eğitim | Test |
| | 50 | 0,0608 | 0,0520 | 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 |




(a)



(b)



(c)



(d)

Grafik 4.4 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.

5. SONUÇLAR VE ÖNERİLER

Bu tez 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 başarımlarının performansı 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) izlendiği görülmektedir. Bu çalışmada da orta vadede elde edilen geçmiş veriden yola çıkılarak enerji tüketiminin tahmini gerçekleştirilmiştir. Bu çalışmada önerilen modeller geliştirilerek, farklı sektörlere ilişkin enerji tüketim verilerine uygulanması, gelecek çalışmalar kapsamında değerlendirilmektedir.



KAYNAKLAR

- [1] Berriel, R. F., Lopes, A. T., Rodrigues, A., Varejao, F. M. ve Oliveira-Santos, T. (2017). Monthly energy consumption forecast: a deep learning approach. *2017 International Joint Conference On Neural Networks (Ijcn)*, (Electronic ISSN: 2161-4407), 4283-4290. <https://doi.org/10.1109/IJCNN.2017.7966398>
- [2] Bedi, J. ve Toshniwal, D. (2019). Deep learning framework to forecast electricity demand. *Elsevier Applied Energy*, (238), 1313-1326. <https://doi.org/10.1016/j.apenergy.2019.01.113>
- [3] Haliloğlu, E. ve Tutu, B. (2018). Türkiye için kısa vadeli elektrik enerjisi talep tahmini. *Journal Of Yasar University*, (13/51), 243-255.
- [4] Ullah, F. M., Ullah, A., Khan, N., Lee, M. Y., Rho, S. ve Baik, S. W. (2022). Deep learning-assisted short-term power load forecasting using deep convolutional lstm and stacked gru. *Wiley Hindawi Complexity*, (2993184), 1-15. <https://doi.org/10.1155/2022/2993184>
- [5] Singh, A. K., Khatoon, İ. S. ve Muazzam, M. (2013). An overview of electricity demand forecasting techniques. *Network And Complex Systems*, 3(2), 38-48. www.iiste.org
- [6] Kuşkan, E., Çodur, M. K. ve Çodur, M. Y. (2022). Türkiye'deki demiryolu enerji tüketiminin yapay sinir ağları ile tahmin edilmesi. *Konya Mühendislik Bilimleri Dergisi*, 10(1), 72-84. <https://doi.org/10.36306/konjes.935621>
- [7] Bouktif, S., Fiaz, A., Ouni, A. ve Serhani, M. A. (2018). Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches. *Energies*, 11(7)(1636), 1-20. <https://doi.org/10.3390/en11071636>
- [8] Gezmez, K. Ç. (2022). *Bir ilin elektrik tüketim verilerinin makine öğrenmesi yöntemleri ile analizi* [Yayımlanmamış yüksek lisans tezi]. Başkent Üniversitesi.
- [9] Yurdoğlu, H. (2023). *Bir tekstil fabrikasının elektrik tüketim değerlerinin derin öğrenme ile tahminlenmesi* [Yayımlanmamış yüksek lisans tezi]. Pamukkale Üniversitesi.
- [10] Bedi, J. ve Toshniwal, D. (2018). Empirical mode decomposition based deep learning for electricity demand forecasting. *Ieee Access*, 4, 49144-49156. <https://doi.org/10.1109/ACCESS.2018.2867681>
- [11] Wang, Q., Bu, S., He, Z. ve Dong, Z. Y. (2021). Toward the prediction level of situation awareness for electric power systems using cnn-lstm network. *Ieee Transactions On Industrial Informatics*, 17(10), 6951-6961. <https://doi.org/10.1109/TII.2020.3047607>

