

T.C.  
NUH NACİ YAZGAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME İLE ELEKTRİK DAĞITIM ŞEBEKELERİNDE  
TÜKETİM TAHMİNLERİ ANALİZİ

Numan KÖKSAL

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI  
Doç. Dr. Zeki ORALHAN

Ağustos 2025  
KAYSERİ



T.C.  
NUH NACİ YAZGAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME İLE ELEKTRİK DAĞITIM ŞEBEKELERİNDE  
TÜKETİM TAHMİNLERİ ANALİZİ

Numan KÖKSAL

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI  
Doç. Dr. Zeki ORALHAN

Ağustos 2025  
KAYSERİ

**KABUL VE ONAY SAYFASI**

Doç. Dr. Zeki ORALHAN danışmanlığında Numan KÖKSAL tarafından hazırlanan “Derin Öğrenme İle Elektrik Dağıtım Şebekelerinde Tüketim Tahminleri Analizi” adlı bu çalışma jürimiz tarafından Nuh Naci Yazgan Üniversitesi Lisansüstü Eğitim Enstitüsü **Elektrik Elektronik Mühendisliği Anabilim Dalı, Elektrik Elektronik Mühendisliği Yüksek Lisans Programında Yüksek Lisans Tezi** olarak kabul edilmiştir.

28 / 08 / 2025

**Jüri Başkanı :** *Prof. Dr. Fatma LATİFOĞLU*  
*Erciyes Üniversitesi*

**Tez Danışmanı:** *Doç. Dr. Zeki ORALHAN*  
*Nuh Naci Yazgan Üniversitesi*

**Üye :** *Doç. Dr. Asuman SAVAŞÇIHABEŞ*  
*Nuh Naci Yazgan Üniversitesi*

**ONAY**

Bu tezin kabulü Enstitü Kurulunun ..... tarih ve ..... sayılı kararı ile onaylanmıştır.

...../...../2025  
*Doç. Dr. Burcu ORALHAN*  
**Enstitü Müdürü**

## YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Nuh Naci Yazgan Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / Nuh Naci Yazgan Üniversitesi Kütüphanesi Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. <sup>(1)</sup>
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ... **ay** ertelenmiştir. <sup>(2)</sup>
- Tezimle ilgili gizlilik kararı verilmiştir. <sup>(3)</sup>

28 /08/ 2025

Numan KÖKSAL

“*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*”

- (1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanın**ın önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanın**ın önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir \*. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.  
Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

\* Tez **danışmanın**ın önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** tarafından karar verilir.

**ETİK BEYAN**

Bu alıřmadaki bütn bilgi ve belgeleri akademik kurallar erevesinde elde ettiđimi, grsel, iřitsel ve yazılı tm bilgi ve sonuları bilimsel ahlak kurallarına uygun olarak sunduđumu, kullandıđım verilerde herhangi bir tahrifat yapmadıđımı, yararlandıđım kaynaklara bilimsel normlara uygun olarak atıfta bulunduđumu, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, Do. Dr. Zeki ORALHAN danıřmanlıđında tarafımdan retildiđini ve Nuh Naci Yazgan niversitesi Lisansst Eđitim Enstits Tez Yazım Kılavuzuna gre yazıldıđını beyan ederim.

*Numan KKSAL*

## TEŞEKKÜR

Yüksek Lisans tez çalışmam süresince değerli bilgilerini ve yardımlarını esirgemeyen danışmanım Nuh Naci Yazgan Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Öğretim Üyesi Sn. Doç. Dr. Zeki ORALHAN 'a, sabırla bana bu süreçte destek çıkan ve yanımda olan eşim Azime İrem KÖKSAL 'a, bu günlere gelmemde emek ve desteklerini hiçbir zaman esirgemeyen ve her zaman yanımda olan babam Selçuk KÖKSAL 'a, annem Belkıs KÖKSAL 'a, abim Enes KÖKSAL 'a ve biricik yiğenim İpek KÖKSAL 'a teşekkürlerimi borç bilirim. (Kayseri, 28/08/2025).

Numan KÖKSAL



## ÖZET

Bu tez, enerji tüketim tahminlerinin doğruluğunu ve verimliliğini artırmayı amaçlayan derin öğrenme modellerinin kullanımını incelemektedir. Elektrik dağıtım şebekelerinin etkin yönetimi, sürdürülebilir enerji kaynaklarının entegrasyonu ve talep yönetimi gibi konularda bu tekniklerin nasıl faydalı olabileceği araştırılmaktadır. Tez, elektrik tüketim tahminlerinin doğruluğunu artırarak, enerji maliyetlerini optimize etmek, yenilenebilir enerji kullanımını artırmak ve enerji kayıplarını azaltmak için öneriler sunmaktadır. Ayrıca, derin öğrenme ve yapay zeka teknolojilerinin enerji sistemlerinin daha verimli ve sürdürülebilir hale getirilmesindeki potansiyeli vurgulanmaktadır. Çalışmada elektrik tüketim tahminlerinde kullanılan dört popüler derin öğrenme modeli olan Uzun Kısa Süreli Bellek (LSTM), Çok Katmanlı Algılayıcılar (MLP), Tekrarlayan Sinir Ağları (RNN), Kapı Kontrollü Tekrarlayan Birimler (GRU) ve Transformer Derin Öğrenme Modeli yöntemleri incelenmiş ve elde edilen sonuçlar neticesinde RNN modelinin diğerlerine göre daha yüksek tahmin başarısı sergilediği tespit edilmiştir.

**Anahtar Kelimeler:** Çok katmanlı algılayıcılar, derin öğrenme, elektrik tüketimi, hava durumu, kapı kontrollü tekrarlayan birimler, tekrarlayan sinir ağları, uzun kısa süreli bellek

## ABSTRACT

This thesis examines the use of deep learning models aimed at improving the accuracy and efficiency of energy consumption forecasts. It investigates how these techniques can be beneficial in areas such as the effective management of electricity distribution networks, integration of sustainable energy sources, and demand management. By enhancing the accuracy of electricity consumption predictions, the study offers suggestions for optimizing energy costs, increasing the use of renewable energy, and reducing energy losses. Moreover, it highlights the potential of deep learning and artificial intelligence technologies to make energy systems more efficient and sustainable. The study analyzes four popular deep learning models used in electricity consumption forecasting: Long Short-Term Memory (LSTM), Multilayer Perceptrons (MLP), Recurrent Neural Networks (RNN), Gated Recurrent Units (GRU), and the Transformer Deep Learning Model. Based on the results obtained, it was determined that the RNN model exhibited higher prediction accuracy compared to the others.

**Keywords:** Multilayer Perceptrons, Deep Learning, Electricity consumption, Weather, Gated Recurrent Units, Recurrent Neural Networks, Long Short-Term Memory

## İÇİNDEKİLER

|                                                     |          |
|-----------------------------------------------------|----------|
| KABUL VE ONAY SAYFASI.....                          | i        |
| YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI.....     | ii       |
| ETİK BEYAN.....                                     | iii      |
| TEŞEKKÜR.....                                       | iv       |
| ÖZET.....                                           | v        |
| ABSTRACT.....                                       | vi       |
| İÇİNDEKİLER.....                                    | vii      |
| SİMGELER VE KISALTMALAR .....                       | ix       |
| TABLolar .....                                      | ix       |
| ŞEKİLLER VE GRAFİKLER.....                          | x        |
| <br>                                                |          |
| <b>1. GİRİŞ.....</b>                                | <b>1</b> |
| <b>2. LİTERATÜR ANALİZİ .....</b>                   | <b>3</b> |
| <b>3. PROBLEMİN TANIMI .....</b>                    | <b>5</b> |
| 3.1. Elektrik Tüketimi.....                         | 6        |
| 3.1.1. Elektrik Tüketimini Etkileyen Faktörler..... | 6        |
| 3.2 Yapay Zeka .....                                | 7        |
| 3.2.1. Makine Öğrenmesi .....                       | 9        |
| 3.2.1.1. Denetimsiz Öğrenme .....                   | 10       |
| 3.2.1.2. Denetimli Öğrenme .....                    | 10       |
| 3.2.1.2.1. Yapay Sinir Ağları .....                 | 11       |
| 3.2.1.2.2. Derin Öğrenme .....                      | 11       |
| a. Recurrent Neural Network (RNN) .....             | 12       |
| b. Long Short-Term Memory (LSTM) .....              | 14       |
| c. Multi Layer Perceptron (MLP) .....               | 16       |
| d. Gated Recurrent Units (GRU) .....                | 17       |
| e. Transformer Neural Network (TNN) .....           | 19       |
| 3.3 Performans Ölçütleri .....                      | 20       |
| 3.3.1 Root Mean Square Error (RMSE).....            | 20       |
| 3.3.2 Residuals Sum of Square (RSS).....            | 21       |
| 3.3.2 Belirleme katsayısı (R2).....                 | 21       |
| 3.4. Hiperparametreler .....                        | 22       |

|                                                                  |    |
|------------------------------------------------------------------|----|
| 3.4.1. Veri Setinin Boyutu .....                                 | 22 |
| 3.4.2. Learning Rate (Öğrenme Oranı) .....                       | 22 |
| 3.4.3. Epoch (Eğitim Tur Sayısı) .....                           | 23 |
| 3.4.4. Dropout (Unutma Oranı) .....                              | 23 |
| 3.5 Zaman Serilerinde Durağanlık Analizi .....                   | 23 |
| 3.6 Veri Seti .....                                              | 23 |
| <b>4. YÖNTEM</b> .....                                           | 25 |
| 4.1. LSTM Yöntemi.....                                           | 25 |
| 4.2. MLP Yöntemi.....                                            | 26 |
| 4.3. RNN Yöntemi .....                                           | 28 |
| 4.4. GRU Yöntemi .....                                           | 29 |
| 4.5. TNN Yöntemi .....                                           | 31 |
| <b>5. SONUÇLAR</b> .....                                         | 33 |
| 5.1. RNN ile Elde Edilen Sonuçlar.....                           | 33 |
| 5.2. MLP ile Elde Edilen Sonuçlar.....                           | 34 |
| 5.3. GRU ile Elde Edilen Sonuçlar.....                           | 35 |
| 5.4. LSTM ile Elde Edilen Sonuçlar.....                          | 36 |
| 5.5. TNN ile Elde Edilen Sonuçlar.....                           | 37 |
| 5.6. Sonuçlar.....                                               | 38 |
| 5.7. Öneriler.....                                               | 39 |
| <b>6.KAYNAKLAR</b> .....                                         | 40 |
| <b>7. EKLER</b>                                                  |    |
| <b>EK-1:</b> Tez Çalışması Hava Durumu Verileri İzin Yazısı      |    |
| <b>EK-2:</b> Tez Çalışması Elektrik Tüketim Verileri İzin Yazısı |    |
| <b>EK-3:</b> Özgeçmiş                                            |    |

## SİMGELER ve KISALTMALAR

|                         |                                 |
|-------------------------|---------------------------------|
| <b>LSTM</b>             | Long Short-Term Memory          |
| <b>MLP</b>              | Multilayer Perceptrons          |
| <b>RNN</b>              | Recurrent Neural Networks       |
| <b>GRU</b>              | Gated Recurrent Units           |
| <b>TSS</b>              | Transformer Deep Learning Model |
| <b>RMSE</b>             | Root Mean Square Error          |
| <b>RSS</b>              | Residuals Sum Of Square         |
| <b><math>R^2</math></b> | Belirleme Katsayısı             |

## TABLolar

| Tablo |                                                     | Sayfa |
|-------|-----------------------------------------------------|-------|
| 4.1   | LSTM Modeli nöron sayısı analiz tablosu             | 25    |
| 4.2   | LSTM modeli unutm oranı analiz tablosu              | 25    |
| 4.3   | LSTM modeli öğrenme oranı analiz tablosu            | 26    |
| 4.4   | MLP Modeli nöron sayısı analiz tablosu              | 26    |
| 4.5   | MLP modeli unutm oranı analiz tablosu               | 27    |
| 4.6   | MLP modeli öğrenme oranı analiz tablosu             | 27    |
| 4.7   | RNN Modeli nöron sayısı analiz tablosu              | 28    |
| 4.8   | RNN modeli unutm oranı analiz tablosu               | 28    |
| 4.9   | RNN modeli öğrenme oranı analiz tablosu             | 28    |
| 4.10  | GRU Modeli nöron sayısı analiz tablosu              | 29    |
| 4.11  | GRU modeli unutm oranı analiz tablosu               | 30    |
| 4.12  | GRU modeli öğrenme oranı analiz tablosu             | 30    |
| 4.13  | TNN Modeli nöron sayısı analiz tablosu              | 31    |
| 4.14  | TNN modeli unutm oranı analiz tablosu               | 31    |
| 4.15  | TNN modeli öğrenme oranı analiz tablosu             | 31    |
| 5.1   | RNN modelindeki en başarılı sonuca ilişkin veriler  | 32    |
| 5.2   | MLP modelindeki en başarılı sonuca ilişkin veriler  | 32    |
| 5.3   | GRU modelindeki en başarılı sonuca ilişkin veriler  | 34    |
| 5.4   | LSTM modelindeki en başarılı sonuca ilişkin veriler | 35    |
| 5.5   | TNN modelindeki en başarılı sonuca ilişkin veriler  | 36    |

**ŞEKİLLER VE GRAFİKLER**

| <b>Şekil</b> |                                                        | <b>Sayfa</b> |
|--------------|--------------------------------------------------------|--------------|
| 3.1          | Makine öğrenmesi türleri ve genel şeması               | 9            |
| 3.2          | RNN modeli temel yapısı                                | 13           |
| 3.3          | RNN modeli işleyiş biçimi                              | 13           |
| 3.4          | LSTM Modeli İşleyiş Biçimi                             | 14           |
| 3.5          | MLP modeli mimarisi                                    | 16           |
| 3.6          | GRU modeli Mimarisi                                    | 18           |
| 3.7          | TNN modeli Mimarisi                                    | 19           |
| 3.8          | 2023 yılına ait 8760 saatlik elektrik tüketim verileri | 24           |
| 3.9          | 2023 yılına ait 8760 saatlik hava durumu verileri      | 24           |
| 5.1          | RNN modeli analiz grafiği                              | 32           |
| 5.2          | MLP modeli analiz grafiği                              | 33           |
| 5.3          | GRU modeli analiz grafiği                              | 34           |
| 5.4          | LSTM modeli analiz grafiği                             | 35           |
| 5.5          | TNN modeli analiz grafiği                              | 36           |

## 1. GİRİŞ

Enerji sistemlerinin karşı karşıya olduğu en önemli sorunlardan biri olan enerji tüketim tahminlerinin doğruluğunu ve verimliliğini arttırmayı amaçlamaktadır. Elektrik dağıtım şebekelerinin etkin yönetimi, sürdürülebilir enerji kaynaklarının entegrasyonu, talep yönetimi ve enerji verimliliği gibi konularda derin öğrenme tekniklerinin kullanılması, bu alandaki yenilikçi çalışmaların önünü açmaktadır (Güler, 2024).

Tezin amacı, derin öğrenme modellerinin ve algoritmalarının elektrik tüketim tahminleri üzerinde nasıl etkili kullanılabileceğini araştırmak ve analiz etmektir. Bu, hem kısa dönemi hem de uzun dönemi tüketim tahminlerinde doğruluk oranını artırarak, enerji üretim ve dağıtım planlamasında önemli iyileştirmeler sağlayabilir. Elektrik tüketim tahminlerindeki doğruluk, enerji üretim maliyetlerinin optimize edilmesi, yenilenebilir enerji kaynaklarının daha etkin kullanımı ve enerji kaybının en aza indirilmesi açısından kritik bir öneme sahiptir (Arslan, 2020).

Bu tez aynı zamanda, elektrik tüketimindeki mevsimsel değişiklikler, hava durumu etkilerini dikkate alarak derin öğrenme modellerinin nasıl eğitilebileceği ve geliştirilebileceği konusunda detaylı bilgiler sunacaktır. Ayrıca, bu tekniklerin elektrik dağıtım şebekelerinin yönetiminde nasıl bir katkı sağlayabileceği ve enerji talep tahminlerinin daha doğru bir şekilde yapılabilmesi için önerilerde bulunacaktır (Güler, 2024).

Tezin önemi, enerji sektöründeki mevcut zorlukların üstesinden gelmek ve enerji sistemlerinin daha verimli, ekonomik ve çevre dostu hale getirilmesi yolunda önemli bir adım atılmasını sağlamaktır. Ayrıca, derin öğrenme ve yapay zeka teknolojilerinin potansiyelini ortaya koyması açısından da büyüktür. Elektrik dağıtım şebekelerinde tüketim tahminlerinin doğruluğunu artırarak, enerji kaynaklarının daha etkin kullanılmasına ve enerji sistemlerinin sürdürülebilirliğine katkıda bulunması beklenmektedir (Berus ve Yakut, 2024).

Bu çalışma ile tüketim performanslarının tahmin edilmesi üzerine yoğunlaşılmıştır. Enerji tüketiminin tahminlenmesi enerji kaynağını verimli bir şekilde

kullanmak ve enerji yönetim stratejilerini iyileştirmek için oldukça önemlidir. Bu bağlamda günümüzde de gittikçe yaygınlaşmakta olan derin öğrenme tekniklerinin uygulanması enerji tüketiminin daha doğru ve etkin bir şekilde tahminlenmesine olanak sağlamaktadır. Gerçekleştirilen bu çalışmada elektrik tüketim tahmininde kullanılan beş popüler derin öğrenme modeli olan Long Short Term Memory (LSTM), Multi Layer Perceptron (MLP), Recurrent Neural Network (RNN), Gated Recurrent Units (GRU) ve Transformer Neural Network (TNN) modelleri incelenerek bu modellerin tahmin başarısı karşılaştırmalı olarak değerlendirilmektedir.



## 2. LİTERATÜR ANALİZİ

Örnek ve Tuğcu (2022), çalışmalarında akıllı şebekelerde derin öğrenme tekniklerinin kullanımına dair mevcut çalışmaların kapsamlı bir incelemesini yapmıştır. İnceleme, yük tahmini, mikro şebeke yönetimi, talep yönetimi, hata tespiti, durum tahmini, güç sistemi analizi, siber güvenlik ve yenilenebilir enerji üretimi gibi alanlara odaklanmıştır. Araştırma, derin öğrenme uygulamalarının akıllı şebeke sistemlerindeki öneminin artacağını ve bu sistemlerin güvenilirlik, güvenlik ve dayanıklılığını iyileştirmede önemli rol oynayacağını vurgulamıştır. Akıllı şebeke problemlerinde AI ve DL tabanlı yaklaşımların kullanımının şebeke güvenilirliği ve dayanıklılığındaki birtakım iyileştirmeler gibi pek çok alanda avantajlar sağladığı görülmüştür.

Kamber ve Arkadaşları (2021), çalışmalarında yapay sinir ağları (YSA) ve uzun kısa dönemli bellek (LSTM) mimarisi kullanılarak kısa süreli elektrik talep tahmini yapmışlardır. İspanya'nın 2015-2016 yılları arasındaki elektrik verileri üzerinden gerçekleştirilen tahminleme çalışmasında, YSA ve ARIMA modellerinin tahmin başarılarını karşılaştırmışlardır. Çalışmada, elektrik üretim ve tüketim verileri ENTSOE portalından toplanmış, saatlik veriler LSTM mimarisi temelinde analiz edilmiştir. Elde edilen sonuçlar, LSTM ve ARIMA modellerinin benzer performans gösterdiğini, ancak YSA modelinin daha yüksek hesaplama gücü gerektirdiğini ve daha fazla eğitim verisine ihtiyaç duyduğunu ortaya koymuştur.

Arifoğlu ve Kandemir (2022), Gün Öncesi Piyasasında saatlik Piyasa Takas Fiyatlarının derin öğrenme teknikleri kullanılarak tahmin edilmesine odaklanmışlardır. MLP, CNN, LSTM ve GRU modelleri aracılığıyla 24 saatlik fiyat tahminleri gerçekleştirilmiştir. Sonuçlar incelendiğinde, LSTM modeli %8,15 MAPE değeriyle en yüksek ortalama tahmin performansını göstermiş, sırasıyla MLP (%8,44 MAPE), GRU (%8,72 MAPE) ve CNN (%9,27 MAPE) modelleri takip etmiştir. Bu bulgular, saatlik Piyasa Takas Fiyatının tahmininde LSTM modelinin diğer kullanılan modellere kıyasla daha üstün performans sergilediğini göstermektedir.

Utku (2020), çeşitli alanlarda gelecekteki olayların zamanlarının ve türlerinin tahmin edilmesine yönelik uzun süredir devam eden araştırmalara bir yenilik getirmiştir. Geliştirilen hibrit derin öğrenme modeli HDLM, mevcut RF, SVM, ARIMA, MLP, CNN,

GRU, LSTM ve CNN ile GRU'nun birleştirildiği CNN+GRU hibrit modeliyle karşılaştırılarak test edilmiştir. HDLM, e-ticaret, DDoS saldırıları, su ve acil çağrı veri kümeleri gibi farklı alanlarda uygulanmış ve deneysel sonuçlar, bu modelin gelecekteki olayların zamanını tahmin etmede diğer modellere göre üstün olduğunu ortaya koymuştur. Bu bulgular, olayların önceden tahmin edilmesi konusunda önemli bir ilerleme olarak değerlendirilebilir.

Kavas (2019), çalışmasında küresel bir sorun olan enerji arz ve talep dengesini ele almakta ve Türkiye'nin enerji tüketim tahminlerine odaklanmaktadır. Geliştirilen hibrit yapay sinir ağları modeli olan feed forward ve bi-directional long short-term memory (bi-LSTM) mimarileri kullanılarak doğalgaz ve elektrik enerjisi tüketiminin tahmin edilmesi amaçlanmıştır. Çalışmada, farklı optimizasyon yöntemleriyle eğitilen modeller arasında kapsamlı bir karşılaştırma yapılmış ve en iyi performans gösteren modelin bir LSTM mimarisi olduğu belirlenmiştir. Veri toplama sürecinde çeşitli kurumlardan elde edilen verilerle eğitilen modeller, gerçekleştirilen tahminlerin tutarlılık zaman aralıklarını belirlemek için kullanılmıştır. Sonuç olarak, modelin uzun vadeli tahmin performansının veri setinin uzunluğu ile arttığı gözlemlenmiştir.

### 3. PROBLEMİN TANIMI

Derin öğrenme günümüzde özellikle veri analizi, talep yönetimi, gerçek zamanlı tahmin ve sürdürülebilirlik gibi alanlarda üzerinde önemle durulan kavramlar arasında yer almaktadır (Choi vd., 2020: s.1; Douaioui vd., 2024: s.1). Günümüzde dünya nüfusunun giderek artması ve enerji tüketiminin yüksek seviyelere çıkması enerji alanında gerçek tahminlerde bulunmayı ve sürdürülebilirlik faaliyetlerinin geliştirilmesini önemli bir konu haline getirmektedir. Bu noktada derin öğrenmenin elektrik dağıtım şebekelerinde tüketim tahminlerinde kullanılması önem arz etmektedir. Derin öğrenme ile elektrik dağıtım şebekelerinde tüketim tahminlerinde bulunulması öncelikli olarak veri analizi açısından üzerinden sıklıkla durulan bir konudur. Elektrik tüketimini etkileyen birçok unsur bulunmaktadır. Söz konusu unsurların başında tatil günleri, içinde bulunulan saat ve hava durumu gelmektedir. Derin öğrenme sayesinde büyük veri setlerinin analiz edilmesi ve elektrik tüketimini etkileyen değişkenler arasındaki ilişkilerin ortaya konulması mümkün hale gelmektedir (Ahmad vd., 2022: 1; Forootan vd., 2022: s.1; Gallegos vd., 2024: s.1).

Elektrik tüketiminde doğru tahmin unsuru enerji tasarrufunun sağlanmasında büyük bir etkiye sahiptir. geleneksel tahmin yöntemlerine kıyasla derin öğrenmenin elektrik tüketiminde daha doğru tahminler ortaya koyması mümkündür. Bu durum enerji şirketlerinin doğru tahminler yapmasına ve kaynaklarını daha verimli kullanmasına katkı sağlamaktadır. Yapılan çalışmalar elektrik tasarrufu sağlanmasında da derin öğrenme tahminlerinin etkili sonuçlar ortaya koyduğunu göstermektedir (Abediniangerabi vd., 2021: s.1; Qureshi vd., 2024: s.1). Elektrik dağıtım ve tüketim süreçlerinde doğru tahminlerde bulunulması enerji tasarrufunun yanında sürdürülebilirlik faaliyetlerinin de geliştirilmesinde önemli bir konudur. Son yıllarda elektrik üretim, dağıtım ve tüketim faaliyetlerinde sürdürülebilirlik üzerine yapılan çalışmaların arttığı görülmektedir (Pappas vd., 2012: s. 626; Kabeyi ve Olanrewaju, 2020: s. 530). Derin öğrenme sayesinde yapılan doğru tahminler yenilenebilir enerji kaynaklarının birbiri ile entegrasyonunu daha kolay hale getirmektedir. Bu durum hem sürdürülebilirlik faaliyetlerinin geliştirilmesine hem de elektrik üretim maliyetlerini düşürmektedir. Elektrik dağıtım şebekelerinin verimliliğinin artırılması da derin öğrenme sayesinde mümkün hale gelmektedir (Oladapo vd., 2024: s.1; Aderibigbe vd., 2023: s. 341). Söz konusu faydaları nedeniyle derin öğrenmenin elektrik dağıtım şebekelerinde tüketim tahminlerinde kullanılması

önemli bir konu olarak karşımıza çıkmaktadır. Buna karşılık literatür taraması sonunda bu konuda ülkemizde yapılan çalışmaların sınırlı olduğu görülmüştür. Bu noktada “Elektrik dağıtım şebekelerinde tüketim tahminlerinde derin öğrenmenin etkileri nelerdir?” sorusunun yanıtlanması gerekliliği ortaya çıkmıştır.

### **3.1. Elektrik Tüketimi**

Enerji tüketimi ülkelerin başta endüstri olmak üzere ekonomik kalkınmasında önemli bir yere sahiptir. literatürde yer alan çalışmalarda da enerji tüketiminin ekonomik kalkınmada önemli bir girdi olduğuna vurgu yapılmaktadır (Mucuk ve Uysal, 2009: s.105). Türkiye açısından ele alındığı zaman elektrik üretim ve tüketim düzeyi ile ekonomik büyüme arasında anlamlı ilişki olduğu görülmektedir. Elektrik tüketiminin özellikle sanayi alanında tüketim düzeyi yükseldikçe sanayi üretiminin de arttığı, bu durumun ekonomik büyümeye katkı sağladığı belirtilmektedir (Şahin, 2025: s.7; Ağır ve Kar, 2010: s.149). Elektrik tüketiminin yüksek olması günlük hayatı da kolay hale getirmektedir. Ancak günümüzde elektrik tüketiminin giderek artması elektrik üretimini de önemli bir konu haline getirmiştir. Günümüzde elektrik tüketimine cevap verebilmek için ülkelerin elektrik arzını arttırmaya ve çeşitlendirmeye yönelik çalışmalar yürüttüğü görülmektedir (Ertuğrul, 2011: s.49).

#### **3.1.1. Elektrik Tüketimini Etkileyen Faktörler**

Elektrik tüketimini arttıran unsurların başında nüfus artışı gelmektedir. Nüfusun artması konut ve işyeri sayısını arttıracığı için bölgenin elektrik tüketim gereksinimini de arttırmaktadır (Hlongwane ve Daw, 2023: s.374). Nüfusun yaşadığı bölgenin sanayileşmiş bir yer olması da elektrik tüketimini arttıran diğer bir unsurdur. Mevcut sanayi bölgelerinde yer alan üretim tesis sayısının artması da elektrik tüketiminin artmasına zemin hazırlamaktadır. Sanayi bölgelerinde elektrik tüketimi üretim alanları ve işletmelerin enerji gereksinimine göre farklılık göstermektedir. Özellikle enerji yoğun çalışan işletmelerin fazla olması elektrik tüketimini arttırmaktadır (Sahoo ve Sethi, 2020: s.1; Hadi vd., 2021: s.403).

Hava durumu elektrik tüketimini etkileyen diğer bir faktördür. Sıcak havalarda klima ile ortamın soğutulması kadar kış günlerinde de ortam ısının arttırılması elektrik tüketimini arttırmaktadır. Hava durumunun yanında insanların yaşam tarzları da elektrik

tüketimini arttırabilmektedir. Hava durumundan ayrı olarak kişinin yaşam tarzı nedeniyle evde uzun ya da kısa süre durması ev içinde tüketilen elektrik miktarı üzerinde belirleyicidir (Zhang vd., 2019: s.1259; Mideksa ve Kallbekken, 2010: s.3579). Enerji verimliliğini arttırmaya yönelik önlemlere ağırlık verilmemesi de elektrik tüketimini arttırmaktadır. Özellikle eski ve verimsiz teknolojik cihazların kullanılması, günlük hayatta enerji tasarrufu sağlayan yeni teknolojilerden yararlanılmaması elektrik tüketiminin yükselmesine neden olmaktadır (Olatunde vd., 2024: s.1). Fiyatlandırma ve tarife uygulamaları da elektrik tüketimini etkilemektedir. Elektrik fiyatlarının düşük olması genellikle elektrik tüketimini arttıran unsurlar arasında yer almaktadır. Ancak elektrik tüketim maliyetlerinin artması insanların günlük yaşamda gereksiz elektrik tüketimlerini azaltmaktadır (Stamminger ve Anstett, 2013: s.353; Ansarin vd., 2020: s.1).