- [12] Ibrahim, B., Rabelo, L., Gutierrez-Franco, E. ve Clavijo-Buritica, N. (2022). Machine learning for short-term load forecasting in smart grids. *Energies*, 15(21), 8079 (1-19). <https://doi.org/10.3390/en15218079>
- [13] Seabe, P. L., Moutsinga, C. R. B. ve Pindza, E. (2023). Forecasting cryptocurrency prices using lstm, gru and bi-directional lstm:a deep learning approach. *Fractal And Fractional*, 7(203), 1-18. <https://doi.org/10.3390/fractalfrac7020203>
- [14] Kiprijanovska, Ī., Stankoski, S., Ilievski, Ī., Jovanovski, S., Gams, M. ve Gjoreski, H. (2020). Houseec: day-ahead household electrical energy consumption forecasting using deep learning. *Energies*, 13(2672), 1-29. <https://doi.10.3390/en13102672>
- [15] Kaysal, K., Akarşlan, E. ve Hocaođlu, F. O. (2022). *Türkiye kısa dönem elektrik yük talep tahmininde makine öğrenmesi yöntemlerinin karşılaştırılması*. Bşeu Fen Bilimleri Dergisi, 9(2), 693-702. <https://doi.org/10.35193/bseufbd.1004827>
- [16] Solyalı, D. (2020). A comparative analysis of machine learning approaches for short-/long-term electricity load forecasting in Cyprus. *Sustainability*, 12(3612), 1-34. <https://doi.org/10.3390/su12093612>
- [17] Belagoune, S., Bali, N., Bakdi, A., Baadji, B. ve Atif, K. (2021). Deep learning through lstm classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems. *Elsevier Measurement*, 177(109330), 1-14. <https://doi.org/10.1016/j.measurement.2021.109330>
- [18] Wen, S., Wang, Y., Tang, Y., Xu, Y., Li, P. ve Zhao, T. (2019). Real-time identification of power fluctuations based on lstm recurrent neural network: a case study on singapore power system. *Ieee Transactions On Industrial Informatics*, 15(9), 5266-5275. <https://doi.org/10.1109/TII.2019.2910416>
- [19] Alazab, M., Khan, S., Rama, S. S., Krishnan, , Pham, Q., Reddy, M. P. K. ve Gadekallu, T. R. (2020). A multidirectional lstm model for predicting the stability of a smart grid. *Ieee Access, Special Section On Evolving Technologies In Energy Storage Syytems For Energy Systems Applications*, 8(2020), 85454-85463. [11.1109/ACCESS.2020.2991067](https://doi.org/10.1109/ACCESS.2020.2991067)
- [20] Tulensaloo, J., Seppänen, J. ve Ilina, A. (2020). An lstm model for power grid loss prediction. *Elsevier, Electric Power Systems Research*, 189(106823), 1-4. <https://doi.org/10.1016/j.epsr.2020.106823>
- [21] Al-Jaafrey, T. M., Al-Odienat, A. ve Altaharwah, Y. A. (2022). The solar energy forecasting using lstm deep learning technique. *2022 International Conference On Emerging Trends In Computing And Engineering Applications (Etcea)*, 978-16654-7709-3(22). <https://doi.org/10.1109/ETCEA57049.2022.10009717>
- [22] Torres, J. F., Lvarez, F. M. ve Troncoso, A. (2022). A deep lstm network for the spanish electricity consumption forecasting. *Neural Computing And Applications*, 2022(34), 10533-10545. <https://doi.org/10.1007/s00521-021-06773-2>