### 3.2. Yapay Zekâ

Kavramsal açıdan ele alındığı zaman yapay zekâ “modern toplum yaşamında karmaşık hale gelen sorunlara doğru ve verimli çözüm üretebilme yetisi” olarak tanımlanmaktadır. Diğer bir tanıma göre yapay zekâ “mevcut bir sorunu bilinir, fakat çözümün yöntemi (algoritması) bilinmezken, doğru ve verimli bir çözüm yöntemini çıkarımsayan, öğrenen, ya da keşfeden, insan eliyle üretilmiş sistemlerin tümü” şeklinde ifade edilmektedir (Köroğlu, 2017: s.2). Yapay zekâ çalışmalarının temelinde insan zihnini bütünüyle yapay bir sisteme entegre etme düşüncesi yer almaktadır. Tarihin farklı dönemlerinde yapay zekaya ilişkin unsurlar farklı biçimlerde kendisini göstermiş olmakla beraber, günümüzde yapay zekâ uygulamalarının özellikle insan hayal gücü ile hareket edebilen makineler geliştirme üzerine yoğunlaştığı görülmektedir. Burada ifade edilen zekâ kavramı insanların yaptığı analiz, akıl yürütme ya da hesap yapabilme gibi işlemlerin daha ötesinde bir anlama sahiptir. Bu kapsamda yapay zekâ uygulamalarının ve yapay zekâ geliştirme çalışmalarının sadece akıl yürütme becerisi eklemekten ibaret olmadığı ifade edilmektedir (Doğan, 2021: s.790).

Günümüzde yapay zekanın hayatın birçok alanda etkin bir biçimde kullanılmaya başlandığı ve insan yaşamına olumlu katkıları olduğu görülmektedir. Yapay zekanın yaygın olarak kullanıldığı alanların başında sağlık hizmetleri gelmektedir. Sağlık hizmetlerinin sunumunda ve tedavi süreçlerinde yapay zekadan yaygın olarak faydalandığı görülmektedir. Yapay zekâ uygulamaları sayesinde teşhis ve tanı süreçlerinin yanında tedavi planlarının da daha sağlıklı yapılmaya başlandığı göze

çarpmaktadır. Bu noktada yapay zekâ hem sağlığı koruma hem de hastalıklardan korunma ve sağlığı geliştirmede önemli bir unsur olarak nitelendirilmektedir (Aung vd., 2021: s.4; Dave ve Patel, 2023: s.761; Albu ve Stanciu, 2015: s.19).

Yapay zekâ uygulamaları ekonomik faaliyetlerin daha sağlıklı yürütülmesi, yatırım danışmanlığı, kredi riskinin değerlendirilmesi, dolandırıcılık faaliyetlerinin tespit edilmesi ve piyasa analizinde de sıklıkla kullanılmaktadır (Giudici, 2018: s.1; Ashta ve Herrmann, 2021: s.211). Yapay zekâ uygulamaları sayesinde otomasyon sistemlerinin hızlı gelişim göstermesi zaman alan ve tekrarlayan iş süreçlerinin daha pratik hale getirilmesine katkı sağlamaktadır. Bu durum işletmelerin daha stratejik konulara odaklanmalarına ve zaman ayırmalarına destek olmaktadır (Jarrett ve Choo, 2021: s.1). İşletmeler açısından büyük verilerin hızlı ve güvenilir bir şekilde analiz edilmesi rekabet avantajı sağlama noktasında büyük bir öneme sahiptir. Bu noktada yapay zekâ sayesinde hem büyük verilerin kolayca analiz edildiği hem de işletmelerin faaliyet gösterdikleri alanlarda kendilerine rekabet avantajı sağladıkları gözlenmektedir (Krishna vd., 2023: s.1). Yapay zekanın gelişmesi ile birlikte akıllı makinelerin de ortaya çıkması üretim süreçlerini olumlu yönde etkilemiştir. Akıllı sistemler trafikte sürücüsüz araçların gelişmesine ve ulaşım sistemlerinin daha güvenli hale gelmesine katkı sağlamıştır (Bharadiya, 2023: s.35; Nikitas vd., 2020: s.1).

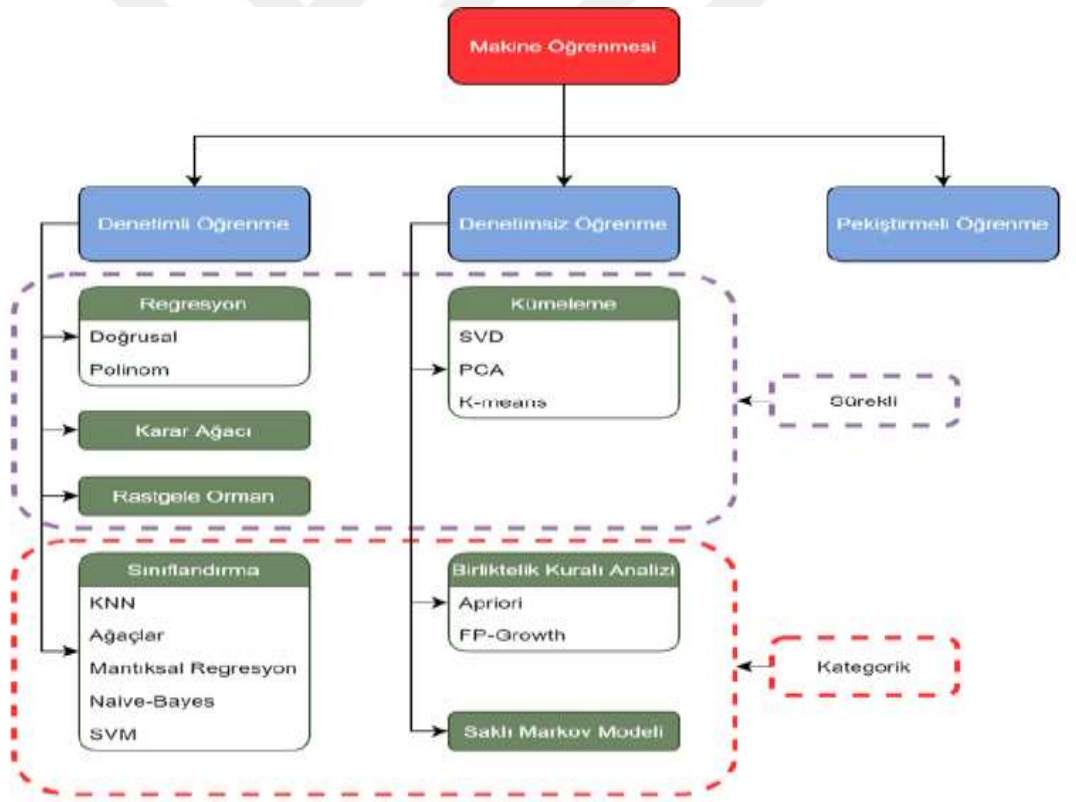
Yukarıda yer alan bilgilerin yanında yapay zekâ sayesinde insanların eğitim hayatında birçok kolaylık ile karşılaştıkları görülmektedir. Literatürde yer alan çalışmalarda yapay zekanın özellikle kişiselleştirilmiş öğrenmeye katkı sağladığı belirtilmektedir. Bu kapsamda her yaş grubundan bireyin kendi öğrenme stiline uygun bir öğretim modeli ile eğitim alması mümkün hale gelmiştir. Öğretmenler ya da merkezi sınavlar düzenleyen kurumlar açısından ele alındığı zaman yapay zekanın sınav ve ödev değerlendirmelerinin daha pratik hale gelmesine destek olduğu görülmektedir (Chen vd., 2020: s.1; Vinkoczi vd., 2023: s.487).

Günlük yaşamı kolaylaştıran, sağlığın korunmasına ve geliştirilmesine katkı sağlayan, bunun yanında eğitim süreçlerini olumlu yönde etkileyen yapay zekanın istihdama katılım süreçlerinde de birtakım kolaylıkları beraberinde getirdiği ifade edilmektedir. Özellikle bir iş koluna yapılan başvuruların değerlendirilmesi ve işe alım süreçlerinin daha hızlı olmasında yapay zekanın önemli bir kolaylık sağladığı görülmektedir. Bunun yanında çalışan memnuniyetinin ölçülmesi ve çalışan

verimliliğinin artırılmasında da yapay zekanın olumlu etkileri olduğu belirtilmektedir (Joshi ve Masih, 2023: s.300; Fraij ve Laszlo, 2021: s.108). Literatürde yer alan bu bilgiler ışığında yapay zekanın iş yaşamından eğitime, sağlıktan günlük hayata birçok faydası olduğu söylenebilir.

### 3.2.1. Makine Öğrenmesi

Kavramsal açıdan ele alındığı zaman makine öğrenmesi “karşılaşılan problemin bu probleme ait ortamdan alınan bilgiler (veriler) doğrultusunda modelleme yapan bilgisayar algoritmalarına verilen ad” olarak ifade edilmektedir. Makine öğrenmesine yönelik ilk yaklaşımların 1950’li yıllarda “Makineler düşünebilir mi?” sorunsalının ortaya atılması ile başladığı görülmektedir. Makine öğrenmesinde üç ana tür ve alt başlıkları bulunmaktadır. Söz konusu türler ve alt başlıklar Şekil 3.1’de sunulmuştur (Kıymaz, 2020: s.7).



Şekil 3.1 Makine öğrenmesi türleri ve genel şeması

Makine öğrenmesi temel olarak yapay zekâ alanının bir bileşeni olmakla beraber, bilgisayarların veriden öğrenme yeteneklerine dayanmaktadır. Günümüzde makine öğrenmesi bilgi çağının temel unsurları arasında yer almaktadır. Bu teknolojinin iş

süreçlerini optimize etmekten kişiselleştirilmiş kullanıcı deneyimlerine kadar oldukça geniş bir alanda kullanıldığı görülmektedir. Makine öğrenmesi teknik ve etik açıdan sürekli adaptasyon ve gelişim gösteren dinamik bir alan olarak varlığını devam ettirmektedir (Ghahramani, 2015: s.452). Manine öğrenmesi denetimsiz ve denetimli öğrenme olmak üzere ikiye ayrılmakta olup, söz konusu öğrenme türleri aşağıda başlıklar halinde açıklanmıştır.

### **3.2.1.1. Denetimsiz Öğrenme**

Denetimsiz öğrenmede algoritmalara girilen verilerin dış bir müdahale ya da yönlendirme olmadan işlendiği görülmektedir. Bu öğrenme modelinde verilerin sahip olduğu yapısal özellikler ile desenler ve veriler arasındaki ilişkiler otomatik olarak keşfedilmeye çalışılmaktadır. Denetimsiz öğrenme, veri sınıflandırması, veri keşfi ve örüntü tanıma gibi özelliklere sahip olmakla beraber, yapay zekâ ve veri bilimi alanlarında önemli bir yere sahiptir. Denetimsiz öğrenmenin temel amacı etiketlenmemiş veri kümelerinde yer alan desenlerin ve gizli yapıların bulunmasıdır. Bu süreç temel olarak verilerin içinde yer alan düzensizlikleri ve ilişkileri keşfetme esasına göre yürütülmektedir (Naeem vd., 2023: s.1). Örneğin; bilgisayar kullanıcılarının gezindikleri sitelerde kullanmış oldukları yaratıcıların kullanıcıya ilgi duyacağı web sitelerini önermesi denetimsiz öğrenme sayesinde mümkün olmaktadır (Kıymaz, 2020: s.8).

### **3.2.1.2. Denetimli Öğrenme**

Denetimli öğrenmede etiketlenmiş veriler ile hedeflenen çıkış verileri arasında eşleştirmeler yapan bir fonksiyon oluşturulmaktadır (Kıymaz, 2020: s.8). Denetimli öğrenme modelin öğrenme süreci, modeli eğitmek için kullanılan ve her biri için doğru çıktıya sahip olan etiketlenmiş veri setleri tarafından yönlendirilen bir yapıya sahiptir. Model temel olarak girdi verileri ile etiketler arasındaki ilişkileri öğrenmek amacıyla eğitilmektedir. Bu öğrenme modelinde görülmemiş veriler üzerinde doğru tahminlerin yapılması söz konusudur. Sistemin uyum sağlayabilmesi için verilerin bir kısmı ile eğitim yapılması gerekmektedir. Eğitim verileri girdi ve çıktılarından meydana gelmektedir. Bu fonksiyonu belirleyen ise regresyon ya da sınıflandırma algoritmalarıdır (Kıymaz, 2020: s.8).

### 3.2.1.2.1. Yapay Sinir Ağları

Yapay sinir ağları son yıllarda araştırmacılar tarafından sıklıkla araştırılan konular arasında yer almakta beraber, temelde bilgisayarların öğrenmesine yönelik çalışmaları içermektedir. Kavramsal açıdan ele alındığı zaman yapay sinir ağları “matematik bilimi tarafından formüle edilmesi oldukça zor problemlerin bilgisayarlar tarafından sezgisel metotlar ile çözümlenmesini” ifade etmektedir (Kıymaz, 2020: 10). Yapay sinir ağları birbirine bağlı olan çok sayıda işlem biriminden meydana gelmekle beraber, karmaşık desenleri tanıma, tahminde bulunma, veri sınıflama ve karar verme gibi görevleri yerine getirmede kullanılmaktadır. Yapay sinir ağları özellikle derin öğrenme ile makine öğrenmesinde sıklıkla kullanılan, dijital teknolojilerde de farklı uygulamaların içinde yer alan bir yapı olarak nitelendirilmektedir (Schmidhuber, 2015: 85; Kufel vd., 2023: s.1).

Yapı olarak yapay sinir ağlarının insan beyninin sinir hücrelerine (nöronlar) benzediği görülmektedir. İnsan beyninde her bir nöron girdi sinyallerini almakta, bu sinyaller üzerinden işlem yapmakta ve çıktı üretmektedir. Bu sistem içerisinde yer alan nöronlar birbiri ile ağırlıklar vasıtasıyla bağlantılıdır ve ağırlıkların öğrenme süreci devam ettikçe güncellendiği görülmektedir. Yapay sinir ağlarında öğrenmenin devam etmesi teşhis, sınıflandırma, verileri ilişkilendirme, tahminde bulunma, veri yorumlama ve veri filtreleme gibi alanlarda doğru sonuçlar ortaya konulmasına katkı sağlamaktadır. Bunun yanında hangi problemin hangi problem çözme yöntemleri ile yapılacağına karar verme sürecinde de yapay sinir ağlarından yararlanılmaktadır (Dayhoff ve DeLeno, 2001: s.1605).

### 3.2.1.2.2. Derin Öğrenme


Derin öğrenme yapı olarak makine öğrenmesinden farklı bir sisteme sahiptir. kavramsal açıdan ele alındığı zaman derin öğrenme “öznitelik (ya da özellik) çıkarımı işlemini (girdi olarak verilen ölçülmüş değerler üzerinden yeni türetilmiş değerler oluşturma) herhangi bir destek bulunmaksızın kendisine ait sinir ağı içerisinde gerçekleştirebilmesi” olarak tanımlanmaktadır (Kıymaz, 2020: s.9). Derin öğrenme temel olarak insan beynindeki bilgi işleme biçimini modelleyen yapay sinir ağlarından ilham almaktadır. Yapay sinir ağları birbiri ile bağlantılı yapay nöronlardan meydana gelmekle beraber, verilerin sahip oldukları özelliklerden yola çıkarak karmaşık işlevleri yerine getirmektedir. Derin öğrenme kavramı içerisinde yer alan “derinlik” terimi ağ içerisindeki

katman sayısının fazlalığına atıfta bulunmaktadır. Çok sayıda gizli katman içeriğine sahip olan yapay sinir ağları verileri daha derinlemesine işlemekte ve basit işlemlerden oldukça karmaşık durumlara kadar farklı soyutlamalar yapabilmektedir (Georgevici ve Terblanche, 2019: s.712).

#### **a. Recurrent Neural Network (RNN)**

Bu sinir ağları tahmin dizileri etrafından kullanılmak için oluşturulmaktadır (Kıymaz, 2020: s.13). Bilindiği gibi insanların sahip oldukları düşüncelerin temelini geçmiş dönemlerde edindikleri bilgiler oluşturmaktadır. Geleneksel sinir ağları ile böyle bir işlem yapılması imkansızdır. Bu durum aynı zamanda geleneksel sinir ağlarının önemli bir eksikliği olarak nitelendirilmektedir. RNN ise temel olarak bu tür sorunları ele alan bir yapıya sahiptir. Tekrarlayan sinir ağlarının temel mantığı sinir ağlarındaki sıralı bilgilerin kullanılmasıdır. Geleneksel sinir ağlarının her birinde tüm girdi ve çıktılar birbirinden bağımsız olduğu kabul edilmektedir. RNN mimarisinin literatürde tekrarlayan sinir ağları olarak nitelendirilmesinin temelinde bir dizinin her bir ögesi için benzer görevin önceki çıktılara bağlı olarak yerine getirilmesidir (Hermans ve Schrauwen, 2013: s.1; Santoro vd., 2018: s.1).

RNN mimarisinde çalışma sistemi incelendiği zaman, bir giriş katmanı ile iki gizli katmanın ve bir çıkış katmanının olduğu görülmektedir. Söz konusu katmanların tamamı birbirinden bağımsız olarak çalışmaktadır. Bu noktada her bir katmanın kendine özgü bir fonksiyonunun olduğu, her katmandaki yapıların bir ağırlığının bulunduğu ve her bir katmanın farklı bir fonksiyonu yerine getirdiği görülmektedir. Bu yapı sayesinde sistemin mümkün olduğu kadar daha olası sonuçlar ortaya koyması amaçlanmaktadır. Tekrarlanan söz konusu aşamalar sayesinde bir önceki giriş durumu depolanmakta ve yeni elde edilen giriş değerleri ile birleştirilmektedir. Bu sayede yeni elde edilen giriş ile önceki girişler arasında ilişki kurulmaktadır (Li vd., 2018: s.5457; Yao ve diğerleri, 2013: s.2524). Söz konusu özellikleri sayesinde tekrarlayan sinir ağlarının özellikle sıralı ve zamanla ilişkili verileri iyi analiz ettiği, konuşma tanıma ve dil işleme gibi konularda yüksek performans sergilediği görülmektedir. RNN, yalnızca mevcut girdilere değil, aynı zamanda geçmiş dönemlerdeki olayların birikimine de duyarlı bir yapıya sahiptir. Bu durum bağlamsal açıdan ilgili çıktılar üretilmesine katkı sağlamaktadır. Tekrarlayan sinir ağlarının genel yapısı Şekil 3.2’de sunulmuştur.




Şekil 3.2 RNN modeli temel yapısı

Tekrarlayan sinir ağlarında hesaplama eşitlik 3.1 ve 3.2'deki gibi gerçekleşmektedir. Eşitlik 3.1 olarak ifade edilen “ $h_t$ ” temel olarak gizli durumu, “ $W_x$ ” girdi ağırlıklarını, “ $W_h$ ” gizli durum ağırlıklarını, “ $x_t$ ” girdiyi,  $b$  ise ağırlık (bias) vektörünü ifade etmekle beraber, gizli durum güncellemesini gerçekleştirmektedir. Söz konusu yapı Şekil 3.3'te sunulmuştur.

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

$$y_t = W_y \cdot h_t + b_y \quad (3.2)$$


Çıktı hesaplama temel olarak eşitlik 3.2'de belirtildiği gibi gerçekleşmektedir. Burada “ $W_y$ ” çıktı ağırlıklarını, “ $y_t$ ” çıktıyı ve “ $b_y$ ” çıktı için ağırlık vektörünü ifade etmektedir.



Şekil 3.3 RNN modeli işleyiş biçimi

### b. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) yapay sinir ağı içinde kullanılan bir tür tekrarlayan sinir ağı (RNN) mimarisi olarak değerlendirilmekte ve RNN'lerin geliştirilmiş hali olup geri besleme mantığı ile çalışmaktadır. LSTM'ler, özellikle zaman serisi verileri ya da sıralı veriler ile çalışırken, uzun dönemli bağımlılıkları öğrenme yeterlikleri sayesinde ön plana çıkmaktadırlar. RNN'ler, geçmiş bilgileri hatırlama noktasında zorlanabilmektedir. Bu durum uzun dizilerde bilgi kaybına yol açmaktadır. LSTM'ler ise, "hücre durumu" olarak adlandırılan bir mekanizmadan yararlanarak edinilen bilgiyi uzun süre saklayabilmektedir. Böylece geçmişteki bilgileri unutmadan yeni bilgiler öğrenebilmektedir (Van Houdt vd., 2020: s.5929)



Şekil 3.4. LSTM Modeli İşleyiş Biçimi

LSTM'lerin temel bileşenleri arasında giriş kapısı ile unutma kapısı ve çıkış kapısı bulunmaktadır. Söz konusu kapılar, hangi edinilen bilgilerin hatırlanacağına, hangi bilgilerin unutulması gerektiğine ve hangi bilgilerin çıkışa aktarılacağına karar vermektedir. Bu yapı sayesinde LSTM'lerin dil işleme, ses tanıma ve diğer sıralı veri uygulamaları için oldukça etkili çalıştıkları görülmektedir (Collette vd., 2000: s.46; Oruh vd., 2022: s.1).

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

Eşitlik 3.3'te belirtilen  $ft$  unutma kapısı aktivasyon vektörünü,  $\sigma$  fonksiyonu sigmoid fonksiyonu,  $Wf$  unutma kapısı ağırlıklarını,  $ht-1$  bir önceki hücre çıktısını,  $xt$  mevcut girdi ve  $bf$  ise unutma fonksiyon kapısı bias vektörüdür.

Girdi katmanı, mevcut girdinin bellekte nasıl ve saklanıp saklanmayacağını kararlaştırır. Bu süreç, LSTM'nin hangi bilginin önemli olduğunu ve uzun vadeli bağlamlarda nasıl kullanılacağını öğrenmesine yardımcı olur.

$$\hat{I}t = \sigma(Wi.[ht-1, xt] + bi) \quad (3.4)$$

$$\tilde{C}t = \tanh(Wc.[ht-1, xt] + bc) \quad (3.5)$$

Modelin bir tür belleği gibi işlev gören, hücre içindeki bilgiyi taşıyan ve zamanla bu bilgiyi güncelleyerek ilerleyen hücre durumunun hesaplanması, eşitlik 3.6'da gösterilmiştir. Bu eşitlikte  $Ct$  güncellenmiş hücre durumunu,  $Ct-1$  ise önceki durumu temsil eder.

$$Ct = ft.Ct-1 + it.\tilde{C}t \quad (3.6)$$

Çıkış katmanı olarak adlandırılan son katman, hangi bilgilerin sonuç olarak üretileceğine karar verir. Bu durum, modelin hem mevcut duruma hem de daha önce öğrenilen bağlamlara bağlı olarak hangi bilgilerin önemli olduğunu belirlemesini sağlar ve aşağıdaki eşitlikle hesaplanır. Eşitlik 3.7 'de  $Ot$  çıkış katmanını,  $ht$  hücre çıktısını,  $Wo$  çıkış katmanının ağırlıklarını ve  $bo$  ise ağırlık (bias) vektörünü temsil eder.

$$Ot = \sigma(Wo.[ht-1, xt] + bo) \quad (3.7)$$

$$ht = ot.\tanh(ct) \quad (3.8)$$


LSTM modelinin bu katmanları bir araya gelerek, hem kısa vadeli hem de uzun vadeli bağımlılıkları etkili biçimde öğrenmesini ve işlemesini sağlar. Bu yapı, dil modelleme, metin üretimi, konuşma tanıma gibi birçok karmaşık görevde başarıyla kullanılmıştır. Zamanla değişen sıralı verileri modelleme açısından LSTM'yi son derece uygun kılan, bu özellikleridir. Çünkü model, geçmiş bilgileri koruma yeteneğinin yanı sıra, yeni bilgilerle de güncellenebilir. Böylece zaman içinde dinamik bir şekilde öğrenme ve uyum sağlama becerisi kazanır.

### c. Multi Layer Perceptron (MLP)

Multi Layer Perceptron (MLP), yapı olarak yapay sinir ağlarının farklı bir türü olmakla beraber, genellikle denetimli öğrenme sürecinde etkin rol oynamaktadırlar. Yapısı birden fazla katmandan meydana gelmekle beraber, sahip olduğu katmanlar giriş katmanı, en az bir tane gizli katman ve çıkış katmanı şeklinde sıralanmaktadır. Yapı içerisinde her katman önceki katmanlardan gelen verileri almakta, alınan veriler üzerinde matematiksel işlemler yaptıktan sonra yeni veriler üretmektedir (Popescu ve diğerleri, 2009: 579; Ramchoun ve diğerleri, 2016: 26; Noriega, 2005: 1). Çok katmanlı algılayıcılar Şekil 3.5'te sunulduğu gibi üç katmandan oluşmaktadır. Katmanlar arasında yer alan gizli katmanın matematiksel eşitliği eşitlik 3.9 'da açıklanmıştır. Burada belirtilen her gizli katman " $l$ " ile ifade edilmekle beraber, önceki katman çıktılarına " $W_l$ " ile ifade edilen ağırlıklar ve " $b_l$ " ile ifade edilen biaslar uygulayarak hesaplanmaktadır. Sonrasında bir " $f_l$ " aktivasyon fonksiyonu kullanılmaktadır. " $a_{l-1}$ " önceki katman çıktısı iken, " $z_l$ " bu katmandaki aktivasyon fonksiyonuna girmeden önceki değeri ifade etmektedir. Eşitlik 3.10'da yer alan " $a_l$ " ise aktivasyon sonrası çıktıyı vermektedir.

$$z_l = W_l \cdot a_{l-1} + b_l \quad (3.9)$$

$$a_l = f_l \cdot z_l \quad (3.10)$$



Şekil 3.5. MLP modeli mimarisi

MLP'nin temel katmanları aşağıda açıklanmıştır.


**Giriş katmanı:** Giriş katmanındaki her bir nöron bir girdi özelliğini temsil etmektedir. Bu katman modelin dışarıdan almış olduğu verilerin bulunduğu katmandır.

**Gizli katmanlar:** Bu katman temel olarak girişte yer alan verileri işleyen ve daha karmaşık özellikleri öğrenen bir katman olarak karşımıza çıkmaktadır. Bu bölümde bir ya da daha fazla katman bulunabilmektedir. Katmanda yer alan her bir nöron bir aktivasyon fonksiyonu kullanmakta ve çıktısını hesaplamaktadır.

**Çıkış katmanı:** Bu katman modelin sonuçları ile tahminlerinin üretildiği katmanı oluşturmaktadır. Çıkış katmanında yer alan nöron sayısı çözülmesi gereken probleme göre değişkenlik göstermektedir (Trenn, 2008: s.836; Panchal vd., 2011: s.332).

#### **d. Gated Recurrent Units (GRU)**

Gated Recurrent Units (GRU) temel olarak tekrarlayan sinir ağı mimarisi olmakla beraber, derin öğrenme alanında yaygın olarak kullanılmaktadır. GRU'lar genellikle sıralı veriler ve zaman serisi verileri ile çalışırken, uzun dönemli bağımlılıkların daha iyi öğrenilmesi için tasarlanmıştır. GRU'lar iki ana kapıdan meydana gelmektedir. Bunlar; güncelleme kapısı ile sıfırlama kapısıdır. Bu kapıların temel fonksiyonlarının başında hangi bilgilerin hatırlanması ve hangi bilgilerin unutulması gerektiğinin kontrolü gelmektedir. Bu sayede geçmiş dönemlerde anlamlandırılan bilgiler daha etkili bir şekilde kullanılabilir hale gelmektedir. GRU'lar bu özellikleri sayesinde özellikle makine çevirisi, dil modelleme ve ses tanıma gibi alanlarda etkili sonuçlar ortaya koyabilmektedir (Fu vd., 2020: s.788; Kanai vd., 2017: s.1; Irie vd., 2016: s.1). Kapı kontrollü tekrarlayan birimler mimarisi şekil 3.6'da açıklanmıştır.



Şekil 3.6: GRU modeli Mimarisi

GRU yapı olarak derin öğrenme ile sıralı veri işleme konularında önemli bir yere sahiptir. GRU eşitliği aşağıda yer almakla beraber, eşitlik 3.11’de yer alan “ $z_t$ ” güncelleme kapısının aktivasyon vektörünü, “ $\sigma$ ” sigmoid fonksiyonu, “ $W_z$ ” güncelleme kapısı ağırlıklarının, “ $h_{t-1}$ ” önceki gizli durumu, “ $x_t$ ” mevcut girdiyi ve “ $b_z$ ” güncelleme kapısı için ağırlık vektörünü belirtmektedir.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (3.11)$$

“ $R_r$ ” sıfırlama kapısındaki aktivasyon vektörünü ifade etmektedir. Sıfırlama kapısı ağırlıkları “ $W_r$ ,” sıfırlama kapısı ağırlık vektörü ise “ $b_r$ ” şeklinde ifade edilerek eşitlik 3.12’de belirtilen sıfırlama kapısı hesaplanabilmektedir.

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3.12)$$

Yeni gizli durumu hesabı eşitlik 3.13 ile hesaplanmaktadır. Burada yer alan “ $W$ ” yeni gizli durum ağırlıklarını ifade ederken, “ $b$ ” ise gizli durum için ağırlık vektörünü ifade etmektedir.

$$\tilde{h}_t = \tanh(W \cdot [r_t, h_{t-1}, x_t] + b) \quad (3.13)$$

$$h_t = z_t \cdot h_{t-1} + (1 - z_t) \cdot \tilde{h}_t \quad (3.14)$$


Son olarak eşitlik 3.14 ile gizli durum güncellemesi hesaplanmaktadır. Eşitlik 3.14 ‘de belirtilen “ $1 - z_t$ ” güncelleme kapısının tamamlayıcısı, “ $h_t$ ” ise gizli durumu ifade etmektedir.

### e. Transformer Neural Network (TNN)

Transformer Neural Network, 2017 yılında Vaswani ve çalışma arkadaşları tarafından önerilen ve doğal dil işleme başta olmak üzere birçok alanda büyük başarılar elde eden bir derin öğrenme mimarisidir. Bu mimari, özellikle sıralı verilerle çalışırken uzun vadeli bağıntıları modelleme yeteneği ile dikkat çekmektedir. TNN modeli, geleneksel tekrarlayan sinir ağlarının (RNN, LSTM, GRU) aksine, verileri sırayla değil, aynı anda işler. Bu sayede daha yüksek verimlilik ve daha hızlı eğitim süresi sağlar (Vaswani vd., 2017: s.2).

TNN yapısı, temel olarak encoder ve decoder olmak üzere iki ana bileşenden oluşmaktadır. Encoder tarafı, girdi dizisini işleyerek anlamlı bir bağlamsal temsile dönüştürürken, decoder bu temsili kullanarak çıktıyı üretmektedir. Ancak birçok uygulamada yalnızca encoder veya yalnızca decoder kısmı kullanılabilir.

TNN modelleri, bu güçlü mimarileri sayesinde makine çevirisi, metin özetleme, metin sınıflandırma, görsel tanıma ve zaman serisi tahmini gibi pek çok farklı alanda başarılı sonuçlar elde etmiştir (Dosovitskiy vd., 2020: s.4; Li vd., 2019: s.23).



Şekil 3.7: TNN modeli Mimarisi

$$Attention(Q, K, V) = softmax \left( \frac{QK^T}{\sqrt{d_k}} \right) V \quad (3.15)$$

Eşitlik 3.15 'de "Query (Q)", "Key (K)" ve "Value (V)" olarak adlandırılan üç temel vektör kümesi arasındaki ilişkilerin hesaplanması esasına dayanmaktadır (Vaswani vd., 2017: s.3).

Burada Query(Q), modelin diğer girdilerle ilişkisini öğrenmek istediği sorgu vektörünü, Key(K) tüm girişlerdeki verilere ait anahtar vektörlerini temsil eder. Bu vektörler ilgili sorgunun hangi girdiye ne düzeyde dikkat edileceğini belirler. Value(V) ise her bir girdinin diğer girdilere ne kadar dikkat etmesi gerektiğini hesaplar. Bu dikkat skorları, softmax fonksiyonu ile normalize edilir. Skorlar value matrisindeki değerlerle çarpılarak birleştirilir. Bu işlem sonucunda da model sadece önemli gördüğü girdilerden gelen bilgileri daha fazla yansıtan özet oluşturur. Qkt ise Sorgu ile anahtar vektörlerinin matris çarpımı sonucu elde edilen benzerlik (uyum) skorlarını ifade eder. Dk Anahtar vektörlerinin boyut sayısının kareköküdür. Softmax Her bir anahtar için hesaplanan benzerlik skorlarını normalize ederek, bunların toplamının 1 olmasını sağlar. Bu işlem, hangi girdilere ne kadar dikkat edileceğini belirler.

### 3.3 Performans Ölçütleri

Kullanılacak olan tahmin yöntemlerinin sahip oldukları performans düzeyi tahmin hatasını tanımlayan bazı teknikler ile ölçülmektedir. Hata değerinin yüksek olması durumunda tahmin doğruluk oranının düşük olduğu görülmektedir. Performans ölçütlerinin kök ortalama kare hatası, regresyon toplam kareler, belirleme katsayısı ve hiperparametreler şeklinde sıralandığı görülmektedir. Söz konusu performans ölçütleri aşağıda başlıklar halinde açıklanmıştır.

#### 3.3.1. Root Mean Square Error (RMSE)

Kök ortalama kare hatası temel olarak iki farklı veri kümesi arasında bulunan hata oranını ölçmede kullanılan bir performans ölçüm tekniğidir. Burada gerçek değer ile tahmin edilen değerin karşılaştırılması söz konusudur. Kök ortalama kare hatası değeri aşağıda yer alan eşitlikteki gibi belirlenmektedir. Değer ne kadar düşük çıkarsa gerçek değer ile tahmin edilen değerin birbirine yakın olduğu ortaya konulmaktadır. Eşitlik 3.16'da bulunan “n” değeri veri kümesindeki örüntü sayısını, “t” skoru gerçek değeri, “y” ise tahmin edilen değeri ifade etmektedir (Chai ve Draxler, 2014: s.1525).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t - y)^2} \quad (3.16)$$

### 3.3.2. Residuals Sum of Square (RSS)

Residuals Sum of Square (RSS) temel olarak regresyon analizinde bir modelin gerçek değerleri ile tahmin edildiği değerler arasında bulunan farkların karelerinin toplamını gösteren bir eşitlik ile hesaplanmaktadır. Diğer bir ifade ile modelin kalıntılarını ya da hatalarını ölçen bir metriktir. Genel olarak model performansının bir göstergesi olarak kullanılmaktadır. Düşük RSS değeri hataların az ve modelin uyumlu olduğunu göstermektedir. Bu değer bir taraftan modelin iyi olma düzeyini değerlendirirken, diğer taraftan ise modeli farklı modeller ile karşılaştırmaktadır. Eşitlik 3.17 ‘deki “y” tahmin değerini, “t” ise gerçek değeri ifade etmektedir (Xu, 2017: s.895).

$$RSS = \sum_{i=1}^n (t - y)^2 \quad (3.17)$$

### 3.3.3. Belirleme katsayısı ( $R^2$ )

Belirleme katsayısı (BK) temel olarak bağımsız değişkenlerdeki açıklama oranını göstermektedir. Belirleme katsayısı bir regresyon modelinin bağımsız değişkenlerinin, bağımlı değişkenin varyansını ne kadar açıkladığını gösteren bir istatistiksel ölçü olarak kullanılmaktadır.  $R^2$ , 0 ile 1 arasında bir değer almaktadır.  $R^2 = 0$ : Model, bağımlı değişkenin varyansını hiç açıklamadığını göstermektedir. Bu noktada modelin tahminleri, gerçek değerlerden tamamen bağımsızdır.  $R^2 = 1$ : Model, bağımlı değişkenin varyansını tamamen açıkladığını göstermektedir. Bu durumda modelin tahminleri gerçek değerlerle birebir örtüşmektedir. Eşitlik 3.18’de yer alan “t” gerçek değeri, “y” tahmin değerini, “ $\mu$ ” ise ortalama değeri göstermektedir (Asuero vd., 2006: s.41; Chicco vd., 2021: s.18; Topal vd., 2010: s.53).

$$BK = 1 - \frac{\sum_{i=1}^n (t - y)^2}{\sum_{i=1}^n (t - \mu)^2} \quad (3.18)$$

### 3.4. Hiperparametreler

Hiperparametreler, bir makine öğrenmesi modelinde öğrenme sürecini kontrol eden ve modelin performansını etkileyen ayarları ifade etmektedir. Söz konusu parametreler, modelin mimarisi, öğrenme süreci ve optimizasyon yöntemleri gibi unsurları belirlemektedir. Hiperparametreler temelde modelin eğitimi sırasında öğrenilmemekte, bunun yerine modelin eğitilmesinden önce belirlenmektedir. Hiperparametrelerin ayarlanması genel olarak deneme yanılma yöntemi, grid search veya random search gibi tekniklerle yapılmaktadır. Hiperparametre optimizasyonunun yapılması modelin genel performansını artırmak için kritik bir adım olarak değerlendirilmektedir (Probst vd., 2019: s.1).

#### 3.4.1. Veri setinin boyutu

Derin öğrenme uygulama süreçlerinde veri setinin çeşitliliği ve büyüklüğünün öğrenilmesi model açısından oldukça önemlidir. Veri setinin büyük olması öğrenmenin etkili olması açısından önem arz etmektedir. Buna karşılık sadece veri setinin büyüklüğü model için yeterli olmamaktadır. Önemli olan veri çeşitliliğinin sağlanmasıdır. Çeşitliliğin artması durumunda modelin başarısı da artmaktadır.

#### 3.4.2. Learning rate (Öğrenme oranı)

Öğrenme oranı temel olarak makine öğrenimi ve derin öğrenme modellerinin eğitim sürecinde kullanılan önemli bir hiperparametre olarak değerlendirilmektedir. Bu oran ile ağırlıkların güncellenme hızını belirlenmektedir. Bu kapsamda modelin her bir iterasyonda (ya da epoch'ta) kaybı minimize etmek için ağırlıklarını ne kadar değiştireceği kontrol edilmektedir. Öğrenme oranı, model performansı üzerinde önemli bir belirleyici olduğu için uygun bir değer seçmek oldukça önemlidir. Genel olarak deneme yanılma yöntemi ya da hiperparametre optimizasyon teknikleri kullanılarak en iyi öğrenme oranı belirlenmektedir (Peace vd., 2015: s.359). Öğrenme oranının yüksek olması durumunda yeterli çözüme ulaşma noktasında modelin aşırı atlamalar yapmasına ve hatta optimum çözümü kaçırmaya neden olmaktadır. Çok düşük düzeyde oran ise eğitimin uzun sürmesine ve modelin yavaş öğrenmesine zemin hazırlamaktadır.

### 3.4.3. Epoch (Eğitim tur sayısı)

Eğitim tur sayısı temel olarak bir makine öğrenimi modelinin eğitim verisi üzerinde kaç kez tam bir döngü gerçekleştirdiğini ifade etmektedir. Bu kapsamda modelin tüm eğitim verisi setini bir kez kullanarak ağırlıklarını güncellemesi için geçirdiği toplam sayıyı ifade etmektedir. Her bir epoch, modelin verilerden öğrenme sürecinin bir aşamasını göstermektedir (McGibbon ve Khochfar, 2022: s.5423).

### 3.4.4. Dropout (Unutma oranı)


Unutma oranı temel olarak yapay sinir ağları içerisinde ezberlemeyi engelleme amacıyla kullanılan bir düzenleme tekniği olarak değerlendirilmektedir. Eğitim süreci boyunca sinir ağının katmanlarında yer alan nöronların bir bölümü tesadüfen seçilerek geçici olarak devre dışı bırakılmaktadır. Söz konusu işlem her eğitim sürecinde tasarlanmakta ve farklı bir alt küme nöron kullanılması sağlanmaktadır. Bu durum nöronlara aşırı düzeyde bağlanmayı engellemektedir. Eğitim süreci tamamlandıktan sonra unutma oranı işlemi kaldırılmakta ve tüm nöronların kullanımı ile tahmin yapılmaktadır (Dalibi vd., 2018: s.1; Lykourantzou vd., 2009: s.950).

## 3.5. Zaman Serilerinde Durağanlık Analizi

Zaman serileri analizi temelde belirli bir zaman diliminde gözlemlenen verilerin incelenmesi ile ilişkilidir. Durağanlık analizi genellikle zaman serisinin istatistiksel özelliklerinin zamanla değişip değişmediğini belirlemek amacıyla kullanılmaktadır. Durağan bir zaman serisi; varyansı, ortalaması ve otokorelasyonu zamanla değişmeyen bir seriyi ifade etmektedir. Birçok zaman serisi modelinin geçerliliği için durağanlık kritik bir ön koşul olarak nitelendirilmektedir (Roşca, 2010: s.177; Petrica vd., 2017: s.6).


## 3.6. Veri Seti

Gerçekleştirilen çalışmada tüketim tesislerine ilişkin veriler MEDAŞ 'a ait Konya ili Karapınar ilçesinde bulunan tarımsal sulama faaliyeti gösteren abonelerin 2023 yılına ait Şekil 3.8'de belirtildiği gibi 1 yıllık ve saatlik elektrik tüketim verileri (kWh) kullanılmıştır. Veri seti 8760 saatlik bir ölçüm içermektedir.



Şekil 3.8 2023 yılına ait 8760 saatlik elektrik tüketim verileri

Aynı zamanda Karapınar ilçesine ait Meteoroloji 8. Bölge Müdürlüğü'nden alınan Şekil 3.9'da belirtilen 2023 yılı hava durumu sıcaklık verileri saatlik olarak kullanılmıştır. Veri seti 8760 saatlik veri içermektedir. Veri setlerinin %80 i eğitim %20 si test veri seti olarak ayrılmıştır.



Şekil 3.9. 2023 yılına ait 8760 saatlik hava durumu verileri

## 4.YÖNTEM

### 4.1. LSTM Yöntemi

Gerçekleştirilen çalışmada elektrik tüketim tahmini için bir LSTM modeli oluşturulmuştur. Oluşturulan LSTM modeli için optimum parametreleri tespit edebilmek için uygulama gerçekleştirilmiştir.

Veri setinin %80 i eğitim için kullanılarak model eğitilmiş ve %20 si ise test için kullanılarak test gerçekleştirilmiştir.

Katmanlardaki optimum nöron sayıları, unutma oranı için 0.2 öğrenme oranı için ise 0.001 Olarak belirlenmiş ve sabit tutulmuştur. Yapılan deneysel çalışmanın sonucunda LSTM modeli için en uygun katman nöron sayıları ise 128,8,32,1 olarak belirlenmiş ve Tablo 4.1’de sunulmuştur.

**Tablo 4.1** LSTM Modeli nöron sayısı analiz tablosu

| Nöron Sayıları | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 128,64,64,1    | 0.097  | 16,323  | 85,10% |
| 128, 64,32,1   | 0,096  | 15,856  | 85,50% |
| 128,64,16,1    | 0,0966 | 16,059  | 85,30% |
| 128,64,8,1     | 0,0968 | 16,116  | 85,30% |
| 128,32,64,1    | 0,0967 | 16,096  | 85,30% |
| 128,32,32,1    | 0,0987 | 16,775  | 84,70% |
| 128,32,16,1    | 0,0969 | 16,143  | 85,20% |
| 128,32,8,1     | 0,0968 | 16,128  | 85,20% |
| 128,16,64,1    | 0,0991 | 16,913  | 84,50% |
| 128,16,32,1    | 0,9801 | 16,513  | 84,90% |
| 128,16,16,1    | 0,0967 | 16,088  | 85,30% |
| 128,16,8,1     | 0,0976 | 16,391  | 85,05% |
| 128,8,64,1     | 0,0965 | 16,028  | 85,30% |
| 128,8,32,1     | 0,0955 | 15,6906 | 85,60% |
| 128,8,16,1     | 0,0973 | 16,278  | 85,10% |
| 128,8,8,1      | 0,0971 | 16,232  | 85,19% |

Katman nöron sayıları 128,8,32,1 olarak belirlendikten sonra öğrenme oranı 0,001 değerinde sabit tutulmuş ve en uygun unutma oranı 0.1 belirlenerek tablo 4.2’de sunulmuştur.

Tablo 4.2 LSTM modeli unutm oranı analiz tablosu

| Unutm Oranı | RMSE   | RSS     | $R^2$  |
|-------------|--------|---------|--------|
| 0.1         | 0,0944 | 15,341  | 86,00% |
| 0.2         | 0,0955 | 15,6906 | 85,60% |
| 0.3         | 0,098  | 16,509  | 84,90% |
| 0.4         | 0,098  | 16,775  | 84,70% |
| 0.5         | 0,0974 | 16,333  | 85,10% |
| 0.6         | 0,095  | 15,803  | 85,50% |
| 0.7         | 0,098  | 16,526  | 84,90% |

Katman nöron sayıları ve unutm oranı sabit tutularak en uygun öğrenme oranı analizler sonucunda 0.001 olarak belirlenmiş ve tablo 4.3’de sunulmuştur.

Tablo 4.3 LSTM modeli öğrenme oranı analiz tablosu

| Öğrenme Oranı | RMSE   | RSS     | $R^2$    |
|---------------|--------|---------|----------|
| 0.01          | 0,252  | 109,662 | -338,10% |
| 0.001         | 0,0944 | 15,341  | 86,00%   |
| 0.0001        | 0,096  | 15,88   | 85,50%   |
| 0.00001       | 0,114  | 22,514  | 79,40%   |

#### 4.2. MLP Yöntemi

Gerçekleştirilen çalışmada elektrik tüketim tahmini için bir MLP modeli oluşturulmuştur. Oluşturulan MLP modeli için optimum parametreleri tespit edebilmek için uygulama gerçekleştirilmiştir.

Veri setinin %80 i eğitim için kullanılarak model eğitilmiş ve %20 si ise test için kullanılarak test gerçekleştirilmiştir.

Katmanlardaki optimum nöron sayıları, unutm oranı için 0,2 öğrenme oranı için ise 0.001 Olarak belirlenmiş ve sabit tutulmuştur. Yapılan deneysel çalışmanın sonucunda MLP modeli için en uygun katman nöron sayıları ise 128,16,64,1 olarak belirlenmiş ve Tablo 4.4’de sunulmuştur.

Tablo 4.4 MLP Modeli nöron sayısı analiz tablosu

| Nöron Sayıları | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 128,64,64,1    | 0,096  | 16,12   | 85,00% |
| 128, 64,32,1   | 0.1002 | 17.29   | 84,20% |
| 128,64,16,1    | 0,991  | 16,894  | 84,50% |
| 128,64,8,1     | 0,1035 | 18,4307 | 83,10% |
| 128,32,64,1    | 0,0988 | 16,806  | 84,60% |
| 128,32,32,1    | 0,0976 | 16,392  | 85,05% |
| 128,32,16,1    | 0,1018 | 17,826  | 83,70% |
| 128,32,8,1     | 0,0988 | 16,785  | 84,60% |
| 128,16,64,1    | 0,0943 | 15,309  | 86,03% |
| 128,16,32,1    | 0,097  | 16,194  | 85,20% |
| 128,16,16,1    | 0,0996 | 17,074  | 84,40% |
| 128,16,8,1     | 0,1016 | 17,752  | 83,80% |
| 128,8,64,1     | 0,1005 | 17,388  | 84,10% |
| 128,8,32,1     | 0,0998 | 17,148  | 84,30% |
| 128,8,16,1     | 0,1036 | 18,469  | 83,10% |
| 128,8,8,1      | 0,0995 | 17,021  | 84,40% |

Katman nöron sayıları 128,16,64,1 olarak belirlendikten sonra öğrenme oranı 0.001 değerinde sabit tutulmuş ve en uygun unutmama oranı 0.5 belirlenerek tablo 4.5’de sunulmuştur.

Tablo 4.5 MLP modeli unutmama oranı analiz tablosu

| Unutmama Oranı | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 0.1            | 0,107  | 19,846  | 81,90% |
| 0.2            | 0,0943 | 15,309  | 86,03% |
| 0.3            | 0,0985 | 16,706  | 84,70% |
| 0.4            | 0,252  | 109,799 | -0,12% |
| 0.5            | 0,0871 | 13,058  | 88,00% |
| 0.6            | 0,252  | 109,93  | -0,24% |
| 0.7            | 0,252  | 109,82  | -0,15% |

Katman nöron sayıları ve unutmama oranı sabit tutularak en uygun öğrenme oranı analizler sonucunda 0.001 olarak belirlenmiş ve tablo 4.6’da sunulmuştur.

Tablo 4.6 MLP modeli öğrenme oranı analiz tablosu

| Öğrenme Oranı | RMSE   | RSS     | $R^2$  |
|---------------|--------|---------|--------|
| 0.01          | 0,257  | 113,981 | -3,90% |
| 0.001         | 0,0871 | 13,058  | 88,00% |
| 0.0001        | 0,0966 | 16,057  | 85,30% |
| 0.00001       | 0,109  | 20.729  | 81,00% |

### 4.3. RNN Yöntemi

Gerçekleştirilen çalışmada elektrik tüketim tahmini için bir RNN modeli oluşturulmuştur. Oluşturulan RNN modeli için optimum parametreleri tespit edebilmek için uygulama gerçekleştirilmiştir.

Veri setinin %80 i eğitim için kullanılarak model eğitilmiş ve %20 si ise test için kullanılarak test gerçekleştirilmiştir.

Katmanlardaki optimum nöron sayıları, unutmama oranı için 0,2 öğrenme oranı için ise 0.001 Olarak belirlenmiş ve sabit tutulmuştur. Yapılan deneysel çalışmanın sonucunda RNN modeli için en uygun katman nöron sayıları ise 128,32,64,1olarak belirlenmiş ve Tablo 4.7’de sunulmuştur.

Tablo 4.7 RNN Modeli nöron sayısı analiz tablosu

| Nöron Sayıları | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 128,64,64,1    | 0.089  | 13.84   | 87,30% |
| 128, 64,32,1   | 0,101  | 17,678  | 83,80% |
| 128,64,16,1    | 0,1009 | 17,5301 | 84,01% |
| 128,64,8,1     | 0,0923 | 14,652  | 86,63% |
| 128,32,64,1    | 0,0894 | 13,763  | 87,40% |
| 128,32,32,1    | 0,144  | 35,671  | 67,40% |
| 128,32,16,1    | 0,1002 | 17,286  | 84,20% |
| 128,32,8,1     | 0,0983 | 16,63   | 84,83% |
| 128,16,64,1    | 0,0968 | 16,131  | 85,20% |
| 128,16,32,1    | 0,1159 | 23,129  | 78,90% |
| 128,16,16,1    | 0,103  | 18,461  | 83,10% |
| 128,16,8,1     | 0,1032 | 18,327  | 10,32% |
| 128,8,64,1     | 0,1029 | 18,212  | 83,30% |
| 128,8,32,1     | 0,1067 | 19,582  | 82,10% |
| 128,8,16,1     | 0,1007 | 17,454  | 84,08% |
| 128,8,8,1      | 0,1016 | 17,763  | 83,80% |

Katman nöron sayıları 128,32,64,1 olarak belirlendikten sonra öğrenme oranı 0.001 değerinde sabit tutulmuş ve en uygun unutmama oranı 0.3 belirlenerek tablo 4.8’de sunulmuştur.

Tablo 4.8 RNN modeli unutm oranı analiz tablosu

| Unutm Oranı | RMSE   | RSS    | $R^2$  |
|-------------|--------|--------|--------|
| 0.1         | 0,0919 | 14,526 | 86,70% |
| 0.2         | 0,0894 | 13,763 | 87,40% |
| 0.3         | 0,0891 | 13,675 | 87,50% |
| 0.4         | 0,127  | 27,891 | 74,50% |
| 0.5         | 0,105  | 19,301 | 82,30% |
| 0.6         | 0,093  | 14,909 | 85,10% |
| 0.7         | 0,096  | 15,911 | 85,40% |

Katman nöron sayıları ve unutm oranı sabit tutularak en uygun öğrenme oranı analizler sonucunda 0.0001 olarak belirlenmiş ve tablo 4.9’da sunulmuştur.

Tablo 4.9 RNN modeli öğrenme oranı analiz tablosu

| Öğrenme Oranı | RMSE   | RSS     | $R^2$  |
|---------------|--------|---------|--------|
| 0.01          | 0,252  | 109,969 | -0,20% |
| 0.001         | 0,0894 | 13,763  | 87,40% |
| 0.0001        | 0,0803 | 11,105  | 89,80% |
| 0.00001       | 0,0897 | 13,842  | 87,30% |

#### 4.4. GRU Yöntemi

Gerçekleştirilen çalışmada elektrik tüketim tahmini için bir GRU modeli oluşturulmuştur. Oluşturulan GRU modeli için optimum parametreleri tespit edebilmek için uygulama gerçekleştirilmiştir.

Veri setinin %80 i eğitim için kullanılarak model eğitilmiş ve %20 si ise test için kullanılarak test gerçekleştirilmiştir.

Katmanlardaki optimum nöron sayıları, unutm oranı için 0,2 öğrenme oranı için ise 0.001 Olarak belirlenmiş ve sabit tutulmuştur. Yapılan deneysel çalışmanın sonucunda GRU modeli için en uygun katman nöron sayıları ise 128,16,32,1 olarak belirlenmiş ve tablo 4.10’da sunulmuştur.

Tablo 4.10 GRU Modeli nöron sayısı analiz tablosu

| Nöron Sayıları | RMSE   | RSS    | $R^2$  |
|----------------|--------|--------|--------|
| 128,64,64,1    | 0.097  | 16.25  | 85,00% |
| 128, 64,32,1   | 0,096  | 16,17  | 85,20% |
| 128,64,16,1    | 0,0989 | 16,83  | 84,60% |
| 128,64,8,1     | 0,0923 | 14,652 | 86,63% |
| 128,32,64,1    | 0,0952 | 15,606 | 85,70% |
| 128,32,32,1    | 0,0961 | 15,891 | 85,50% |
| 128,32,16,1    | 0,0951 | 15,555 | 85,80% |
| 128,32,8,1     | 0,1019 | 17,879 | 83,69% |
| 128,16,64,1    | 0,0924 | 14,701 | 86,50% |
| 128,16,32,1    | 0,0916 | 14,441 | 86,80% |
| 128,16,16,1    | 0,0937 | 15,098 | 86,20% |
| 128,16,8,1     | 0,0923 | 14,656 | 86,60% |
| 128,8,64,1     | 0,0961 | 15,859 | 85,53% |
| 128,8,32,1     | 0,1    | 17,19  | 84,30% |
| 128,8,16,1     | 0,0921 | 14,587 | 86,60% |
| 128,8,8,1      | 0,093  | 14,871 | 86,40% |

Katman nöron sayıları 128,16,32,1 olarak belirlendikten sonra öğrenme oranı 0.001 değerinde sabit tutulmuş ve en uygun unutmama oranı 0.2 belirlenerek tablo 4.11’de sunulmuştur.

Tablo 4.11 GRU modeli unutmama oranı analiz tablosu

| Unutmama Oranı | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 0.1            | 0,097  | 16,236  | 85,10% |
| 0.2            | 0,0916 | 14,441  | 86,80% |
| 0.3            | 0,0924 | 14,6802 | 86,60% |
| 0.4            | 0,098  | 16,765  | 84,70% |
| 0.5            | 0,0989 | 16,844  | 84,60% |
| 0.6            | 0,0957 | 15,775  | 85,60% |
| 0.7            | 0,098  | 16,526  | 84,90% |

Katman nöron sayıları ve unutmama oranı sabit tutularak en uygun öğrenme oranı analizler sonucunda 0.001 olarak belirlenmiş ve tablo 4.12’de sunulmuştur.

Tablo 4.12 GRU modeli öğrenme oranı analiz tablosu

| Öğrenme Oranı | RMSE   | RSS    | $R^2$  |
|---------------|--------|--------|--------|
| 0.01          | 0,098  | 16,616 | 84,80% |
| 0.001         | 0,0916 | 14,441 | 86,80% |
| 0.0001        | 0,0961 | 15,893 | 85,50% |
| 0.00001       | 0,102  | 18,162 | 83,40% |

#### 4.5. TNN Yöntemi

Gerçekleştirilen çalışmada elektrik tüketim tahmini için bir TNN modeli oluşturulmuştur. Oluşturulan TNN modeli için optimum parametreleri tespit edebilmek için uygulama gerçekleştirilmiştir.

Veri setinin %80 i eğitim için kullanılarak model eğitilmiş ve %20 si ise test için kullanılarak test gerçekleştirilmiştir.

Katmanlardaki optimum nöron sayıları, unutm oranı için 0,2 öğrenme oranı için ise 0.001 Olarak belirlenmiş ve sabit tutulmuştur. Yapılan deneysel çalışmanın sonucunda TNN modeli için en uygun katman nöron sayıları ise 128,64,16,1 olarak belirlenmiş ve tablo 4.13’de sunulmuştur.

Tablo 4.13 TNN Modeli nöron sayısı analiz tablosu

| Nöron Sayıları | RMSE   | RSS     | $R^2$  |
|----------------|--------|---------|--------|
| 128,64,64,1    | 0,1825 | 57,2717 | 47,77% |
| 128, 64,32,1   | 0,2073 | 73,9346 | 32,58% |
| 128,64,16,1    | 0,1725 | 51,1745 | 53,33% |
| 128,64,8,1     | 0,1929 | 63,9662 | 41,67% |
| 128,32,64,1    | 0,2021 | 70,2175 | 35,97% |
| 128,32,32,1    | 0,2000 | 68,8059 | 37,26% |
| 128,32,16,1    | 0,1809 | 56,3079 | 48,65% |
| 128,32,8,1     | 0,1938 | 64,5995 | 41,09% |
| 128,16,64,1    | 0,1943 | 64,9524 | 40,77% |
| 128,16,32,1    | 0,1863 | 59,6793 | 45,58% |
| 128,16,16,1    | 0,1879 | 60,7064 | 44,64% |
| 128,16,8,1     | 0,1850 | 58,8766 | 46,31% |
| 128,8,64,1     | 0,2088 | 75,0088 | 31,60% |
| 128,8,32,1     | 0,2097 | 75,6110 | 31,05% |
| 128,8,16,1     | 0,2115 | 76,9440 | 29,84% |
| 128,8,8,1      | 0,1926 | 63,8095 | 41,81% |

Katman nöron sayıları 128,64,16,1 olarak belirlendikten sonra öğrenme oranı 0.001 değerinde sabit tutulmuş ve en uygun unutm oranı 0.2 belirlenerek tablo 4.14’de sunulmuştur.

Tablo 4.14 TNN modeli unutm oranı analiz tablosu

| Unutm Oranı | RMSE   | RSS     | $R^2$  |
|-------------|--------|---------|--------|
| 0.1         | 0,1888 | 61,2804 | 44,12% |
| 0.2         | 0,1725 | 51,1745 | 53,33% |
| 0.3         | 0,2087 | 74,8799 | 31,72% |
| 0.4         | 0,1932 | 64,1707 | 41,48% |
| 0.5         | 0,1927 | 63,8769 | 41,75% |
| 0.6         | 0,2293 | 90,4460 | 17,52% |
| 0.7         | 0,1952 | 65,5136 | 40,26% |

Katman nöron sayıları ve unutmama oranı sabit tutularak en uygun öğrenme oranı analizler sonucunda 0.001 olarak belirlenmiş ve tablo 4.15’de sunulmuştur.

Tablo 4.15 TNN modeli öğrenme oranı analiz tablosu


| Öğrenme Oranı | RMSE   | RSS      | $R^2$  |
|---------------|--------|----------|--------|
| 0.01          | 0,2518 | 109,0190 | 0,58%  |
| 0.001         | 0,1725 | 51,1745  | 53,33% |
| 0.0001        | 0,2096 | 75,5411  | 31,11% |
| 0.00001       | 0,2140 | 78,7644  | 28,18% |

## 5. SONUÇLAR

### 5.1. RNN ile Elde Edilen Sonuçlar

Gerçekleştirilen bu çalışmada RNN modeli toplamda dört katmandan oluşmaktadır. Modelin mimarisinde kullanılan nöron sayıları çeşitli analizler sonucunda optimize edilmiş ve en iyi performansın 128,32,64,1 şeklinde yapılanma ile elde edildiği belirlenmiştir. Bununla birlikte modelin eğitim sürecinde hiperparametre ayarlamaları da dikkatle yapılarak gerçekleştirilen analizler sonucunda dropout (unutma oranı) için 0.3, learning rate (öğrenme oranı) için ise 0.0001 değeri belirlenmiştir.

Gerçekleştirilen bu çalışma sonucunda model toplamda 100 epoch (eğitim tur sayısı) boyunca eğitilmiştir. Eğitilen model ileriye dönük 168 saatlik tahminleme yapacak şekilde yapılandırılmıştır. Bu tahminler modelin test verileri üzerinde değerlendirilerek çıktılar, aynı zaman dilimine ait gerçek verilerle karşılaştırılarak Şekil 5.3 'de ve modele ilişkin en başarılı sonuca ilişkin veriler ise Tablo.5.3 'de sunulmuştur.



Şekil 5.1 RNN modeli analiz grafiği


Tablo 5.1 RNN Modelindeki en başarılı sonuca ilişkin veriler

| Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$  |
|-----------------------|--------------|---------------|--------|
| 128,32,64,1           | 0,3          | 0,0001        | 89,80% |

## 5.2. MLP ile Elde Edilen Sonuçlar

Gerçekleştirilen bu çalışmada MLP modeli toplamda dört katmandan oluşmaktadır. Modelin mimarisinde kullanılan nöron sayıları çeşitli analizler sonucunda optimize edilmiş ve en iyi performansın 128,16,64,1 şeklinde yapılanma ile elde edildiği belirlenmiştir. Bununla birlikte modelin eğitim sürecinde hiperparametre ayarlamaları da dikkatle yapılarak gerçekleştirilen analizler sonucunda dropout (unutma oranı) için 0.5, learning rate (öğrenme oranı) için ise 0.001 değeri belirlenmiştir.

Gerçekleştirilen bu çalışma sonucunda model toplamda 100 epoch (eğitim tur sayısı) boyunca eğitilmiştir. Eğitilen model ileriye dönük 168 saatlik tahminleme yapacak şekilde yapılandırılmıştır. Bu tahminler modelin test verileri üzerinde değerlendirilerek çıktılar, aynı zaman dilimine ait gerçek verilerle karşılaştırılarak Şekil 5.2 ‘de ve modele ilişkin en başarılı sonuca ilişkin veriler ise Tablo.5.2 ‘de sunulmuştur.



Şekil 5.2 MLP modeli analiz grafiği


Tablo 5.2 MLP Modelindeki en başarılı sonuca ilişkin veriler

| Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$  |
|-----------------------|--------------|---------------|--------|
| 128,16,64,1           | 0,5          | 0,001         | 88,00% |

### 5.3. GRU ile Elde Edilen Sonuçlar

Gerçekleştirilen bu çalışmada GRU modeli toplamda dört katmandan oluşmaktadır. Modelin mimarisinde kullanılan nöron sayıları çeşitli analizler sonucunda optimize edilmiş ve en iyi performansın 128,16,32,1 şeklinde yapılanma ile elde edildiği belirlenmiştir. Bununla birlikte modelin eğitim sürecinde hiperparametre ayarlamaları da dikkatle yapılarak gerçekleştirilen analizler sonucunda dropout (unutma oranı) için 0.2, learning rate (öğrenme oranı) için ise 0.001 değeri belirlenmiştir.

Gerçekleştirilen bu çalışma sonucunda model toplamda 100 epoch (eğitim tur sayısı) boyunca eğitilmiştir. Eğitilen model ileriye dönük 168 saatlik tahminleme yapacak şekilde yapılandırılmıştır. Bu tahminler modelin test verileri üzerinde değerlendirilerek çıktılar, aynı zaman dilimine ait gerçek verilerle karşılaştırılarak Şekil 5.4 ‘de ve modele ilişkin en başarılı sonuca ilişkin veriler ise Tablo.5.4 ‘de sunulmuştur.



Şekil 5.3 GRU modeli analiz grafiği


Tablo 5.3 GRU Modelindeki en başarılı sonuca ilişkin veriler

| Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$   |
|-----------------------|--------------|---------------|---------|
| 128,16,32,1           | 0,2          | 0,001         | 86,80 % |

#### 5.4. LSTM ile Elde Edilen Sonuçlar

Gerçekleştirilen bu çalışmada LSTM modeli toplamda dört katmandan oluşmaktadır. Modelin mimarisinde kullanılan nöron sayıları çeşitli analizler sonucunda optimize edilmiş ve en iyi performansın 128,8,32,1 şeklinde yapılanma ile elde edildiği belirlenmiştir. Bununla birlikte modelin eğitim sürecinde hiperparametre ayarlamaları da dikkatle yapılarak gerçekleştirilen analizler sonucunda dropout (unutma oranı) için 0.1, learning rate (öğrenme oranı) için ise 0.001 değeri belirlenmiştir.

Gerçekleştirilen bu çalışma sonucunda model toplamda 100 epoch (eğitim tur sayısı) boyunca eğitilmiştir. Eğitilen model ileriye dönük 168 saatlik tahminleme yapacak şekilde yapılandırılmıştır. Bu tahminler modelin test verileri üzerinde değerlendirilerek çıktılar, aynı zaman dilimine ait gerçek verilerle karşılaştırılarak Şekil 5.1 'de ve modele ilişkin en başarılı sonuca ilişkin veriler ise Tablo.5.1 'de sunulmuştur.



Şekil 5.4 LSTM modeli analiz grafiği


Tablo 5.4 LSTM Modelindeki en başarılı sonuca ilişkin veriler

| Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$  |
|-----------------------|--------------|---------------|--------|
| 128,8,32,1            | 0,1          | 0,001         | 86,00% |

### 5.5. TNN ile Elde Edilen Sonuçlar

Gerçekleştirilen bu çalışmada GRU modeli toplamda dört katmandan oluşmaktadır. Modelin mimarisinde kullanılan nöron sayıları çeşitli analizler sonucunda optimize edilmiş ve en iyi performansın 128,64,16,1 şeklinde yapılanma ile elde edildiği belirlenmiştir. Bununla birlikte modelin eğitim sürecinde hiperparametre ayarlamaları da dikkatle yapılarak gerçekleştirilen analizler sonucunda dropout (unutma oranı) için 0.2, learning rate (öğrenme oranı) için ise 0.001 değeri belirlenmiştir.

Gerçekleştirilen bu çalışma sonucunda model toplamda 100 epoch (eğitim tur sayısı) boyunca eğitilmiştir. Eğitilen model ileriye dönük 168 saatlik tahminleme yapacak şekilde yapılandırılmıştır. Bu tahminler modelin test verileri üzerinde değerlendirilerek çıktılar, aynı zaman dilimine ait gerçek verilerle karşılaştırılarak Şekil 5.5 ‘de ve modele ilişkin en başarılı sonuca ilişkin veriler ise Tablo.5.5 ‘de sunulmuştur.



Şekil 5.5 TNN modeli analiz grafiği

Tablo 5.5 TNN Modelindeki en başarılı sonuca ilişkin veriler

| Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$   |
|-----------------------|--------------|---------------|---------|
| 128,64,16,1           | 0,2          | 0,001         | 53,33 % |

## 5.6. Sonuçlar

Gerçekleştirilen bu çalışmada tarımsal sulama tarife grubuna ait elektrik tüketimlerinin gelecekteki değerlerini tahmin etmek amacı ile farklı derin öğrenme mimarileri kullanılmış ve bu modellerin performansları karşılaştırmalı olarak değerlendirilmiştir. MLP, LSTM, GRU, RNN ve TNN derin öğrenme modelleri kullanılmıştır. Modelleme sürecinde Meram Elektrik Dağıtım A.Ş. 'den temin edilen 2023 yılına ait toplam 8760 saatlik elektrik tüketim verisi, aynı döneme karşılık gelen Meteoroloji 8. Bölge Müdürlüğü kaynaklık sıcaklık verileri ile entegre edilmiştir. Bu iki temel veri seti birleştirilerek modelin giriş verisi haline getirilmiş ve mevsimsel değişkenlik ile tüketim alışkanlıkları arasında korelasyonun sağlıklı bir biçimde modellenmesi hedeflenmiştir. Her bir modelin performansı ise RMSE, RSS ve R2 metrikleri ile değerlendirilmiştir.

Yapılan değerlendirme sonucunda en yüksek başarıyı gösteren model Şekil 5.1'de da görüldüğü gibi RNN modeli olmuştur. RNN modeli %89,80 'lik bir R2 değeri ile zaman serisi yapısındaki tüketim verisini en etkin şekilde tahmin etmiş ve hem kısa hem de uzun dönem bağımlılıkları öğrenme noktasında başarılı sonuçlar üretmiştir.

İkinci en başarılı performans %88,00 'lik R2 değeri ile MLP modeli tarafından sergilenmiştir. MLP modeli her ne kadar zaman bağımlılığı olmayan klasik bir yapıya sahip olsa da çok katmanlı yapısı ile tüketim tahminini oldukça iyi modellemiştir.

Üçüncü sırada yer alan model ise GRU modeli olmuştur. GRU modeli, RNN ve LSTM modellerine kıyasla daha az sayıda parametre ile işlem yapmasına rağmen %86,80'lik bir R2 değeri elde ederek oldukça başarılı bir performans sergilemiştir. Bu da GRU 'nun hem eğitilme süresi hem de model karmaşıklığı açısından verimli bir seçenek olduğunu göstermektedir.

LSTM modeli ise genellikle zaman serisi analizlerinde sıkça tercih edilmesine rağmen bu çalışmada beklentinin altında bir performans göstermiştir. %86,00'lık bir R2 değeri ile GRU ve MLP modellerinin gerisinde kalmıştır.

Son olarak TNN modeli çalışmada en düşük başarıyı göstermiştir. TNN modeli, sadece %53,33 'lük bir R2 değeri ile diğer modellere kıyasla oldukça düşük bir tahmin doğruluğu sağlamaktadır. Transformer mimarisi genellikle büyük veri setleri ve doğal dil işleme uygulamalarında yüksek başarı gösterse de bu çalışmada kullanılan veri yapısı ve modelin parametre hassasiyeti nedeniyle performansı düşük kalmaktadır. Ayrıca TNN

modelinin eğitim sürecinde daha fazla veriye ve işlem gücüne ihtiyaç duyması da bu düşüklüğün bir diğer nedeni olabilir.

Tablo 5.6 Tüm Derin Öğrenme Modellerindeki en başarılı sonuçlara ilişkin veriler

| Derin Öğrenme Modeli | Katman Nöron sayıları | Unutma Oranı | Öğrenme Oranı | $R^2$   |
|----------------------|-----------------------|--------------|---------------|---------|
| LSTM Modeli          | 128,8,32,1            | 0,1          | 0,001         | 86,00 % |
| MLP Modeli           | 128,16,64,1           | 0,5          | 0,001         | 88,00 % |
| RNN Modeli           | 128,32,64,1           | 0,3          | 0,0001        | 89,80 % |
| GRU Modeli           | 128,16,32,1           | 0,2          | 0,001         | 86,80 % |
| TNN Modeli           | 128,64,16,1           | 0,2          | 0,001         | 53,33 % |

Sonuç olarak gerçekleştirilen çalışmada RNN modelinin tarımsal sulama grubuna ait elektrik tüketiminin tahmininde en uygun model olduğu sonucuna varılmıştır. RNN ‘nin ardından gelen MLP ve GRU modelleri hem başarı düzeyleri hem de model sadeliği bakımından dikkat çekici alternatiflerdir. Elde edilen bu bulgular ileriye dönük planlama, yük tahmini ve enerji yönetimi süreçlerinde uygun model tercihlerine ışık tutmaktadır.

### 5.7. Öneriler

Bu tez kapsamında elde edilen bulgular ışığında, gelecekte gerçekleştirilecek çalışmalarda veri çeşitliliğinin artırılması önerilmektedir; yalnızca sıcaklık değil, nem, yağış, rüzgâr gibi meteorolojik değişkenlerin yanı sıra tarımsal üretim takvimi ve elektrik fiyatları gibi faktörlerin de modele dahil edilmesi tahmin doğruluğunu artırabilir. Ayrıca, farklı iklim bölgelerinden alınacak verilerle modelin genellenebilirliği güçlendirilebilir. Transformer gibi büyük veri gerektiren modellerin daha uzun süreli ve zengin veri setleriyle yeniden denenmesi faydalı olabilir. Hibrit yaklaşımlar kullanılarak model başarımı geliştirilebilir. Gerçek zamanlı tahmin yapılabilen sistemlerin geliştirilmesi, elektrik dağıtım şirketlerinde karar destek aracı olarak kullanımını mümkün kılabilir. Son olarak, modellerin karar mekanizmalarının daha iyi anlaşılması için açıklanabilir yapay zekâ tekniklerinden yararlanılması ve enerji politikalarına yönelik senaryo analizlerinin eklenmesi de ileriki çalışmalara katkı sağlayacaktır.

## 6. KAYNAKLAR

- Abediniangerabi, B., Makhmalbaf, A., & Shahandashti, M. (2021). Deep learning for estimating energy savings of early-stage facade design decisions. *Energy and AI*, 5, 1–13.
- Aderibigbe, A. O., Ani, E. C., Ohenhen, P. E., Ohalet, N. C., & Daraojimba, D. O. (2023). Enhancing energy efficiency with AI: A review of machine learning models in electricity demand forecasting. *Engineering Science & Technology Journal*, 4(6), 341–356.
- Ağır, H., & Kar, M. (2010). Türkiye'de elektrik tüketimi ve ekonomik gelişmişlik düzeyi ilişkisi: Yatay kesit analizi. *Sosyoekonomi*, 12(Özel Sayı), 149–176.
- Ahmad, T., Madonski, R., Zhang, D., Huang, C., & Mujeeb, A. (2022). Data-driven probabilistic machine learning in sustainable smart energy/smart energy systems: Key developments, challenges, and future research opportunities in the context of smart grid paradigm. *Renewable and Sustainable Energy Reviews*, 160, 1–35.
- Albu, A., & Stanciu, L. (2015). Benefits of using artificial intelligence in medical predictions. In *2015 E-Health and Bioengineering Conference* (pp. 1–4).
- Ansarin, M., Ghiassi-Farrokhfal, Y., Ketter, W., & Collins, J. (2020). The economic consequences of electricity tariff design in a renewable energy era. *Applied Energy*, 275, 1–13.
- Ashta, A., & Herrmann, H. (2021). Artificial intelligence and fintech: An overview of opportunities and risks for banking, investments, and microfinance. *Strategic Change*, 30(3), 211–222.
- Asuero, A. G., Sayago, A., & González, A. G. (2006). The correlation coefficient: An overview. *Critical Reviews in Analytical Chemistry*, 36(1), 41–59.
- Aung, Y. Y., Wong, D. C., & Ting, D. S. (2021). The promise of artificial intelligence: A review of the opportunities and challenges of artificial intelligence in healthcare. *British Medical Bulletin*, 139(1), 4–15.
- Bharadiya, J. P. (2023). Artificial intelligence in transportation systems: A critical review. *American Journal of Computing and Engineering*, 6(1), 35–45.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250.
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278.

- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, 1–24.
- Choi, E., Cho, S., & Kim, D. K. (2020). Power demand forecasting using long short-term memory (LSTM) deep-learning model for monitoring energy sustainability. *Sustainability*, 12(3), 1–14.
- Collette, F., Van der Linden, M., & Poncelet, M. (2000). Working memory, long-term memory and language processing: Issues and future directions. *Brain and Language*, 71(1), 1–7.
- Dalipi, F., Imran, A. S., & Kastrati, Z. (2018). MOOC dropout prediction using machine learning techniques: Review and research challenges. In *2018 IEEE Global Engineering Education Conference* (pp. 1007–1014).
- Dave, M., & Patel, N. (2023). Artificial intelligence in healthcare and education. *British Dental Journal*, 234(10), 761–764.
- Dayhoff, J. E., & DeLeo, J. M. (2001). Artificial neural networks: Opening the black box. *Cancer: Interdisciplinary International Journal of the American Cancer Society*, 91(8), 1615–1635.
- Doğan, M. (2021). Yapay zekâ ve özgür irade: Yapay özgür iradenin imkânı. *TRT Akademi*, 6(13), 788–811.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Hounsby, N. (2020). *An image is worth 16x16 words: Transformers for image recognition at scale* (arXiv:2010.11929). arXiv.
- Douaioui, K., Oucheikh, R., Benmoussa, O., & Mabrouki, C. (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. *Applied System Innovation (ASI)*, 7(5), 1–24.
- Ertuğrul, H. M. (2011). Türkiye’de elektrik tüketimi büyüme ilişkisi: Dinamik analiz. *Enerji, Piyasa ve Düzenleme*, 2(1), 49–73.
- Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine learning and deep learning in energy systems: A review. *Sustainability*, 14(8), 1–49.
- Fraij, J., & László, V. (2021). A literature review: Artificial intelligence impact on the recruitment process. *International Journal of Engineering and Management Sciences*, 6(1), 108–119.
- Fu, J., Chiba, Y., Nose, T., & Ito, A. (2020). Language modeling in speech recognition for grammatical error detection based on neural machine translation. *Acoustical Science and Technology*, 41(5), 788–791.

- Gallegos, J., Arévalo, P., Montaleza, C., & Jurado, F. (2024). Sustainable electrification—Advances and challenges in electrical-distribution networks: A review. *Sustainability*, 16(2), 1–31.
- Georgevici, A. I., & Terblanche, M. (2019). Neural networks and deep learning: A brief introduction. *Intensive Care Medicine*, 45(5), 712–714.
- Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553), 452–459.
- Giudici, P. (2018). Fintech risk management: A research challenge for artificial intelligence in finance. *Frontiers in Artificial Intelligence*, 1, 1–6.
- Hadi, M. F., Hidayat, M., Widiarsih, D., & Murialti, N. (2021). The role of electricity and energy consumption influences industrial development between regions in Indonesia. *International Journal of Energy Economics and Policy*, 11(3), 403–408.
- Hermans, M., & Schrauwen, B. (2013). Training and analysing deep recurrent neural networks. *Advances in Neural Information Processing Systems*, 26, 1–9.
- Hlongwane, N. W., & Daw, O. D. (2023). Electricity consumption and population growth in South Africa: A panel approach. *International Journal of Energy Economics and Policy*, 13(3), 374–383.
- Irie, K., Tüske, Z., Alkhoul, T., Schlüter, R., & Ney, H. (2016). LSTM, GRU, highway and a bit of attention: An empirical overview for language modeling in speech recognition. In *Interspeech* (pp. 3519–3523).
- Joshi, D. A., & Masih, D. J. (2023). Enhancing employee efficiency and performance in Industry 5.0 organizations through artificial intelligence integration. *European Economic Letters (EEL)*, 13(4), 300–315.
- Kabeyi, M. J., & Olanrewaju, O. A. (2020). Managing sustainability in electricity generation. In *2020 IEEE International Conference on Industrial Engineering and Engineering Management* (pp. 530–536).
- Kanai, S., Fujiwara, Y., & Iwamura, S. (2017). Preventing gradient explosions in gated recurrent units. *Advances in Neural Information Processing Systems*, 30, 1–10.
- Kıymaz, Y. E. (2020). *Güneş enerjisi santrallerinde derin öğrenme kullanılarak elektrik üretimi tahmininin yapılması* (Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü). Konya.
- Köroğlu, Y. (2017). *Yapay zekâ'nın teorik ve pratik sınırları*. Boğaziçi Üniversitesi Yayinevi.
- Krishna, S. R., Rathor, K., Ranga, J., Soni, A., Srinivas, D., & Kumar, A. (2023). Artificial intelligence integrated with big data analytics for enhanced marketing. In *2023 International Conference on Inventive Computation Technologies* (pp. 1073–1077).

- Kufel, J., Bargieł-Łączek, K., Kocot, S., Koźlik, M., Bartnikowska, W., Janik, M., & Gruszczyńska, K. (2023). What is machine learning, artificial neural networks and deep learning?—Examples of practical applications in medicine. *Diagnostics*, 13(15), 1–22.
- Li, S., Li, W., Cook, C., Zhu, C., & Gao. (2018). Independently recurrent neural network (IndRNN): Building a longer and deeper RNN. *aigraph.csit.org*. Erişim tarihi: 21.04.2025
- Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). Dropout prediction in e-learning courses through the combination of machine learning techniques. *Computers & Education*, 53(3), 950–965.
- McGibbon, R. J., & Khochfar, S. (2022). Multi-epoch machine learning 1: Unravelling nature versus nurture for galaxy formation. *Monthly Notices of the Royal Astronomical Society*, 513(4), 5423–5437.
- Mideksa, T. K., & Kallbekken, S. (2010). The impact of climate change on the electricity market: A review. *Energy Policy*, 38(7), 3579–3585.
- Mucuk, M., & Uysal, D. (2009). Türkiye ekonomisinde enerji tüketimi ve ekonomik büyüme. *Maliye Dergisi*, 157(1), 105–115.
- Naeem, S., Ali, A., Anam, S., & Ahmed, M. M. (2023). An unsupervised machine learning algorithms: Comprehensive review. *International Journal of Computing and Digital Systems*, 13(1), 911–921.
- Nikitas, A., Michalakopoulou, K., Njoya, E. T., & Karampatzakis, D. (2020). Artificial intelligence, transport and the smart city: Definitions and dimensions of a new mobility era. *Sustainability*, 12(7), 1–19.
- Noriega, L. (2005). *Multilayer perceptron tutorial*. School of Computing, Staffordshire University.
- Oladapo, B. I., Olawumi, M. A., & Omigbodun, F. T. (2024). Machine learning for optimising renewable energy and grid efficiency. *Atmosphere*, 15(10), 1250–1269.
- Olatunde, T. M., Okwandu, A. C., & Akande, D. O. (2024). Reviewing the impact of energy-efficient appliances on household consumption. *International Journal of Science and Technology Research Archive*, 6(2), 1–11.
- Oruh, J., Viriri, S., & Adegun, A. (2022). Long short-term memory recurrent neural network for automatic speech recognition. *IEEE Access*, 10, 30069–30079.
- Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D. (2011). Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, 3(2), 332–337.
- Pappas, C., Karakosta, C., Marinakis, V., & Psarras, J. (2012). A comparison of electricity production technologies in terms of sustainable development. *Energy Conversion and Management*, 64, 626–632.

- Igiri, C. P., Anyama, O. U., & Silas, A. I. (2015). Effect of learning rate on artificial neural network in machine learning. *International Journal of Engineering Research & Technology*, 4(2), 359–363.
- Petrică, A. C., Stancu, S., & Ghițulescu, V. (2017). Stationarity–The central concept in time series analysis. *International Journal of Emerging Research in Management and Technology*, 6(1), 6–16.
- Popescu, M. C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579–588.
- Probst, P., Boulesteix, A. L., & Bischl, B. (2019). Tunability: Importance of hyperparameters of machine learning algorithms. *Journal of Machine Learning Research*, 20(53), 1–32.
- Qureshi, M., Arbab, M. A., & Rehman, S. U. (2024). Deep learning-based forecasting of electricity consumption. *Scientific Reports*, 14(1), 1–11.
- Ramchoun, H., Idrissi, M. J., Ghanou, Y., & Ettaouil, M. (2017). Multilayer perceptron: Architecture optimization and training with mixed activation functions. In *Proceedings of the 2nd International Conference on Big Data, Cloud and Applications* (pp. 1–6).
- Rosca, E. R. (2010). Stationary and non-stationary time series. *The USV Annals of Economics and Public Administration*, 10(1), 177–186.
- Sahoo, M., & Sethi, N. (2020). Impact of industrialization, urbanization, and financial development on energy consumption: Empirical evidence from India. *Journal of Public Affairs*, 20(3), 1–10.
- Santoro, A., Faulkner, R., Raposo, D., Rae, J., Chrzanowski, M., Weber, T., & Lillicrap, T. (2018). Relational recurrent neural networks. *Advances in Neural Information Processing Systems*, 31, 1–12.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
- Stamminger, R., & Anstett, V. (2013). The effect of variable electricity tariffs in the household on usage of household appliances. *Smart Grid and Renewable Energy*, 4(4), 353–365.
- Sahin, Y. S. (2025). Elektrik tüketimi ve sanayi üretimi ilişkisinin son dönem seyri. *Research and Monetary Policy Department, Central Bank of the Republic of Turkey*, 2502, 1–9.
- Topal, M., Eydurhan, E., Yağanoğlu, A. M., Sönmez, A., & Keskin, S. (2010). Çoklu doğrusal bağlantı durumunda ridge ve temel bileşenler regresyon analiz yöntemlerinin kullanımı. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 41(1), 53–57.

- Trenn, S. (2008). Multilayer perceptrons: Approximation order and necessary number of hidden units. *IEEE Transactions on Neural Networks*, 19(5), 836–844.
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929–5955.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Vinkóczy, T., Koltai, J. P., Nagy, N. G., Szabó-Szentgróti, E., & Szabó-Szentgróti, G. (2023). The sustainable contribution of artificial intelligence to higher education: Results of a pilot study. *Chemical Engineering Transactions*, 107, 487–492.
- Xu, S. (2017). Predicted residual error sum of squares of mixed models: An application for genomic prediction. *G3: Genes, Genomes, Genetics*, 7(3), 895–909.
- Yao, K., Zweig, G., Hwang, M. Y., Shi, Y., & Yu, D. (2013). Recurrent neural networks for language understanding. In *Interspeech* (pp. 2524–2528).
- Zhang, C., Liao, H., & Mi, Z. (2019). Climate impacts: Temperature and electricity consumption. *Natural Hazards*, 99(3), 1259–1275.

**EKLER**

**EK-1:** Tez çalışmasında kullanılan hava durumu verileri için Meteoroloji Genel Müdürlüğü 8. Bölge Müdürlüğünden alınan izin yazısı



T.C.  
ÇEVRE, ŞEHİRCİLİK VE İKLİM DEĞİŞİKLİĞİ BAKANLIĞI  
Meteoroloji Genel Müdürlüğü  
8. Bölge Müdürlüğü



Sayı : E-46130084-107-422943  
Konu : Rasat Bilgisi ve Bilgi İstekleri

07.01.2025

**DAĞITIM YERLERİNE**

İlgi : 07.01.2025 tarihli dilekçeniz.

İlgi'de kayıtlı dilekçenizle istenilen meteorolojik bilgiler Ek'te verilen bağlantı adresinde sunulmuştur.

10 Haziran 2020 tarihli ve 31151 sayılı Resmi Gazete'de yayımlanan "Resmi Yazışmalarda Uygulanacak Usul ve Esaslar Hakkında Yönetmelik" uyarınca resmi yazışmalarda paylaşım saklama işlemleri için elektronik ortam kullanımı esas unsur haline getirilmiştir. Bu kapsamda istemiş olduğunuz meteorolojik veriler, yazımızın tarihi itibarıyla 3 ay süresince verilen Ek'teki bağlantı üzerinden indirilebilecektir.

Bilgilerini ve gereğini arz/rica ederim.

Derya ERGÜN  
Bölge Müdürü a.  
Bölge Müdür Yardımcısı

Ek: <https://bulut.mgm.gov.tr/share/preview/xMxwGuFaqwvgfvSt>

Dağıtım:

Gereği:

Sayın Numan KÖKSAL

Bilgi:

METEOROLOJİK VERİ İŞLEM DAİRESİ  
BAŞKANLIĞINA

**EK-2: Tez çalışmasında kullanılan, elektrik tüketim verileri için Meram Elektrik Dağıtım AŞ'den izin yazısı**

MEDAŞ Evrak Tarih ve Sayısı: 10/03/2025-9136

SAYIN NUMAN KÖKSAL



**MERAM Elektrik Dağıtım A.Ş.**

KANUNİ MERKEZ

Sancak Mahallesi Yeni İstanbul Caddesi No:92 Selçuklu / KONYA

Tel : +90 (850) 251 30 00

Faks : +90 (850) 251 31 00

: +90 (332) 255 00 82

ÇM No : 444 8 186

Web : www.meramedas.com.tr

E-Mail : info@meramedas.com.tr

Kep : meram.dagitim@hs02.kep.tr

Mersis No : 0833 0030 8740 0017

Selçuk VD : 833 003 0874

**LÜTFEN İLGİLİ YAZINIZDA AŞAĞIDAKİ REFERANS**

**NUMARASINI BELİRTİNİZ.**

☐ Tarih : 10/03/2025

☐ Referans No : RTGMV\_ETB\_622.02\_9136

**ÖZÜ: VERİ TALEBİ**

İLGİ: 10.03.2025 tarihli dilekçe.

İlgi dilekçe ile Konya İli Karapınar ilçesinde yer alan ve 2023 yılı içerisinde tüketim yapan tarımsal sulama tarife grubuna ait tesisatların tüketim verisi talep edilmektedir.

Talep edilen veriler Ek-1 de tarafınızla paylaşılmıştır.

Bilgilerinize sunarız,

Saygılarımızla.

*e-imza*

**Anılcan ESER**

Enerji Talepleri Mühendisi

*e-imza*

**Mustafa SAĞLAM**

Tüketici Hizmetleri Müdürü

Y.S.Olgun

Ek :

1-Tarımsal Sulama Tarife Grubuna Ait Tüketim Verisi.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

Adı, Soyadı: Numan KÖKSAL

Uyruğu: T.C.

Doğum Tarihi ve Yeri:

Medeni Durumu:

Tel:

GSM:

email:

Yazışma Adresi:

### EĞİTİM

| Derece        | Kurum                        | Mezuniyet Tarihi |
|---------------|------------------------------|------------------|
| Yüksek Lisans | Nuh Naci Yazgan Üniversitesi |                  |
| Lisans        | Cumhuriyet Üniversitesi      | 11.09.2017       |
| Lise          | Erzincan Anadolu Lisesi      | 08.06.2012       |

### İŞ DENEYİMLERİ

| Yıl         | Kurum                      | Görev       |
|-------------|----------------------------|-------------|
| 2019- Halen | Meram Elektrik Dağıtım A.Ş | Başmühendis |
| 2018-2019   | Doğan Elektrik             | Mühendis    |

### YABANCI DİL

İngilizce, Almanca