- [23] Mocanu, E., Nguyen, P. H., Gibescu, M. ve Kling, W. L. (2016). Deep learning for estimating building energy consumption. *Elsevier - Sustainable Energy, Grids And Networks*, 6(2019), 99-99. <http://dx.doi.org/10.1016/j.segan.2016.02.005>
- [24] Bedi, J. ve Toshniwal, D. (2019). Deep learning framework to forecast electricity demand. *Elsevier - Applied Energy*, 238(2019), 1312-1326. <https://doi.org/10.1016/j.apenergy.2019.01.113>
- [25] Agga, A., Abbou, A., Labbadi, M., Houm, Y. E. ve Ali, İ. H. O. (2022). Cnn-lstm: an efficient hybrid deep learning architecture for predicting short-term photovoltaic power production. *Elsevier - Electric Power Systems Research*, 208(107908), 1-14. <https://doi.org/10.1016/j.epr.2022.107908>
- [26] Rao, S. N. V. B., Yellapragada, V. P. K., Padma, K., Pradeep, D. J., Reddy, C. P., Amir, M. ve Refaat, S. S. (2022). Day-ahead load demand forecasting in urban community cluster microgrids using machine learning methods. *Energies - Mdpi*, 15(6124), 1-25. <https://doi.org/10.3390/en15176124>
- [27] Vantuch, T., Vidal, A. G., Ramallo-González, A. P., Skarmeta, A. F. ve Mišák, S. (2016). Machine learning based electric load forecasting for short and long-term period. *Ieee*, 978-1-5090-4130-5(16), 511-516.
- [28] Ghazal, T. M., Noreen, S., Said, R. A., Khan, M. A., Siddiqui, S. Y., Abbas, S., Aftab, S. ve Ahmad, M. (2022). Energy demand forecasting using fused machine learning approaches. *Intelligent Automation & Soft Computing - Tech Science Press*, 33(1), 539-553. <https://doi.org/10.32604/iasc.2022.019658>
- [29] Olu-Ajayi, R., Alaka, H., Sulaimon, İ., Sunmola, F. ve Ajayi, S. (2022). Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques. *Elsevier - Journal Of Building Engineering*, 45(103406), 1-13. <https://doi.org/10.1016/j.job.2021.103406>
- [30] Chen, C., Liu, Y., Kumar, M. ve Qin, J. (2018). Energy consumption modelling using deep learning technique —a case study of eaf. *Elsevier - Sciencedirect, 51St Cirp Conference On Manufacturing Systems*, 72(2018), 1063-1068. <https://doi.org/10.1016/j.procir.2018.03.095>
- [31] 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. *Elsevier - Sustainable Computing: Informatics And Systems*, 30(100532), 1-12. <https://doi.org/10.1016/j.suscom.2021.100532>
- [32] Enerji ve Tabii Kaynaklar Bakanlığı, (2024, Nisan). *Elektrik*. <https://Enerji.gov.tr>. <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>
- [33] Tedas, (2024, Nisan). *Elektrik dağıtım şirketleri*. tedas.gov.tr/Tr/1. <https://tedas.gov.tr/tr/1>
- [34] Teias, (2024, Mayıs). *Türkiye elektrik üretim-iletim 2022 istatistikleri*. <https://www.teias.gov.tr>. <https://www.teias.gov.tr/turkiye-elektrik-uretim-iletim-istatistikleri>

- [35] Bilim, N. (2016). *Türkiye'nin elektrik enerjisi üretimindeki dışa bağımlılığın azaltılması için uygulanması gereken politikalar*. Selçuk Üniversitesi Mühendislik Fakültesi, 4(2), 145-154. <https://doi.org/10.15317/Scitech.2016218526>
- [36] Jahan, I. S., Snasel, V., & Misak, S. (2020). *Intelligent systems for power load forecasting: A study review*. *Energies*, 13(22), 6105.
- [37] Aguilar Madrid, E.; Antonio, N. *Short-Term Electricity Load Forecasting with Machine Learning*. *Information* 2021, 12, 50. <https://doi.org/10.3390/info12020050>
- [38] Oracle, (2024, Mayıs). *Makine öğrenimi nedir?*. <https://www.oracle.com/Tr>. <https://www.oracle.com/tr/artificial-intelligence/machine-learning/what-is-machine-learning/>
- [39] M.Y. Çodur, A. Tortum, 2009, *Modelling Car Ownership in Turkey Using Neural Networks*, *Proceedings of the Institution of Civil Engineers-transport*, 62(2), 97-106
- [40] M.Erdoğan, İ.Kaya, 2020, *A New Approach for Rule Estimation of Fuzzy Inference System*, *Konya Mühendislik Bilimleri Dergisi*, 8(4), 906-915
- [41] Sundar, G., and Patchaiammal, P. (2022, February). *Comprehensive Deep Recurrent Artificial Neural Network (CDRANN): Evolutionary Model for Future Prediction*. In *International Conference on Computing, Communication, Electrical and Biomedical Systems* (pp. 217-234). Cham: Springer International Publishing.
- [42] Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). "Machine learning and deep learning in energy systems: A review", *Sustainability*, 14(8), 4832.
- [43] Şeker, A., Diri, B., Balık, H. (2017). *Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme*. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- [44]Turhost, (2021, Kasım). *Deep learning nedir?*. <https://www.turhost.com>. <https://www.turhost.com/blog/deep-learning-nedir/>
- [45] Becominghuman, (2011, Kasım). *Yapay zeka, makine öğrenimi ve derin öğrenme nedir?*. <https://www.elektrikport.com>. <https://www.elektrikport.com/teknik-kutuphane/yapay-zek%C3%A2-makine-ogrenimi-ve-derin%20ogrenme-nedir/21774#ad-image-0>

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad ,

BERUS, Yusuf

Web sayfası
(Research Gate, Academia, vs.)

Eğitim Bilgileri

| Derece | Kurum | Mezuniyet Yılı |
|---------------|---|----------------|
| Yüksek Lisans | - | |
| Lisans | Dicle Üniversitesi, Elektrik-Elektronik Müh. | 1997 |
| Lise | İsmet Paşa Lisesi (Gaziantep) | 1992 |

İş Denevi

| Dönem (Yıl) | Şirket, Kurum | Görev |
|-------------|-----------------------|-------------------------------------|
| 1997-1998 | Şehitkamil Belediyesi | Fen Müdürlüğü Elektrik Mühendisi |
| 1998-2004 | SMM | Şantiye Şefi, Saha Mühendisi |
| 2004-2013 | TEDAŞ, Batman | Proje Tesis Planlama Müdürü |
| 2013-2024 | DİCLE EDAŞ | Enrj. Kyp. ve OSOS Saha Opr. Müdürü |

Yabancı Dil

İngilizce, B1

Yayınlar

1. Diyarbakır DİSKİ Enerji Sistemi Güç İletiminde Seri Kompanzasyon ile P- δ Eğrilerinin Modellenmesi, İNSAC
- 2.-
- 3.-
- 4.-

Özel İlgiler

Arıcılık

Sürücü Belgesi B Sınıfı

Sertifikalar: : Linkage Yönetici Geliştirme Programı, ELDER Elektrik Piyasası Dağıtım ve Tüketici Hizmetler Eğitimi, ELDER Elektrik Piyasası Tarifeler Eğitimi

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

| | | | |
|--|---|---|----------------------------------|
| Öğrencinin Adı, Soyadı | Yusuf BERUS | | |
| Öğrenci No | 22805022 | | |
| Ana Bilim Dalı | Elektrik-Elektronik Mühendisliği | | |
| Program Türü | Proje <input type="checkbox"/> | Yüksek Lisans <input checked="" type="checkbox"/> | Doktora <input type="checkbox"/> |
| Tez Danışmanı (Ünvanı, Adı, Soyadı) | Dr. Öğr. Üyesi Yurdağül BENTEŞEN YAKUT | | |
| (Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı) | - | | |
| Tez Başlığı | Enerji Sistemlerinde Makine Öğrenmesi ile Güç Tüketim Tahmini | | |
| RAPOR BİLGİLERİ | | | |
| Raporlama Aşaması | | | |
| Sayfa Sayısı | 66 | | |
| Raporlama Tarihi | 05.07.2024 | | |
| Benzerlik Oranı (%) | 14 | | |

Yukarıda bilgileri verilen tez çalışmamın toplam sayfalık kısmına ilişkin, 05/06/2024 tarihinde şahsım/tez danışmanım tarafından turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 14 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
Kaynaklar hariç
Alıntılar hariç/dâhil
Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Yusuf BERUS

Tarih: 05.07.2024

İmza:

Danışman Adı, Soyadı: Dr. Öğr. Üyesi

İmza:

Yurdağül BENTEŞEN YAKUT

Tarih:

Ana Bilim Dalı Başkanı Adı, Soyadı:

İmza:

Doç. Dr. Cafer BUDAK

Tarih:
