



T.C.  
NECMETTİN ERBAKAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



**GÜNEŞ ENERJİSİ SANTRALLERİNDE  
DERİN ÖĞRENME KULLANILARAK  
ELEKTRİK ÜRETİMİ TAHMİNİNİN  
YAPILMASI**

**Yunus Emre KIYMAZ**

**YÜKSEK LİSANS TEZİ**

**Enerji Sistemleri Mühendisliği Anabilim Dalı**

**Aralık-2020  
KONYA  
Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Yunus Emre KIYMAZ tarafından hazırlanan “GÜNEŞ ENERJİSİ SANTRALLERİNDE DERİN ÖĞRENME KULLANILARAK ELEKTRİK ÜRETİMİ TAHMİNİNİN YAPILMASI” adlı tez çalışması 17/12/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Enerji Sistemleri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Prof. Dr. Ahmet SAMANCI

#### Danışman

Prof. Dr. Hidayet OĞUZ

#### Üye

Dr. Öğr. Üyesi Murat KÖKLÜ

### İmza

.....

.....

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../2020 gün ve ..... sayılı kararıyla onaylanmıştır.

Prof. Dr. S. Savaş DURDURAN  
FBE Müdürü

## **TEZ BİLDİRİMİ**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Yunus Emre KIYMAZ

Tarih: 17.12.2020

# ÖZET

## YÜKSEK LİSANS TEZİ

### GÜNEŞ ENERJİSİ SANTRALLERİNDE DERİN ÖĞRENME KULLANILARAK ELEKTRİK ÜRETİMİ TAHMİNİNİN YAPILMASI

**Yunus Emre KIYMAZ**

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
Enerji Sistemleri Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Hidayet OĞUZ**

**2020, 90 Sayfa**

**Jüri**

**Prof. Dr. Hidayet OĞUZ**

**Prof. Dr. Ahmet SAMANCI**

**Dr. Öğr. Üyesi Murat KÖKLÜ**

Güneş enerjisi santralleri yenilenebilir enerji sistemleri arasında önemli bir konuma sahiptir. Sınırsız kaynak olarak nitelendirilen güneş enerjisinin küçük bir kısmının yer küreye ulaşması, bu santrallerin güneş ışığından mümkün olduğunca yeterli kapasitede yararlanabilmesi önem arz ettiğinden, verimlilik adına günümüze kadar önemli teknolojik gelişmeler yaşanmaktadır. Bu tip sistemlerin kurulumu pahalıdır ve 25 yıl gibi ortalama ömürleri bulunmaktadır. Bu sistemlerden optimum şekilde faydalanmak için ileriye dönük elektrik üretim tahminleri yapılması önemli olabilmektedir.

Bu tez çalışması, Konya'nın Çumra, Tuzlukçu ve Yunak ilçelerinde kurulu ve yıllık 1MW kapasiteli (Santral\_A, Santral\_B, Santral\_C, Santral\_D) güneş santrallerine ait günlük frekanslı 2 yıllık üç veri seti ve saatlik frekanslı 1 yıllık bir veri seti (tek değişkenli zaman serileri) üzerinde değerlendirme yapılmıştır. Güneş enerjisi santrallerinden elde edilen bu verilere göre derin öğrenme kullanılarak elektrik üretim analizi yapılmıştır. Tercih edilen derin öğrenme yöntemi; uzun kısa süreli hafıza (LSTM) olup zaman serisi analizinde kullanılan bir başka istatistiksel yöntem olan mevsimsel otoregresif hareketli ortalama (SARIMA) ile karşılaştırılmıştır. Her bir veri seti için elde edilen sonuçlar; beş farklı hata performans ölçüm sistemine tabii tutulmuş (MSE, RMSE, NMSE, MAE, MAPE) ve LSTM modelinin SARIMA modeline göre çoğunlukla gerçek verilere daha yakın sonuçlar verdiği tespit edilmiştir.

Sonuçların ardından güneş santrallerinde verimliliğe etki edebilecek faktörler incelenmiş, İç Anadolu Bölgesi, Ege ve Akdeniz bölgelerinde kurulu olan bazı santrallerin saha mühendislerince tespit edilen sorunlar derlenerek bazı yorumlar ve çıkarımlar yapılmıştır.

**Anahtar Kelimeler:** Derin öğrenme, güneş enerjisi santrali, mevsimsel otoregresif entegre hareketli ortalama, tek değişkenli zaman serileri, uzun kısa süreli hafıza

## ABSTRACT

## MS THESIS

# ESTIMATION ELECTRICITY GENERATION USING DEEP LEARNING ON SOLAR POWER PLANTS

**Yunus Emre KIYMAZ**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN ENERGY SYSTEMS ENGINEERING**

**Advisor: Prof. Hidayet OĞUZ**

**2020, 90 Pages**

**Jury**

**Prof. Hidayet OĞUZ**

**Prof. Ahmet SAMANCI**

**Asst. Prof. Murat KÖKLÜ**

Solar power plants have an important position among renewable energy systems. Since it is important that a small part of the solar energy, which is described as an unlimited resource, reaches the earth and that these power plants can benefit from sunlight in sufficient capacity as possible, important technological developments have been experienced so far in terms of efficiency. Such systems are expensive to install and have an average life span of 25 years. It can be important to make forward-looking electricity generation estimates in order to make optimum use of these systems.

This thesis study was evaluated on three 2-year daily frequency data sets and a 1-year data set with hourly frequency (univariate time series) belonging to solar power plants with 1MW annual capacity (Santral\_A, Santral\_B, Santral\_C, Santral\_D) established in Çumra, Tuzlukçu and Yunak districts of Konya. According to these data obtained from solar power plants, electricity generation analysis was made using deep learning. Preferred deep learning method; long-short-term memory (LSTM) and compared with seasonal autoregressive moving average (SARIMA), another statistical method used in time series analysis. Results obtained for each data set; It was subjected to five different error performance measurement systems (MSE, RMSE, NMSE, MAE, MAPE) and it was determined that the LSTM model mostly gave results closer to the real data than the SARIMA model.

After the results, the factors that may affect the efficiency of solar power plants were examined, and some comments and inferences were made by compiling the problems identified by field engineers of some power plants established in Central Anatolia, Aegean and Mediterranean regions.

**Keywords:** Deep learning, long short-term memory, seasonal autoregressive integrated moving average, solar power plant, univariate time series

## ÖNSÖZ

Yenilenebilir enerji sistemlerinin sıklıkla talep gördüğü bugünlerde, özellikle güneş enerjisi santralleri; gelişen teknolojileri sayesinde verimlilikleri artarak ülkelerin dışa bağımlılığını hem de kısıtlı yeraltı kaynakları tüketimini azaltmada önemli rol üstlenmektedir. Bu sistemlerin, ileriye dönük kararlı bir şekilde elektrik üretebilmeleri ve maliyetlerini optimize edebilmek için istatistiksel açıdan tahmin edilmesi gerekmektedir. Bu çalışmada, derin öğrenme metodolojileri kullanılarak elektrik üretim tahmininin yapılması hedeflenmiş, farklı istatistiksel yöntemlerle kıyaslanmıştır.

Bu tez çalışmasında bana yardımcı olan değerli danışman hocam Prof. Dr. Hidayet OĞUZ'a teşekkür ederim. Çalışmam için gerekli elektrik üretim verilerinin paylaşımında ve düzenlenmesinde yardımcı olan İNSOS Enerji Yatırım Danışmanlık A.Ş. Operasyonel Teknolojiler Koordinatörü Sayın Kenan KAHYA'ya ve Elektronik Müh. Ercenk YAVUZ'a teşekkürlerimi sunarım. Yıllar boyunca beraber çalıştığımız ve konuyu belirlememde yardımcı olan AE Kod Teknolojisi proje yöneticimiz Ahmet BÜYÜKASLAN ve yazılım ekibinden Emre BÜYÜKASLAN ve Selman KIRBAĞ'a teşekkür ederim.

Ve son olarak çalışmam boyunca beni destekleyen değerli aileme teşekkür ediyorum.

Yunus Emre KIYMAZ  
KONYA-2020

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>ÖNSÖZ .....</b>	<b>vi</b>
<b>İÇİNDEKİLER.....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>ix</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Yenilenebilir Enerji Kaynakları .....	2
1.1.1. Güneş enerjisi .....	2
1.2. Yapay Zekâ .....	4
1.2.1. Tarihçe .....	4
1.2.2. Makine öğrenmesi.....	7
1.2.3. Derin öğrenme .....	9
1.3. Zaman Serisi, Analizi ve Yöntemleri.....	15
1.3.1. Zaman serisi analizleri .....	16
1.3.2. Zaman serisi yöntemleri.....	16
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>18</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>23</b>
3.1. Yazılım Araçları.....	23
3.1.1. Python .....	23
3.1.2. Anaconda Navigator .....	23
3.1.3. Numpy kütüphanesi .....	24
3.1.4. Matplotlib kütüphanesi .....	24
3.1.5. Tensorflow kütüphanesi.....	24
3.1.6. Pandas kütüphanesi.....	24
3.1.7. Keras kütüphanesi.....	25
3.1.8. Statsmodels kütüphanesi.....	25
3.2. Veri Setleri .....	25
3.3. Veri Tahmin Yöntemleri, Performans Ölçümleri ve Hiper-parametreler .....	28
3.3.1. RNN-LSTM ilişkisi .....	28
3.3.2. Zaman serisi tahmininde kullanılan metotlar.....	34
3.3.3. Performans ölçümleri.....	37
3.3.4. Hiper-parametreler.....	40
3.3.5. Zaman serilerinde durağanlık tespitleri .....	42
3.3.6. Zaman serisi için istatistiksel model seçiminde kullanılan Akaike Bilgi Kriteri (AIC) .....	44
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>45</b>

4.1.	LSTM Modeli.....	46
4.2.	SARIMA Modeli.....	46
4.3.	Veri Setlerine Ait Sonuçlar .....	47
4.3.1.	Santral_A ve tahmin sonuçları.....	47
4.3.2.	Santral_B ve tahmin sonuçları.....	49
4.3.3.	Santral_C ve tahmin sonuçları.....	51
4.3.4.	Santral_D ve tahmin sonuçları.....	52
4.4.	İç Anadolu Bölgesindeki Bazı GES'lere Ait Analizler.....	54
<b>5.</b>	<b>SONUÇLAR VE ÖNERİLER.....</b>	<b>58</b>
5.1.	Sonuçlar.....	58
5.2.	Öneriler .....	59
<b>6.</b>	<b>KAYNAKLAR.....</b>	<b>60</b>
<b>EKLER</b>	<b>.....</b>	<b>63</b>
<b>ÖZGEÇMİŞ</b>	<b>.....</b>	<b>80</b>

## SİMGELER VE KISALTMALAR

### Simgeler

$\alpha$	: Alfa
$\beta$	: Beta
$\delta$	: Delta
$\Delta$	: Büyük delta
$\Phi$	: Fi (model katsayı vektörü - AR)
$\gamma$	: Gama
$\omega$	: Omega (gürültü değeri)
$\sigma$	: Sigmoid fonksiyonu (katman - LSTM)
$\theta$	: Teta (model katsayı vektörü - MA)
tanh	: Hiperbolik tanjant fonksiyonu (katman - LSTM)

### Kısaltmalar

AAAI	: Amerikan Yapay Zekâ Derneği
AC	: Alternatif Akım
ACF	: Otokorelasyon Fonksiyonu
ADF	: Artırılmış Dickey-Fuller
AG	: Alçak Gerilim
AI	: Artificial Intelligence (Yapay Zekâ)
AIC	: Akaike Bilgi Kriteri
AR	: Otoresif (Özbağlanımlı)
ARIMA	: Otoresif Entegre Hareketli Ortalama
ARMA	: Otoresif Hareketli Ortalama
BIST	: Borsa İstanbul
BM	: Boltzmann Makineleri
BMU	: En İyi Eşleşen Birim
BRT	: Torbalı Regresyon Ağaçları
CNN	: Evrişimli Sinir Ağları
CO <sub>2</sub>	: Karbondioksit
CPU	: Merkezi İşlem Birimi
CSP	: Konsantre Güneş Enerjisi
DC	: Doğru Akım
DF	: Dickey-Fuller
DNN	: Derin Sinir Ağı
DÖ	: Derin Öğrenme
GES	: Güneş Enerjisi Santrali
GPU	: Grafik İşlemci Birimi
HMM	: Saklı Markov Modeli
H <sub>2</sub> O	: Su
IA	: Index of Agreement (Uyum indeksi)
ISO	: Bağımsız Sistem Operatörü
kWh	: Kilovatsaat
LSTM	: Uzun Kısa Süreli Hafıza
MA	: Hareketli Ortalama
MAE	: Ortalama Mutlak Hata

MAPE	: Ortalama Mutlak Yüzde Hatası
MBE	: Ortalama Yanlılık Hatası
MDP	: Markov Karar Süreci
MLP	: Çok Katmanlı Algılayıcı
MLR	: Çoklu Doğrusal Regresyon
MÖ	: Makine Öğrenimi (Makine Öğrenmesi)
MPE	: Ortalama Yüzde Hatası
MRE	: Ortalama Bağlı Hata
MSE	: Ortalama Kare Hata
MW	: Megavat
NMAE	: Normalize Edilmiş MAE
NMSE	: Normalize Edilmiş MSE
NRMSE	: Normalize Edilmiş RMSE
OG	: Orta Gerilim
PACF	: Kısmı ACF
PM <sub>2.5</sub>	: Partikül Madde
PReLU	: Parametrik ReLU
PV	: Fotovoltaik
ReLU	: Düzeltilmiş Doğrusal Birim
rMBE	: Göreceli MBE
RMSE	: Kök Ortalama Kare Hata
rRMSE	: Göreceli RMSE
RNN	: Tekrarlayan Sinir Ağları
RTU	: Uzak Terminal Birimi (Cihazı)
SARIMA	: Mevsimsel Otoregresif Entegre Hareketli Ortalama
SCADA	: Denetim kontrolü ve veri toplama
SOM	: Özdüzenleyici Haritalar
SVM	: Destek Vektör Makinesi
SVR	: Destek Vektör Regresyonu
S2S	: Sequence to Sequence (Sıra dizisi)
TIR	: Uluslararası Karayolu Taşımacılığı
TPU	: Tensör İşlem Birimi
TRAI	: Türkiye Yapay Zekâ İnisiyatifi
XOR	: Özel VEYA
YES	: Yenilenebilir Enerji Sistemleri
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ

## 1. GİRİŞ

Yenilenebilir enerji; güneş, rüzgâr, biokütle, jeotermal, hidroelektrik, dalga enerjisi vb. enerji akışı sürekli devam halinde olan enerji kaynakları için kullanılan bir terimdir. Yenilenebilir enerji sistemleri (YES); dünya üzerinde sıkça kullanılan petrol, doğalgaz, kömür vb. kaynaklarının azalması sebebi ile elektrik ihtiyacının karşılanması için yenilenebilir enerji kaynaklarını kullanan sistemler bütünüdür diyebiliriz. Dünyada elektrik üretiminde oldukça sık kullanılan fosil yakıtlar ve türevleri, çevreyi kirletmekle kalmayıp insan, hayvan ve bitki sağlığına da olumsuz etkileri vardır. Buna benzer nedenlerden ötürü de yenilenebilir enerji kullanımı önem arz etmektedir. Var olan bu yenilenebilir enerji kaynaklarına talep gün geçtikçe artmakta, fakat enerji verimliliği konusunda uygulamaya konulmuş yeterince çalışma bulunmamaktadır. Bu durum, fosil yakıtlar karşısında önemli bir engel oluşturmaktadır. Örneğin güneş enerjisi santrallerinin (GES) ilk kurulum ve bakım maliyetleri yüksek olmakla birlikte ortalama ömürlerinin 25 yıl olduğunu düşünürsek, verimlilik konusu GES'ler için oldukça önemlidir.

Ülkemizde gerçek ve tüzel kişilere elektrik satışları kamu kurumları ve yüklenici firmalar aracılığı ile yapılmaktadır. Ayrıca YES ile beraber devlet; kullanıcılara lisanslı ve lisanssız üretim izni vermiştir. Gerçek ve tüzel kişiler böylece hem elektrik üretip kullanabilecekler hem de devlete ihtiyaç fazlası elektriğini satabilecektir. Elektrik satışı için devlet, üretici ile anlaşma yapar. Belirli bir gücün üzerinde veya altında satış, üreticiye zarar olarak dönebilir. Bu durumda elektrik satışından kâr elde edemez veya tasarruf edemez. Burada üretici, geçmişte ürettiği elektrik enerjisi verilerini kullanarak ileriye dönük üretim tahmini yapılabilirse kâra geçmek veya zararını azaltmak için önlem alabilir. Bu tez çalışmasında öncelikle yenilenebilir enerji kaynakları, yapay zekâ ve derin öğrenme, zaman serisi tanımı ve analiz yöntemleri incelenmiş; daha sonra ileriye dönük elektrik üretim tahmini yapılması için çalışmamızda derin öğrenme yöntemlerinden biri olan LSTM (Uzun Kısa Süreli Hafıza) modelini kullanılmıştır. Örnek olarak yıllık 1 MW üretim kapasitesine sahip üç farklı bölgede bulunan örnek olarak seçilmiş üç adet GES üzerinden analiz edilmiştir. Bu modelin yanında zaman serisi analizlerinde kullanılan başka bir istatistiksel bir yöntem olan ARIMA (Oto-regresif Entegre Hareketli Ortalama) 'nın bir varyasyonu olan SARIMA (mevsimsel ARIMA) modeli ile kıyaslayıp sonuçlar değerlendirilmiştir. Bu çalışmanın sonrasında, seçmiş olduğumuz İç Anadolu ağırlıklı, Ege ve Akdeniz bölgelerinde

bulunan bazı GES'lerin üretim verimliliğine negatif yönde etki edebilecek faktörleri üzerinden yorum ve sonuç çıkarmaya çalışılması hedeflenmiştir.

## 1.1. Yenilenebilir Enerji Kaynakları

Yenilenebilir enerji; doğal kaynaklardan elde edilebilen, enerji akışı devamlı olarak sağlanabilen enerjidir diyebiliriz. Bu kaynak çeşitleri güneş santralleri, rüzgâr santralleri, hidrolik güç, biokütle enerjisi vb. örnekler çoğaltılabilir. Çalışmamızda GES bulunduğu için bu konu üzerinde durulmuştur.

### 1.1.1. Güneş enerjisi

Bu enerji türünde temel kaynak güneş olup, düzlemsel güneş kolektörleri, fotovoltaik (PV), konsantre güneş enerjisi (CSP), yapay fotosentez gibi teknolojilerden yararlanılarak enerji üretimi yapılmaktadır.

**Düzlemsel güneş kolektörleri;** güneş enerjisinin bir kısmını soğurarak bu enerjiyi ısı olarak kolektörler vasıtasıyla sıvıyı içeri ileten düzlemsel bir yapıdır. Evlerde, otellerde vs. sıcak su temini için kullanılır (Şekil 1.1).



**Şekil 1.1.** Su ısıtma için kullanılan, genelde çatılara konulan düz yüzeyli termal sistem (PMR\_Press\_Release, 2019)

**Fotovoltaik;** güneş pilleri veya dizinleri ile güneş ışığından elektrik elde etme yöntemidir (Şekil 1.2). PV ayrıca bu konuda yapılan çalışmalar için de kullanılan bir isimdir.

Elektrik üretimi için kristalin güneş hücresindeki alt tabaka, P tipi malzemeden (alüminyum, galyum, indiyum) herhangi biri ile kaplanarak yeşil boşlukları oluşturulur. N tipi üst tabaka ise antimon, arsenik ya da fosfor gibi gezgin elektronlar oluşturan kimyasal maddeler ile kaplanır. Amaç, elektronların üzerinde düşen ışığın, bu elektronları P bölgesine doğru harekete geçirmektir. PV devre düzenli olarak yapılandırılmış ise bu elektronlar devreyi çizilen hattan tekrar N bölgesine doğru tamamlar ve elektriği üretir.




Şekil 1.2. PV güneş panelleri (Dodge, 2018)

**Konsantre güneş enerjisi;** aynalar ve bu aynalara bağlı güneşi izleme sistemleri ile genişçe bir alana düşen güneş ışınlarını daha küçük bir ortama yansıtma prensibine dayanır. Küçük bir alana toplanan güneş ışınları klasik enerji santrallerine ısı kaynağı veya güneş panellerine odaklanarak elektrik enerjisi kaynağı olarak kullanılabilir (Şekil 1.3).



Şekil 1.3. PS10 Solar enerji kulesi, Sevilla (Flickr\_photo, 2007)

**Yapay fotosentez teknolojisi** (Şekil 1.4), bitkilerin fotosentez sisteminden esinlenerek oluşturulmuştur. Fotosentez kısaca; bitkinin yapraklarında bulunan klorofillerin güneş ışığından yararlanarak oksijen ortaya çıkardığı bir kimyasal tepkime sürecidir. Enerji üretiminin diğer yöntemlerine nazaran yapay fotosentez, birden çok yakıt türü üretme olanağına sahiptir. Fotosentetik işlem, ışık, CO<sub>2</sub> ve H<sub>2</sub>O arasındaki tepkimeler sonucunda sıvı hidrojen üretilmesini düzenleyebilir. Hidrojen ile çalışan makinelerde, sıvı hidrojen benzin gibi kullanılması mümkündür. Bunun yanında fotosentez işlemini tersine çevirip, hidrojen ve oksijenin suya katılarak elektrik oluşturacak bir yakıt sistemi kurulumuna da dönüştürülmesini sağlayabilir (Saraçoğlu, 2018).



Şekil 1.4. Yapay fotosentezin çalışma şeması (Yarris, 2015)

## 1.2. Yapay Zekâ

Yapay zekâ, bir bilgisayarın veya bilgisayar kontrollü bir robotun veya makinanın çeşitli işleri zeki canlılara benzer bir şekilde yerine getirme yeteneği olarak söylememiz mümkündür. İngilizcesi Artificial Intelligence olan kavramın kısaltılmış hali olan AI sözcüğü de bilgisayar biliminde sıklıkla kullanılmaktadır. Yapay zekâ genel olarak insanın düşünme metotlarını irdeleyerek bunun gibi yapay yönergeleri geliştirmeye yöneliktir.


### 1.2.1. Tarihçe

Yapay zekâ, modern bilgisayar bilimi kadar eskidir diyebiliriz. Alan Turing, “Makineler düşünebilir mi?” sorunsalını ortaya atarak bu kavramın fikir babası kabul

edilir. Kavramın ortaya çıktığı dönem ise 2. Dünya Savaşı'dır (1943). Savaş sırasında kriptoloji (şifreleme) analizi ihtiyacı için üretilen elektromekanik aygıtlar bilgisayar bilimi ve yapay zekâ kavramları ortaya çıkmıştır. Bu dönemden itibaren aşağıdaki (Çizelge 1.1) gelişmeler yapay zekâda dönüm noktaları olarak kabul edilmiştir (Şekil 1.5).

**Çizelge 1.1.** Yapay zekânın kısa tarihçesi (TRAI, 2018).


Olay	Açıklama
Bilgisayar ve Zekâ (1950)	Alan Turing, makinelerin düşünebilmesinin mümkün olup olmayacağını sorguladığı makalesini paylaşması, bir dönüm noktası yarattı.
Ben, Robot (1950)	Isaac Asimov, etkileri büyük olmuş "Ben, Robot" adlı bilim kurgu romanını yayınladı.
Yapay Zekâ ve Oyun (1951)	Manchester Üniversitesi'ne ait Ferranti 1 makinesini kullanan Christopher Strachey dama programı, Dietrich Prinz ise satranç programı yazdı.
John McCarthy (1955)	1956 yılındaki Dartmouth Konferansı için 1955 yılında McCarthy, Yapay Zekâ terimini ortaya koymuştur.
Perceptron (1957)	1957 yılında bilgisayar bilimci ve psikolog Frank Rosenblatt, canlı sinir hücrelerinden esinlendiği Perceptron (algılayıcı) modelini matematiksel olarak ortaya koymuştur.
Unimation (1962)	Unimation, endüstriyel anlamda 1962 yılında Amerika'da kurulan ilk robot şirkettir.
Marvin Minsky (1967)	Marvin Minsky, "Bir kuşak içinde 'yapay zekâ' oluşturma problemi çözülmüş olacak" tezini 1967'de ortaya atmıştır.
XOR Problemi (1969)	Martin Minsky ve Seymour Papert, "Algılayıcılar: Hesaplamalı Geometriye Giriş" kitabını yazmışlardır. XOR problemine değinmişlerdir.
Cylons (1973)	Orijinal "Battlestar Galactica" bilim kurgu dizisinde savaşçı robotlar Cylonlar tanıtıldı.
AAAI (1980)	1979 yılında kurulan Amerikan Yapay Zekâ Derneği (AAAI), ilk ulusal konferansını 1980 yılında Stanford'da düzenledi.
Deep Blue, Kasparov (1997)	IBM tarafından geliştirilen Deep Blue, 1997 yılında Garry Kasparov ile girdiği satranç karşılaşmasını kazandı.
Deep Neural Network (2006)	Ruslan Salakhutdinov ve Geoffrey Hinton "Yapay Sinir Ağları ile veri boyutunun azaltılması" isimli makalelerini 2006 yılında yayınlamışlardır.
Watson ve Jeopardy! (2011)	IBM'in Watson bilgisayarını, televizyon yarışması "Jeopardy!" şampiyonları Rutter ve Jennings'i yendi.
Apple Siri (2011)	Apple şirketinin 2011 yılında geliştirdiği Siri; telefon, tablet veya bilgisayar kullanıcılarının sorularını yanıtlamak, tavsiyelerde bulunmak ve web hizmetindeki eylemleri yerine getirmek için tasarlanmış bir akıllı kişisel asistandır.
GPU Çağı (2012)	GPU odaklı bir sistem, ImageNet veri tabanında en iyi hata oranını 2012 yılında yarıya indirerek birinci olmuştur.
Amazon Alexa (2014)	Yapay zekâ tabanlı ve bulut teknolojisini kullanan sanal bir asistan olan Amazon Alexa, 2014 yılında hizmete girdi.
AlphaGO (2016)	Google DeepMind tarafından geliştirilen AlphaGO, 2016 senesinde Lee Sedol ile karşılaştığı go maçını 4-1 kazanmıştır.
Asilomar (2017)	Asilomar Conference on Beneficial AI (Faydalı Yapay Zekâ), Future of Life Institute tarafından, 2017 yılında Kaliforniya'daki Asilomar Konferans Alanı'nda düzenlendi.



Şekil 1.5. Yapay zekânın genel tarihçesi (TRAI, 2018)

### 1.2.2. Makine öğrenmesi

Makine öğrenmesi, karşılaşılan problemin bu probleme ait ortamdaki bilgilerin (verilerin) doğrultusunda modelleme yapan bilgisayar algoritmalarının genel adıdır. 1950'li yıllarda "Makineler düşünebilir mi?" sorusunu ortaya koyan Alan Turing ile beraber makine öğrenmesini yapay zekanın bir alt kolu olarak görebiliriz. 1959 yılında makine öğrenmesi ismini koyan bilgisayar bilimci Arthur Samuel kabul edilir (Samuel, 1959). Makine öğrenmesinde bilinen öğrenme türleri ve bu türlere ait alt konu başlıkları Şekil 1.6'da gösterilmiştir.



Şekil 1.6. Makine öğrenmesi türleri ve genel şeması

Makine öğrenmesi (öğrenimi) öğrenme metoduna göre genel anlamda üç gruba ayrılmaktadır, Denetimli (Supervised), Denetimsiz (Unsupervised) ve Pekiştirmeli (Reinforcement) öğrenme.

### 1.2.2.1. Denetimli (Supervised) Öğrenme

Bu öğrenme türünde giriş verileri (etiketlenmiş veri) ile hedeflenen çıkış verileri arasında eşleştirme yapan bir fonksiyon oluşturur.

Sistemin adapte olabilmemesini sağlamak için verilerin bir kısmı ile eğitim yapılması gerekmektedir. Eğitim verisi, girdi ve çıktılardan oluşur. Bu fonksiyon, sınıflandırma ya da regresyon (eğri uydurma) algoritmaları ile belirlenir.

Veri setindeki çıktılar sürekli (veya nümerik) ise regresyon, kategorik ise sınıflandırma algoritmaları kullanılır (Şafak, 2017).

Örneğin elimizde bir bitki türünün hastalıklı ve sağlıklı olmak üzere iki farklı seçenek olduğunu varsayalım. Bu bitki türüne ait bitkilerin hastalık parametreleri sisteme dâhil edilip yeni bitki verisi ile kıyaslanıp hastalık tespitinin yapılabilmesi denetimli öğrenme kullanılarak gerçekleştirilebilir.

### 1.2.2.2. Denetimsiz (Unsupervised) Öğrenme

Bu metotta etiketlenmemiş (işaretlenmemiş) veri yardımı ile bilinmeyen bir yapıyı tahmin edebilmek için bir algoritma kullanan makine öğrenmesi modelidir.


Burada önemli olan konu giriş verisinin hangi sınıfa ait olduğu bilinmemesidir (Şafak, 2017).

Örneğin, bir bilgisayar kullanıcısının gezdiği sitelerde kullandığı tarayıcının kullanıcıya ilgisini çekebileceği bazı web sitelerini önermesi denetimsiz öğrenme modeli ile oluşturulabilir.

### 1.2.2.3. Pekiştirmeli (Reinforcement) Öğrenme

Amaç odaklı bir metot olduğu için diğer öğrenme türlerine göre farklılıklar içermektedir. Davranış psikolojisinden esinlenerek oluşturulan bir öğrenme yaklaşımıdır (Kaelbling ve ark., 1996). Bu problem genelliğinden dolayı oyun kuramı, kontrol kuramı, yöneylem araştırması, bilgi kuramı, istatistik vs. birçok konu ile de çalışmaktadır. MÖ'de ortam genelde bir Markov karar süreci (MDP) şeklinde belirtilir, bu bağlamda pek çok pekiştirmeli öğrenme algoritması dinamik programlama tekniklerini kullanır (Van Otterlo ve Wiering, 2012).

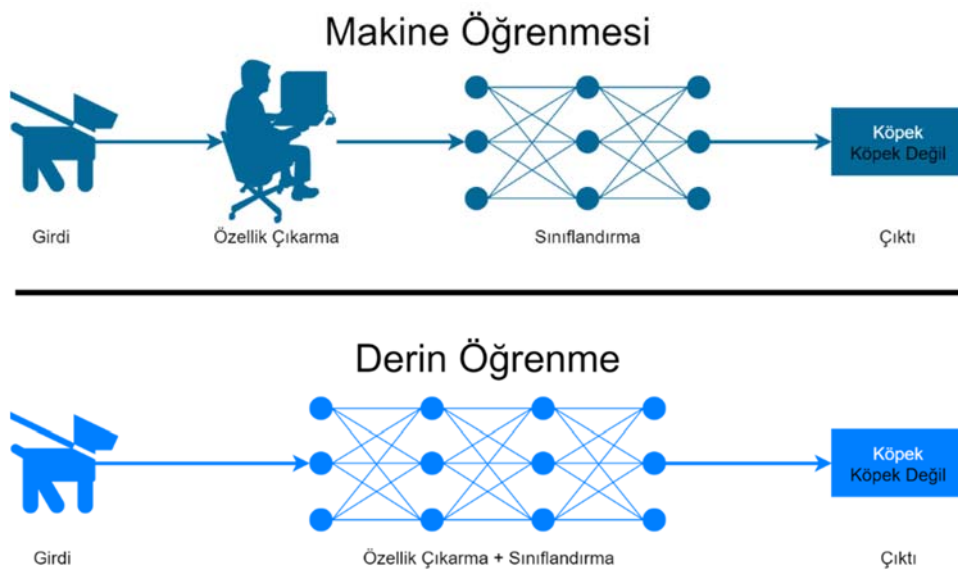
Pekiştirmeli öğrenmenin işleyişi Şekil 1.7’ de verilmiştir. Özne bir eylem içerisine girerek çevre ile etkileşime girer. Çevreyi gözlemledikten sonra yeni durumu ve kazandığı ödülleri analiz eder. Eylemler ve gözlemler döngü içerisinde sırayla birbirilerini takip eder (Kaelbling ve ark., 1996).



Şekil 1.7. Pekiştirmeli öğrenmenin işleyişi (Wikimedia\_Commons, 2017).


### 1.2.3. Derin öğrenme

Derin öğrenme, esasında makine öğrenme ailesinde yer alan ve yapay sinir ağlarını temel alan bir yaklaşımdır. Öğrenme; denetimli, yarı denetimli veya denetimsiz olabilir (LeCun ve ark., 2015). Temel anlamda makine öğrenmesinden farkı Şekil 1.8’de belirtildiği gibi özellik (veya öznetelik) çıkarımı işlemini (girdi olarak verilen ölçülmüş değerler üzerinden yeni türetilmiş değerler oluşturma) herhangi bir destek olmaksızın kendi sinir ağı içerisinde gerçekleştirebilmesidir.



Şekil 1.8. Makine öğrenmesi ile derin öğrenmedeki yapısal farklılıklar (Heidmann, 2019).

Yapay zekâ; sırası ile makine öğrenmesi ve derin öğrenmeyi kapsayacak şekilde tanımlanabilir (Şekil 1.9).



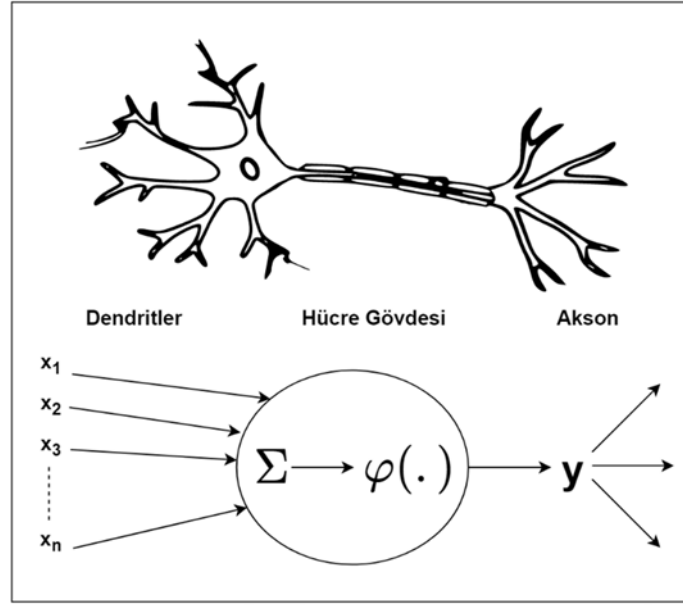
**Şekil 1.9.** Derin öğrenme yaklaşımının makine öğrenmesi ve yapay zekâ ile ilişkisi ( $DÖ \subset MÖ \subset YZ$ ) (Roy, 2019)

Yapay zekâ, makineler tarafından işletilen insanı zekâsı denilebilir. Makine öğrenmesi, yapay zekâyâ ulaşmak için bir araçtır. Derin öğrenme ise makine öğrenimini gerçekleştirmek için kullanılan bir yöntemdir (Proente, 2019).

### 1.2.3.1. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), araştırmacıların ilgi gösterdikleri bir konu olmakla birlikte bilgisayarların öğrenmesine yönelik çalışmaları içerir. Matematiksel olarak formüle edilmesi güç olan problemleri bilgisayarlar, sezgisel metotlar ile çözümlenmektedir.

YSA, insan (veya canlı organizma) beyninin özelliklerinden biri olan öğrenme yöntemini yeni bilgiler türetme, oluşturma ve keşfetme yeteneklerini destek almadan kendi kabiliyeti ile gerçekleştirme amacı ile geliştirilmiştir. Geleneksel programlama yöntemleri ile bu yetenekleri oluşturmak güçtür. Bu sorunun çözümünde YSA'nın adaptif bilgi işleme yeteneğinden yararlanılabilir. İnsan beyninin işleyişine benzer bir şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik çıkarımı, optimizasyon, gibi alanlarda oldukça güzel sonuçlar vermektedir. Örneklerden elde ettiği bilgiler ile kendi deneyimini oluşturabilir, benzer konularda benzer sonuçları çıkarabilirler (Öztemel, 2012). Şekil 1.10'da örnek bir sinir hücresi ve YSA modeli birlikte verilmiştir.

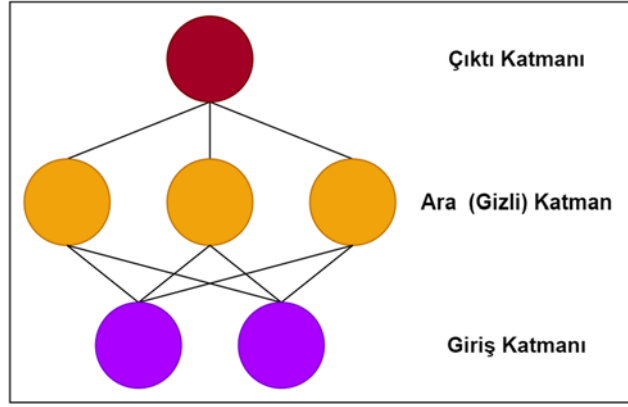


Şekil 1.10. Örnek nöron ve YSA hücresi (BrainCreators, 2017)

### 1.2.3.2. Derin Öğrenme Türleri

Derin Öğrenme temelde yapay sinir ağlarını temel almakta ve gelişen teknolojileri ile birlikte farklı varyasyonları ortaya çıkmaktadır. Daha öncede belirtildiği gibi öğrenme çeşitleri denetimli ve denetimsiz olarak ayrılmaktadır. Başlıca denetimli derin öğrenme türleri; YSA (Çok katmanlı algılayıcılar içeren), Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağlarıdır (RNN). Başlıca denetimsiz öğrenme türleri; Özdüzenleyici (veya özdüzenlemeli vb.) Haritalar (Self Organizing Maps - SOMs), Boltzman Makineleri, Otomatik Kodlayıcılar (AutoEncoders) şeklinde sıralayabiliriz.

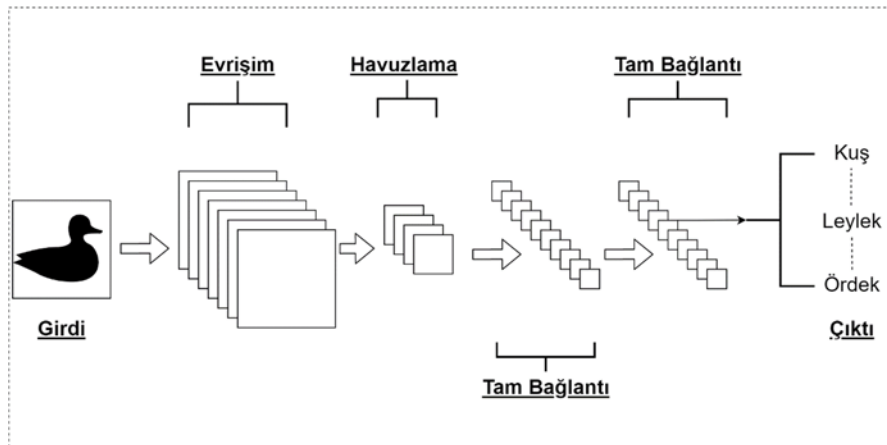
Denetimli öğrenmelerden ilki, **YSA – çok katmanlı algılayıcılar**. YSA konusu önceki bölümlerde de belirtilmiştir. Çok katmalı algılayıcı (Multi Layer Perceptron - MLP) modeli klasik sinir ağları yapısında 1957 yılında Rosenblatt tarafında ortaya atılmıştır. Bilinen en eski öğrenme türlerinden biridir ve bu konuda sayısız araştırma ve uygulamalar yapılmıştır. Algılayıcılar doğası gereği, bir insan beyninin öğrenme modelini taklit ederek bir dizi girdi vasıtası ile temel ikili kalıplara (binary pattern) uyum sağlamasına izin verir. Çok katmanlı algılayıcı (Şekil 1.11), ikiden fazla katmandan oluşan bir sinir ağı modelidir (Gupta, 2019).



Şekil 1.11. MLP'nin genel yapısı

**Evrışimli Sinir Ağları (CNN – Convolutional Neural Networks)**, klasik YSA'nın daha yetenekli ve gelişmiş bir sürümüdür. Veri ön işleme ve hesaplamada daha fazla karmaşıklığı ele almak için oluşturulmuştur.

CNN'ler görüntü verileri için tasarlanmış olup (Şekil 1.12), görüntü sınıflandırma problemlerinde başarılı sonuçlar verebilmektedir. CNN'ler ile görüntü dışı veriler için tasarlanmamış olsa da bu tip veri kümelerinin sınıflandırılmasında da etkileyici sonuçlar verebilir. Giriş verilerini modele aktardıktan sonra CNN'yi oluşturmak dört adımda gerçekleşir. İlk adım Convolution (Evrışim); girdilerin özellik haritalarının çıkarıldığı, sonrasında haritalara filtre uygulandığı bir süreç. İkinci adım Max-Pooling (Maksimum havuzlama); CNN modelimize “mekânsal değişmezlik” sağlar ve oluşturduktan sonra, toplanmış bir özellik haritası elde edilir. Üçüncü adım Flattening (Düzleştirme) CNN'in okuyabilmesi için veriler tek boyutlu diziyeye çevrilir. Son adım da Tam Bağlantı (Full Connection) modelimiz için kayıp (loss function) fonksiyonu da hesaplayan gizli katmandır (Gupta, 2019).



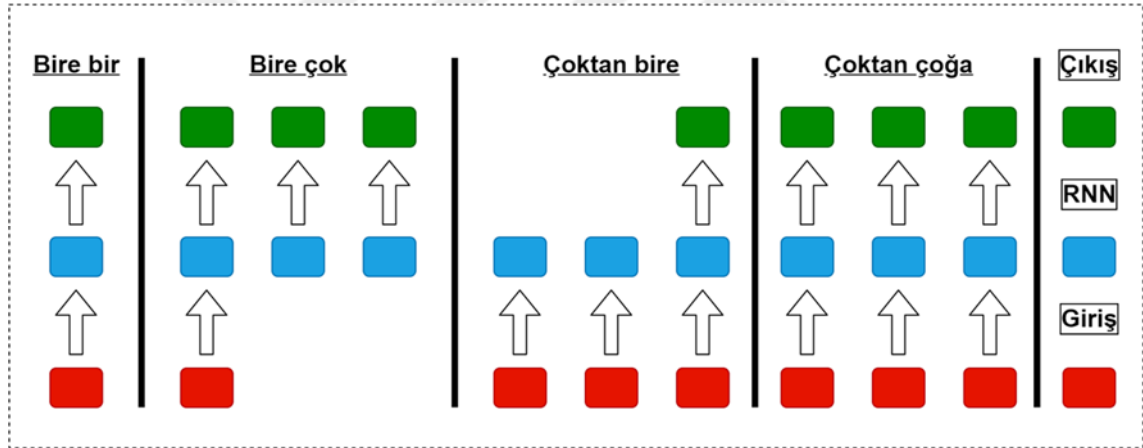
Şekil 1.12. CNN modelinin yapısı

**Tekrarlayan Sinir Ağları (RNN - Recurrent Neural Network)**, tahmin dizileri etrafında kullanılmak üzere oluşturulmuştur. LSTM (Uzun kısa süreli bellek) birçok olası kullanım durumuna sahip popüler bir RNN algoritmasıdır (LSTM modeli ilerleyen konularda detaylıca bahsedilecektir).

**Çizelge 1.2.** RNN'nin kullanıldığı durumlar

Tür	Açıklama	Örnek
1-1 (Bire bir)	Tek çıkış ile eşlenen tek giriş üretir	Görüntü sınıflandırma
1-N (Bire çok)	Bir dizi çıkış ile eşleşen tek giriş üretir	Görüntü altyazılama
N-1 (Çoktan bire)	Bir dizi giriş tek çıktı üretir	Duyarlılık analizi
N-N (çoktan çoğa)	Bir girdi dizi bir çıktı dizisi üretir	Video sınıflandırması (Videoyu çerçevelere bölme ve her kareyi ayrı ayrı etiketleme)

RNN'nin (Şekil 1.13) kullanıldığı durumlar Çizelge 1.2'de gösterilmiştir (Gupta, 2019).




**Şekil 1.13.** RNN'nin çeşitli yapıları (Gupta, 2019)

**Özdüzenleyici Haritalar (SOMs - Self-Organizing Maps)** denetimsiz veriler ile çalışır ve genelde boyut azaltmaya yardımcı olur. (Oluşturulan modelde bulunan rastgele değişken sayısına göre azalış gösterir.) SOM için çıktı her zaman iki boyutludur. Bundan ötürü ikiden fazla giriş özelliği olan verinin çıktısı iki boyuta düşürülür. Giriş ve çıkış düğümlerini bağlayan her sinaps, kendilerine atanan bir ağırlık içerir. Akabinde her veri noktası modelde temsil için mücadele eder. En yakın düğüme BMU (en iyi eşleşen birim best matching unit) denir ve SOM, BMU'ya yaklaşmak için ağırlıklarını günceller. Modelin ilerleyişi ile beraber BMU'nun komşuları azalır. Bir düğüm BMU'ya ne kadar olur ise ağırlıkları da o kadar fazla değişkenlik gösterir. Son

olarak ağırlıklar düğümün bir özelliği olup düğümün giriş alanında nerede olduğunu temsil etmektedir. YSA'nın tam tersine aktivasyon fonksiyonu bulundurmaz. Yaratıcı projeler (AI tarafından üretilen müzik, metin ve video), özellik algılama için boyut azaltma gibi konularda kullanılabilir.

Bundan önce bahsedilen dört modelin ortak noktaları bulunmaktadır. Bu modeller belirli bir yönde çalışmaktadır. SOM'lar denetimsiz veriler ile çalışıyor olsa da denetimli modellere benzer bir şekilde belirli bir yönde çalışmaktadır. Yani girdi, gizli katman(lar) ve çıktı yolu izlenir.

**Boltzmann Makineleri (BM)**; belirli bir yön takip etmemekle beraber, tüm düğümler Şekil 1.14'te belirtildiği gibi dairesel bir hiperuzayda birbirilerine bağlanır.

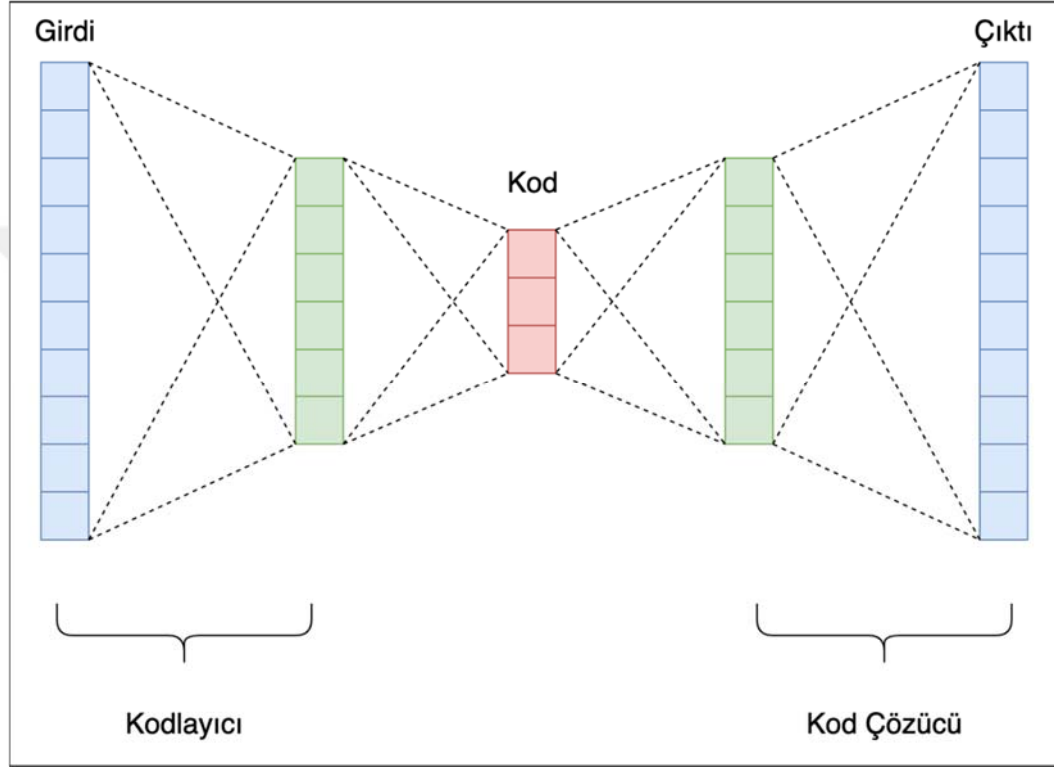


Şekil 1.14. Örnek bir Boltzmann Makinesi

Bu tarzdaki bir model stokastik (rastgele belirlenir) olarak adlandırılır ve yukarıdaki tüm deterministik modellerden farklıdır. Sınırlı Boltzmann Makineleri daha pratik olduğu tespit edilmiştir. BM, bir sistemi izlerken (model, düzenlemeyi zamanla öğrenecektir), ikili öneri sistemi oluştururken ya da çok özel bir veri kümesi ile çalışırken kullanılabilir (Gupta, 2019).

**Autoencoders (Otokodlayıcılar ya da otomatik kodlayıcılar)**, verileri giriş değerlerine göre kodlar sonrasında bir etkinleştirme işlevi gerçekleştirir ve son olarak verilerin çıktı için kodunu çözer (Şekil 1.15). Giriş özellikleri bir tür darboğaz (bottleneck) içinden geçirilerek daha az kategoriye sıkıştırılır. Bundan ötürü veriler

içinde bazı doğal yapılar var ise otokodlayıcı modeli çıktığı almak için onu tanımlayacak ve kaldıracaktır. Gürültü giderici, seyrek, varyasyonel, büzülme (contractive) ve yığılı türde otokodlayıcı çeşitleri mevcuttur. Bu model; veri boyutu küçültmede (özellik algılama işlemi), güçlü öneri sistemi oluşturmada (BM'den daha güçlü) ve devasa veri kümelerinde kodlama özelliği olarak kullanılmaktadır (Gupta, 2019).



Şekil 1.15. Örnek otokodlayıcı model şeması

### 1.3. Zaman Serisi, Analizi ve Yöntemleri

Zaman serisi, istatistik, ekonometri, sinyal işleme, sismoloji, meteoroloji, matematiksel finans vb. alanlarda veri noktalarının sıklığını ifade etmekte olup düzenli zaman aralıklarında ve ardışık zaman alanlarında ölçülür. Örneğin BİST (Borsa İstanbul) endeksinin günlük kapanış değeri veya Türk Hava Yolları'nın günlük yolcu kapasitesini örnek olarak verebiliriz. Zaman serileri türüne göre tek değişkenli (univariate) ve çok değişkenli (multivariate) olmak üzere ikiye ayrılır. Tek değişkenli seriler, tek bir özellik içerirken (örneğin meteorolojide sadece radyasyon verisi) çok değişkenli seriler, birden fazla özellik (meteorolojide sıcaklık, basınç, radyasyon, rüzgâr hızı veya ışınım süresi) barındırabilmektedir.

Zaman serisi tahmini önceden bilinen belirli olayları temel alarak gelecek olayları tahmin (prediction) etmenin kavramsal bir modelidir. Ekonometride zaman serisi tahminine örnek olarak, önceki performanslarına bakılarak bir hisse senedinin açılış fiyatının öngörülmesidir (Lütkepohl ve ark., 2004).

### 1.3.1. Zaman serisi analizleri

Zaman serileri analizi, tahminlerde bulunmak ve serinin gelecekteki değerlerini tahmin etmek için kullanılır. Özellikle YZ alanında, zaman serisi analizi için kullanılan algoritmalar arasında Saklı Markov Modelleri (Hidden Markov Model - HMM), Tekrarlayan Sinir Ağları (RNN), LSTM sinir ağları ve SVM'ler (Destek Vektör Makinaları – Support Vector Machines) bulunmaktadır (Commission, 2018).

### 1.3.2. Zaman serisi yöntemleri

Farklı amaçlar için uygun zaman serilerinde kullanılan bazı analiz yöntemleri verilmiştir.

#### 1.3.2.1. Basit ortalama yöntemi

Bu yöntem, tahmin edilmek istenen değişkenin (Y) geçmiş dönemlerde aldığı değer ortalamalarının alınması ile tahmini değerler bulunmaktadır. Yöntemin hesabı denklem 1.1'deki gibidir.

$$\hat{Y}_i = \frac{\sum_{i=1}^n Y_i}{n} = \bar{Y} \quad (1.1)$$

#### 1.3.2.2. Hareketli ortalamalar yöntemi

Bu metotta Y değişkeninin bir sonraki döneminde alacağı tahmini değer, aynı değişkenin geçmiş “n” dönemdeki ortalamasının alınması ile bulunur. Yöntemin hesabı denklem 1.2'deki gibidir.

$$\hat{Y}_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (1.2)$$

Bu yöntemde n değerinin seçimi konusunda herhangi bir kural yoktur. Genelde 2 ile 7 arasında değişen farklı n değerleri seçilerek, en düşük ortalama tahmin hatasını

(tahmin değerleri ile gerçek değerler arasındaki fark) veren  $n$  değeri tercih edilir. Bu yöntem, ARIMA analizinde bahsedilmiştir.

### 1.3.2.3. Ekspansiyel (Üssel) düzgünleştirme yöntemi

Bu yöntemin amacı,  $Y$  değişkeninin  $i$  döneminde alacağı tahmini değer, bir önceki döneme ait gerçekleşen değeri  $\alpha$  ile ve bir önceki tahmini değeri  $(1-\alpha)$  ile çarpılarak birbirine eklenmesi yoluyla hesaplanır ve  $\alpha$  için 0 ile 1 arasından değer seçilir. Bunun yanı sıra 1. Dönem tahmin değeri ( $\hat{Y}_1$ ) genelde 1. Dönem gerçekleşen değer olarak seçilir.

$$\hat{Y}_i = \alpha Y_{i-1} + (1 - \alpha) \hat{Y}_{i-1}, \quad 0 \leq \alpha \leq 1 \quad (1.3)$$

### 1.3.2.4. Trend analizi yöntemi

Bu metodun basit doğrusal regresyon (bağlanım) yönteminden tek farkı,  $X$  bağımsız değişkenin zaman olmasıdır. Basit doğrusal regresyon yönteminde olduğu gibi bu yöntemde de  $a$  ve  $b$  değerleri hesap edilerek ( $X$  değişkeni olarak yıllar ya da  $i$  sütunu alınarak)  $Y = a + bX$  denklemi bulunur.

### 1.3.2.5. Mevsimsel dalgalanmalar ve trende ortalamalar yöntemi

Bu yöntemde yıllık ve dönemlik olarak verilmiş tarihi (gerçekleşen) değerler önce dönemsel ayrıma uğramadan (her dönemin aynı kabul edildiği varsayılır) trend (eğilim) analizine tabii tutulur. Bu şekilde, talebin genelde (mevsimlik etkileri hesaba dâhil etmeden) nasıl bir trend (artan veya azalan eğilim) içerisinde olduğu tespit edilir. Daha sonra, mevsimlik etkiler dikkate alınır ve her mevsim için geçmiş verilerin trendin ne kadar altında veya üzerinde gerçekleştiği ortalama olarak hesaplanır. Her mevsim için tespit edilen bu ortalamalar (trend - eğilim içinde olanlar) gelecek sene için yapılacak tahminde kullanılır (Yavuz, 2017).

Üçüncü bölümde zaman serisi analizinde kullanılacak olan LSTM ve ARIMA yöntemlerinden detaylıca bahsedilmiş ve bu yöntemler ışığında verilerimiz değerlendirmeye alınmıştır.

Bu tez çalışmasında yukarıda bahsedilen derin öğrenme yöntemlerinden LSTM kullanılarak güneş enerjisi santrallerinde elektrik üretimi tahmini yapılmıştır.

## 2. KAYNAK ARAŞTIRMASI

Bu kısımda derin öğrenme ve yapay zekâ teknikleri kullanılarak güneş enerjisi, rüzgâr enerjisi, hava tahminleri, iklim değışiklikleri vs. yapılmış olan bazı akademik çalışmalara değinilmiştir. Kaynak taraması alfabetik sırada verilmiştir.

Abdel-Nasser ve Mahmoud (2017) yaptıkları çalışmada, PV sistemlerin çıkış gücünü doğru bir şekilde tahmin edilmesi için (LSTM-RNN) yöntemini kullanmışlardır. Önerdikleri yöntem, farklı sitelerden elde edilen yıllık veri setlerini kullanmışlardır. Üç farklı PV tahmin yöntemi (çoklu doğrusal regresyon (MLR), torbalı regresyon ağaçları (BRT) ve sinir ağları) ile kıyaslama yaptıklarında LSTM’de öngörme hatasının daha düşük çıktığını belirtmişlerdir.

Agrawal ve ark. (2018) yapmış oldukları çalışmada, saatlik çözünürlükte uzun vadeli yük tahmini için yeni bir yöntem önermişlerdir. Modeli LSTM-RNN hücrelerinden oluşan tekrarlayan sinir ağı üzerine odaklamışlardır. Elektrik yükü talebinin zaman serisi verilerindeki uzun vadeli ilişkileri LSTM-RNN kullanarak dikkate almışlar doğru tahminlerle sonuç elde etmişlerdir. Bu modeli ISO New England elektrik piyasasının gerçek zamanlı verilerine uyarlamışlardır. 2004’ten 2015’e kadar on iki yıllık kamuya açık verilerle modeli eğitmek ve doğrulamak için toplamışlar ve elektrik talebi tahminleri 2011’den 2015’e kadar beş yıllık süre boyunca yuvarlama esasına göre yapmışlardır. Önerdikleri model %2,25’lik güven aralığında 6,54 Ortalama Mutlak Yüzde Hatası (MAPE) ile doğru tahmin ettiklerini belirtmişlerdir.

Balluff ve ark. (2015), RNN kullanarak rüzgâr hızı ve basıncını tahmin etmişlerdir. Kuzey Avrupa’da (Büyük Britanya, İrlanda, Fransa, Almanya, Danimarka) kurulu olan rüzgâr santrallerinin verilerinden faydalanmışlardır.

Cenek ve ark. (2018), Alaska bölgesi enerji ihtiyacına yönelik ön çalışma yapmışlardır. Birincil kaynak olarak fosil yakıt temelli enerji jeneratörleri kullanılan Alaska bölgesinde son zamanlarda yenilenebilir enerji sistemlerinden de faydalanmaya başlanmıştır. Çoklu enerji kaynaklarının entegrasyonu ve optimizasyonu, topluluğun ne kadar elektrik çekeceğini ve fosil yakıt bazlı kontrolü sağlamak için yenilenebilir kaynaklardan ne kadar elektrik üretileceğini öngörebilecek bir güç yönetim sistemi

tasarımına ihtiyaç duyulmaktadır. Cenek ve ark. (2018), bu sorunu gidermek için, yeni nesil mikro şebeke güç yönetim sisteminde talep edilen gücün bir modül olarak çekilmesini öngören hibrit makine öğrenme algoritması tasarlanmıştır. Algoritma, bir güç yükü tahminini iki alt modele ayırmaktadır. Birinci model, gelecekteki hava koşullarını tahmin etmekte olup ikinci model de öngörülen hava koşullarını toplumun güç talebiyle ilişkilendirmek için eğitilir. Sonuçta model eğitimi ve doğrulama için küçük veriler kullanan makine öğrenme algoritması uygulanabilmekte, dinamik hava koşullarına sahip ortamlarda faaliyet gösteren mikro şebekeler için yakın gelecekte topluluğun talep edeceği güç yükünü tahmin etme kabiliyetini ve çok sayıda düşük kaliteli gelecekteki hava koşullarını, yüksek hassasiyetli güç yükü tahmini ürettiğini belirtmişlerdir.

Gensler ve ark. (2016) bu çalışmada, 21 GES'in enerji çıkışının tahmininde standart bir MLP'ye ve fiziksel bir tahmin modeline kıyasla tahmin güçlerini göstermek için bu algoritmanın kombinasyonlarını kullanmışlardır. Derin Öğrenme algoritmaları kullanılan sonuçlar Yapay Sinir Ağları ile fiziksel modeller gibi diğer referans modellerine kıyasla daha üstün bir tahmin performansı gösterdiği belirtilmiştir.

Huang ve Kuo (2018), hava kirliliği üzerine ön çalışma yapmışlar ve tahmin algoritması geliştirmişlerdir. Modern toplumda, hava kirliliği bu kirlilik insan sağlığı ve çevre üzerinde kritik derecede kötü bir etki yarattığı için önemli bir konudur. Hava kirliticiler arasında Partikül Madde (PM<sub>2.5</sub>), çapı 2,5 µm'ye eşit veya daha az olan askıya alınmış parçacıklardan oluşur. PM<sub>2.5</sub> kaynakları, kömür yakıtlı elektrik üretimi, duman veya tozlar olabilir. Havadaki bu asılı parçacıklar, insan vücudunun solunum ve kardiyovasküler sistemlerine zarar verebilir; bu da astım, akciğer kanseri veya kardiyovasküler hastalıklar gibi başka hastalıklara yol açabilir. Huang ve Kuo (2018) yaptıkları çalışmada, PM<sub>2.5</sub> konsantrasyonunu izlemek ve tahmin etmek için, Konvolüsyonel Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM) birleştirmiş ve PM<sub>2.5</sub> tahmin sistemine uygulanmıştır. Her algoritmanın genel performansını karşılaştırmak için, bu çalışmada yapılan deneylere dört ölçüm endeksi, Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hatası (RMSE) Pearson korelasyon katsayısı ve Uyum İndeksi (IA – Index of Agreement) uygulanmıştır. Diğer makine öğrenme yöntemleriyle karşılaştırıldığında, deneysel sonuçlar, önerilen CNN LSTM modelinin

(APNet) tahmin doğruluğunun bu yazıda en yüksek olduğu ve doğrulandığı belirtilmiştir.

Karabacak ve Cetin (2014) yaptıkları araştırmada; PV ve rüzgâr enerjisinden oluşan hibrit yenilenebilir enerji sistemlerinde, YSA uygulamalarına değinmişlerdir. Sinir ağı modelinin bu tip sistemlerdeki faydalarından bahsetmişlerdir.

Büyük ölçekli toplu konut yükü dışında, tek bir enerji kullanıcısının elektrik yükünü tahmin etmek, söz konusu yüksek oynaklık ve belirsizlik nedeniyle oldukça zordur. Kong ve ark. (2017) bu çalışmada, bu zor meselenin üstesinden gelmek için en popüler derin öğrenme tekniklerinden biri olan uzun süreli kısa süreli bellek (LSTM) tekrarlayan sinir ağı (RNN) tabanlı bir çerçeve önermişlerdir. Önerilen çerçeve, performansın, yük tahmini alanındaki son teknoloji ürünü de dâhil olmak üzere çeşitli kıstaslar ile kapsamlı bir şekilde karşılaştırıldığı, kamuya açık gerçek konut akıllı sayaç verileri seti üzerinde test edilmiştir. Sonuç olarak, önerilen LSTM yaklaşımı, bireysel konutlar için kısa vadeli yük tahmini görevinde listelenen diğer rakip algoritmalarından daha iyi performans gösterdiği açıklanmıştır.

Lee ve Kim (2019), PV'lerin güç tahminine yönelik hibrit bir sistem ortaya koymuşlardır. Son zamanlarda, PV gücünün öngörülmesi, PV operatörlerinin beklenen gelirini ve PV tesislerinin etkin operasyonlarını geliştirmek için büyük önem kazanmıştır. Ek olarak, saatlik olarak kesin PV güç çıkışı tahmini, yenilenebilir enerji pazarındaki elektrik fiyatı sürekli değiştiğinden PV operatörleri ve pazarlar için daha karmaşık stratejiler sağlar. Bununla birlikte, PV güç çıkışlarının saatlik tahmini, meteorolojik bilginin sadece bir günde değil, aynı zamanda günlerce dinamik doğası nedeniyle zorlu bir problem olarak kabul edilir. Bu çalışmada (Lee ve Kim, 2019), yapay sinir ağı (YSA) - derin sinir ağı (DNN) - ve uzun ve kısa süreli bellek (LSTM) tabanlı modelleri anlayabilen üç adet PV güç çıkışı tahmin yöntemi önerilmiştir. Önerilen LSTM tabanlı model, bir günde hem saatlik desenleri hem de gün boyunca mevsimsel desenleri yakalamak için tasarlanmıştır. Deneyleri gerçek veri seti kullanarak yapılmıştır. Deneysel sonuçlar, önerilen YSA temelli modelin tatmin edici sonuçlar veremediğini ve önerilen LSTM temelli modelin, ortalama kesin hata açısından, geleneksel istatistiksel modellere kıyasla %50'den daha iyi bir performans gösterdiğini belirtmiştir.

Li ve ark. (2016), Florida'daki 15 dakika, 1 saat ve 24 saat güneş PV sisteminden enerji üretimlerini öngörmek için yapay sinir ağları (YSA) ve destek vektör regresyonunu (SVR) ile bu iki ortak yöntemi değerlendirip ve karşılaştırmışlardır. Test edilen makine öğrenme algoritmalarına dayanarak hiyerarşik bir yaklaşım önerilmiştir. Bu çalışmada kullanılan üretim verileri, 2014'ten toplanan ortalama 15 dakikalık ortalama güç ölçümlerine karşılık gelmektedir. Modelin doğruluğu, ortalama yanlılık hatası (MBE), ortalama mutlak hata (MAE), kök ortalama kare hatası (RMSE), göreceli MBE (rMBE), ortalama yüzde hatası (MPE) ve göreceli RMSE (rRMSE) metrikleri ile tespit. Bu çalışma, bireysel invertörlerden gelen tahminlerin PV sisteminin toplam güneş enerjisi üretim tahminini nasıl iyileştireceği konusunda bulgular sunmaktadır.

Bu makalede (Marino ve ark., 2016), Derin Sinir Ağları, özellikle Uzun Kısa Süreli Bellek (LSTM) algoritmalarına dayanan yeni bir enerji yükü tahmin metodolojisi sunulmuştur. Çalışma, iki LSTM tabanlı mimariyi araştırmakta: 1) standart LSTM ve 2) LSTM'ye Dayalı Sıra Dizisi (S2S) mimarisi. Her iki yöntem de bir konut müşterisinden elde edilen kıyaslama verileri ile elektrik tüketimi verileri seti üzerinde uygulanmıştır. Her iki mimaride bir saat ve bir dakikalık bir zaman adımli veri setleri üzerinde eğitilmiş ve test edilmiştir. Deneysel sonuçlar göre ikinci yöntem, bir dakikalık çözünürlük verilerinde iyi performans gösterirken diğer yöntemin bir dakikalık çözünürlük verilerinde başarısız olduğu belirtilmiştir. S2S mimarisinin her iki veri kümesinde de iyi performans gösterdiği gösterilmiştir. Ayrıca, sunulan yöntemlerin literatürdeki enerji tahmini için diğer derin öğrenme yöntemleriyle karşılaştırılabilir sonuçlar ürettiği gösterilmiştir.

Paterakis ve ark. (2017), geleneksel makine öğrenme yaklaşımlarına kıyasla daha ileri düzeyde, toplam enerji tüketimini doğru bir şekilde tahmin etmek amacıyla derin öğrenme yöntemleri incelemiştir. Özellikle, son zamanlarda derin öğrenme yetenekleriyle geliştirilmiş olan Çok Katmanlı Algılayıcıların kullanılması önerilmiştir. Ayrıca, Performansı Destek Vektör Makineleri, Gauss İşlemleri, Regresyon Ağaçları, Topluluk Güçlendirme ve Doğrusal Regresyon gibi en yaygın kullanılan makine öğrenme yöntemleri ile karşılaştırılmıştır. Günün ileri enerji tahmininin analizi, farklı tahmin yöntemlerinin, tüketicilerin, rüzgâr ve güneş üretiminin ilginç bir karışımını içeren zorlu bir veri kümesi durumunda önemli ölçüde farklı doğruluk seviyeleri

gösterdiği tespit edilmiştir. Sonuçta Çok Katmanlı Algılayıcılar, bu çalışmada referans olarak kullanılan sekiz yöntemden daha iyi performans göstermiştir.

Sharadga ve ark. (2020) yaptıkları çalışmada, istatistiksel yöntemler ve yapay zekâyâ dayalı olanlar da dâhil olmak üzere birkaç zaman serisi tahmin yöntemi tanıtmış ve PV güç çıkışı tahmini için titizlikle karşılaştırmışlardır. Ayrıca, tüm algoritmalar için tahmin zaman ufku varyasyonunun etkisini araştırmışlardır. Mevcut çalışmada kullanılan veriler, Çin'deki 20 MW şebekeye bağlı bir PV istasyonundan alınan 3640 saatlik çalışma verisini içermektedir.

Şencan (2018) yaptığı çalışmada LSTM kullanarak kısa vadeli elektrik fiyat tahmini yapmıştır. Oluşturduğu modelde tarihsel elektrik fiyat değerlerini girdi olarak kullanmıştır. Kullandığı veriler, Türkiye'nin 2015, 2016 ve 2017 yıllarına ait saatlik elektrik fiyatlarıdır. Çalışmasında kullandığı verileri yaz ve kış mevsimleri için eğitim ve test olmak üzere ikiye bölmüştür. Kullandığı yöntemi RNN ve Üstel Düzeltme yöntemlerinin performansı ile karşılaştırmıştır. LSTM yöntemi kullanarak elde ettiği MAPE değerleri; kış için %5,91 yaz için %5,77'dir.

### 3. MATERYAL VE YÖNTEM

Çalışma, bilgisayar üzerinden belirli yazılım araçları kullanılarak uygulanmıştır. Kullanılan bilgisayarın genel özellikleri Çizelge 3.1 de belirtilmiştir.

**Çizelge 3.1.** Kullanılan bilgisayarın genel özellikleri

Donanım İsmi	Donanım Özellikleri
İşlemci	AMD Ryzen 1500X 3.5 GHz
Ekran Kartı	NVIDIA GeForce GTX 1050Ti 4GB GDDR5
Bellek	16 GB (8+8) 3000 MHz

Bu makine üzerinde kurulan yazılım araçları (uygulama ve kütüphaneler), GES'lere ait olan veri setleri ve kullanılan olan yöntemlerin neler olduğu ve detayları ile birlikte alt başlıklar şeklinde açıklanacaktır.

#### 3.1. Yazılım Araçları

Bu bölümde tezde kullanılan uygulamalar ve yazılım kütüphaneleri derin öğrenme ve istatistiksel analiz için gerekli materyalleri içermektedir. Bu materyaller, istatistiksel çalışmalarda sıklıkla kullanılması, örnek uygulamalarının fazla olması ve erişim kolaylığı nedeniyle tercih edilmiştir.

##### 3.1.1. Python

Python, nesne yönelimli, modüler ve etkileşimli yüksek seviyeli bir programlama dilidir. 1990 yılında Guido van Rossum tarafından tasarlanan bu dili Python Yazılım Vakfı geliştirmektedir.

Modüler yapısı ve her türlü veri alanı girişini destekler. Hemen her türlü platformda çalışabilir (Donat, 2015).

##### 3.1.2. Anaconda Navigator

Anaconda, veri bilimi vb. uygulamalar için Python destekli bir tümleşik Python dağıtımdır. Yapay zekâ ve veri bilimi alanlarında çokça kullanılan kütüphanelerin yanı sıra Jupyter Notebook ve Spyder gibi araçları da sisteminde barındırır. Spyder, Python dilinde yazılmış ve bu dilde geliştirme için kullanılabilen açık kaynak bir geliştirme ortamıdır. Aynı şekilde Jupyter Notebook da bir geliştirme ortamı olup web tabanlı bir

ara yüze sahiptir. Bu uygulamalar; genellikle bilim insanları, veri bilimcileri, istatistikçiler ve mühendisler tarafından tercih edilmelerine karşın öğrenciler ve bağımsız olarak Python’da kod yazan geliştiriciler de kullanabilmektedir (Kaplan, 2019).

Anaconda Navigator ise Anaconda dağıtımını içerisinde bulunan ve geliştiricilerin komut satırı kullanmaksızın uygulama başlatması conda (Python’da kullanılan paket yöneticisi) paketlerini, ortam ve kanallarını yönetmesini sağlayan bir masaüstü grafik kullanıcı arabirimidir (Anaconda\_Navigator, 2020).

### **3.1.3. Numpy kütüphanesi**

Numpy (Numerical Python); Python destekli olup bilimsel hesaplamalar yapılmasına ve yüksek seviyeli matematiksel fonksiyonların oluşturulmasına yardımcı olmak için daha az satırda kod yazımı ile çok boyutlu diziler ve matrislerin oluşturulmasına destek veren, araştırmacılar ve bilim insanları tarafından sıklıkla kullanılan bir açık kaynak kütüphanedir.

### **3.1.4. Matplotlib kütüphanesi**

Veri görselleştirme (Data visualization) için kullanılan bir açık kaynak Python kütüphanesidir. İki veya üç boyutlu grafik çizimleri için kullanışlıdır. Numpy ile uyumlu çalışır. Birçok farklı grafik türlerini (Çizgi, sütun, daire, görüntü işleme vb.) destekler.

### **3.1.5. Tensorflow kütüphanesi**

Google firmasının geliştiriciliğini yaptığı sinir ağları ve makine öğrenimi için kullanılan ücretsiz ve açık kaynak bir kütüphanedir. Sinir ağlarında kullanılan Keras ve makine öğrenimi için kullanılan scikit-learn gibi kütüphaner ile uyumlu bir şekilde çalışır. Google, Tensorflow’un ikinci sürümünde Keras’ı sisteme dâhil etmiştir.

### **3.1.6. Pandas kütüphanesi**

Veri analizi ve manipülasyonu için kullanılan Python dilinde yazılmış açık kaynak bir kütüphanedir. Verileri proje içerisine aktarmak için oldukça kullanışlıdır ve csv, txt, xls vb. formatları destekler. “Dataframe” ve “Series” tipinde çalışır. Genellikle makine öğrenimi için “dataframe” leri kullanır. “Dataframe” leri, ilişkisel veri tabanı sistemlerinde tablolar gibi düşünebiliriz. Tabloda veri işlemleri gibi örneğin; sütun, satır

ekleme veya silme, tabloları birleştirme, ayırma gibi süreçleri pandas, “Dataframe” ler için kullanır.

### 3.1.7. Keras kütüphanesi


Python’da yazılmış açık kaynaklı bir sinir ağı kütüphanesi olup derin öğrenme için kullanılır. Tensorflow ile beraber çalışabilir. Google mühendisi François Chollet tarafından geliştirilmiştir. CNN ve RNN gibi derin sinir ağları tasarımında kullanılır (Keras, 2020).

### 3.1.8. Statsmodels kütüphanesi

Statsmodels, birçok farklı istatistiksel modelin hesaplanması, istatistiksel testler ve istatistiksel veri keşfi için sınıflar ve işlevler sağlayan Python kütüphanesidir. Her tahmin için kapsamlı bir sonuç istatistik listesi mevcuttur. Sonuçların doğrulunu test etmek için mevcut istatistiksel paketlere karşı test edilir (Seabold ve Perktold, 2010).

## 3.2. Veri Setleri


Çalışmada Konya’nın farklı konumlarında bulunan ve her birinin kurulu güçleri 1MW olan GES’lere ait dört adet veri seti incelenmiştir. Bu santraller Konya’nın Çumra, Tuzlukçu, Yunak ve ilçelerinde bulunmaktadır. Bu dört veri setinden üçünün frekansları günlük olmak üzere her biri toplam iki yıllık, sonuncusunun frekansı saatlik olup yaklaşık olarak bir yıllık elektrik üretim verisi (kWh) bulunmaktadır. Bu veriler tek değişkenli zaman serilerinden oluşmaktadır. Veriler INSOS Enerji’den alınmıştır. Şekil 3.1’de GES’lerin konumu gösterilmiştir.



Şekil 3.1. Çalışma için kullanılan GES’lere ait konumlar


Bu kısımdan itibaren çalışmamızda Çumra santrali, Santral\_A (günlük frekanslı), Tuzlukçu santrali, Santral\_B (günlük frekanslı), Yunak santrali, Santral\_C (günlük frekanslı) ve son olarak saatlik veri içeren aynı Çumra santrali; bu sefer Santral\_D (saatlik frekanslı), olarak isimlendirilecektir.

Santral\_A'ya ait elektrik üretim veri grafiği Şekil 3.2'de gösterilmiştir. 800 günlük veri içermektedir.




Şekil 3.2. Santral\_A'ya ait elektrik üretim veri grafiği (Günlük frekanslı)

Santral\_B'ye ait elektrik üretim veri grafiği Şekil 3.3'te gösterilmiştir. 730 günlük veri içermektedir.



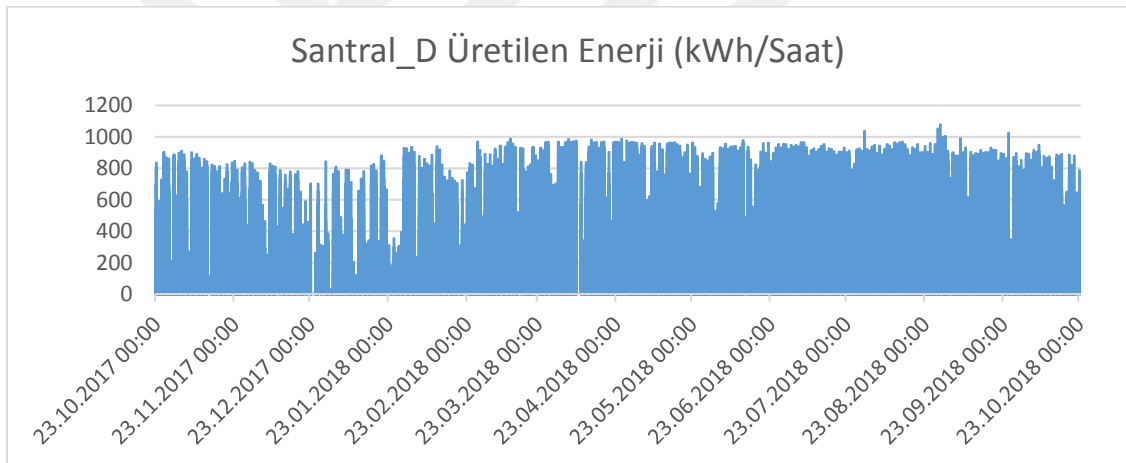
Şekil 3.3. Santral\_B'ye ait elektrik üretim veri grafiği (Günlük frekanslı)

Santral\_C'ye ait elektrik üretim veri grafiği Şekil 3.4'te gösterilmiştir. 730 günlük veri içermektedir.



Şekil 3.4. Santral\_C'ye ait elektrik üretim veri grafiği (Günlük frekanslı)

Santral\_D'ye ait elektrik üretim veri grafiği Şekil 3.5'te gösterilmiştir. 8777 saatlik veri içermektedir.



Şekil 3.5. Santral\_D'ye ait elektrik üretim veri grafiği (Saatlik frekanslı)

Santral\_D'de, esasında Çumra santralinden türetilen ve saatlik frekans içeren veri seti bulunmaktadır. Karışıklık olmaması için Santral\_D ismi verilmiştir. Üç veri setinin günlük frekanslı, dördüncü veri setinin saatlik frekanslı seçilmesinin nedeni; veri yoğunluğunun diğer veri setlerine göre daha fazla olması dolayısı ile sistemin buna nasıl cevap vereceğinin analizidir. Derin öğrenmede veri yoğunluğunun fazla olması sistemin eğitiminde ve tahmin mekanizmasında önemli bir husustur. Konya'nın yüzölçümü olarak büyük olması, yıllık güneş sıcaklık ve radyasyon miktarının önemli düzeylerde olması (mgm.gov.tr, 2018) bakımından bu bölgedeki veriler seçilmiştir.

### 3.3. Veri Tahmin Yöntemleri, Performans Ölçümleri ve Hiper-parametreler


Bu bölümde; veri setlerinin eğitim ve tahmini için kullanılan yöntemlere, performans ölçümlerine, hiper-parametreler ve zaman serisi konularına değinilecektir.

#### 3.3.1. RNN-LSTM ilişkisi

LSTM ağları, bilginin depolanabileceği kapı hücreleri olarak adlandırılır. Tahmin sırasında hücre hangi bilgilerin saklanacağına, kullanılacağına veya unutulacağına karar verir. Giriş ve çıkış kapıları, bilgilerin eğitimli ağırlıklara göre geçmesine veya engellenmesine olanak tanır. Bu mimari; akım girişini, önceki durumu ve hücrenin hafızasını birleştirerek, veri kümelerindeki uzun vadeli bağımlılıkları belirleyebilir. RNN yapısından türetilerek oluşturulmuştur (Hochreiter ve Schmidhuber, 1997). Çalışma prensibine geçmeden önce derin öğrenme bölümünde bahsettiğimiz RNN yöntemini ve LSTM ile ilişkisini değerlendireceğiz.


##### 3.3.1.1. RNN (Tekrarlayan sinir ağları) yapısı

RNN, döngüsel sinir ağlarıdır. Her bir döngüde, ardışık olarak bir sinir ağından diğer bir sinir ağına bilgi gönderir. Normal YSA'dan farkı budur.



Şekil 3.6. RNN ağı

Şekil 3.6'daki diyagramda "A"nın girişi ( $X_t$ ) ve çıkışı ( $h_t$ ) bulunmaktadır. Genel resme baktığımızda klasik YSA'dan çok farklı olmadığını görüyoruz. RNN, aynı ağın kopyaları olarak düşünülebilir ve her bir ardılına bir mesaj iletir. RNN ağının açılmış hali Şekil 3.7'de gösterilmiştir.



Şekil 3.7. RNN modelinin açılmış hali

Bu zincir şeklindeki yapı RNN’lerin seriler ve listeler ile ilişkili olduğunu belirtmektedir. Son yıllarda konuşma tanıma, dil modelleme, resim alt yazılama vs. çalışmalarda başarılı sonuçlar elde edildiği belirtilmiştir. Bu başarıların arkasında LSTM metodunun kullanılmasıdır (Olah, 2015).

### 3.3.1.2. Uzun vadeli bağımlılık sorunu


RNN’in önemli sayılabilecek özelliklerinden biri, önceki verileri mevcut görev ile ilişkilendirebilecekleri düşüncesidir. Örnek vermek gerekirse, önceki video çerçevelerinin (video frames) kullanılması mevcut çerçevenin anlaşılmasını sağlayabilir. RNN’in kabiliyetinin bu çözümü sağlayabilmesi problemin durumuna göre değişebilir.

Örneğin bir görevi yerine getirmek adına son bilgilere göre değerlendirme yapabileceğimiz bir dil modeli olsun. Bir cümle düşünelim; “arabanın tekerlek sayısı **dörttür**”. Buradaki sözcüklere bakarak modelimiz son sözcüğün başka bir bağlama ihtiyaç duymadan yüksek olasılıkla dört olacağını (ilk akla gelendir) tahmin edebilir (3 tekerli araçların 4 tekerlilere kıyasla çok fazla olmadığını düşünürsek tabii). Bunun gibi örneklerde ilgili bilgi ile ihtiyaç duyulan yer arasındaki mesafenin az olması durumunda, RNN’lerin geçmiş bilgiyi kullanmayı öğrenmesi olasıdır.

Bunun dışında daha fazla bağlama ihtiyaç duyulabilir. Örnek bir metin düşünürsek, “Eve geldim... Su içtim” gibi bir cümlede aradaki boşluğa eklenecek metin veya sözcük gibi bir ifade için daha fazla bağlama ihtiyaç duyulabilir. Bu boşluğun artması ile teoride öğrenebilseler de pratik anlamda RNN’ler bu bilgiyi öğrenmekte zorlanır. Bu noktada LSTM’ler bunun çözümü için geliştirilmiştir (Olah, 2015).


### 3.3.1.3. LSTM'nin (Uzun kısa süreli hafıza) içyapısı

Bütün RNN'ler; tekrar eden sinir ağı modül zinciri şeklindedir. Standart RNN'lerde, bu modüller, tek bir tanh katmanı gibi basit bir yapıya sahiptir. Şekil 3.8'de bu zincirin şeması gösterilmiştir.



Şekil 3.8. Standart RNN'de tekrarlanan modül tek katman içerir.

LSTM'lerin de RNN gibi birbirilerini takip eden ardışık yapıları bulunmaktadır. Buradaki önemli fark, takip eden parçalarda tek bir sinir katmanını olmayıp dört katmanlı ve özel etkileşimli bir yapı olmasıdır. Şekil 3.9'da LSTM zinciri gösterilmiştir.




Şekil 3.9. LSTM'de tekrarlanan modül etkileşimli dört katman içerir

LSTM diyagramındaki yapının kolayca anlaşılması amacı ile kullanılan ifadeler Şekil 3.10'da gösterilmiştir.



Şekil 3.10. LSTM diyagramında kullanılan ifadeler


Bu diyagramda, her satıra ait bir düğümün çıktısından diğer modüllerin girişlerine kadar tüm vektörü iletir. Turuncu kutularda sinir ağı katmanları öğrenilir iken sarı dairelerde vektör eklenmesi gibi noktasal işlemleri yerine getirir. Birleştirilen satırlar birleştirme hattını, çizgi çatallaştırma işlemi de kopyalanan içeriğin farklı yerlere gideceğini ifade eder (Olah, 2015).



Şekil 3.11. LSTM hücresinde bulunan LSTM anahtarı

Şekil 3.11’de gösterildiği gibi LSTM anahtarı diyagramın üzerinden geçen yatay çizgi olup bu hatta çalışmaktadır. Hücre taşıma bandına benzetilebilir. Bütün zincir boyunca küçük lineer etkileşimle çalışmaktadır. Bilginin değişime uğramadan hücre boyunca akması kolaylaşır.

LSTM, “kapılar” olarak belirtilen yapılar ile bilgi ekleme ve çıkarma kabiliyetine sahiptir. Kapılar isteğe bağlı olarak bilgi verir. Yapısında sigmoid ağı katmanı ve noktalı çarpma işleminden oluşur (Şekil 3.12).




Şekil 3.12. Sigmoid katmanı ve noktalı çarpma işlemi

Sigmoid katmanı, 0-1 arası çıktı verir ve her bileşenin ne kadar geçmesine müsaade edileceğine karar verir. 1 değeri “her şey geçebilir” anlamına gelirken 0 değer “hiçbir şey geçemez” anlamına gelmektedir. LSTM, hücrenin durumunu korumak için üç adet sigmoid kapısı mevcuttur (Olah, 2015).

### 3.3.1.4. LSTM'nin adımları


Modelin ilk adımı, hangi bilginin hücre durumundan atılacağını tespit etmektir. Bu tespit, “unut kapısı katmanı” olarak adlandırılan bir sigmoid katman tarafından gerçekleştirilir.  $X_t$  ve  $h_{t-1}$  noktalarına bakılır ve  $C_{t-1}$ 'e hücre durumunu her sayı için 0-1 arasında bir çıkış değeri verir (Şekil 3.13). Çıkış değeri 1 olanlar “bu bilgiyi tut” anlamına gelirken, 0 ise “bu bilgiden kurtul” anlamındadır. Önceki sözcükleri kullanarak bir sonraki sözcüğü tahmin etmeye çalışan dil modeli örneğine geri dönelim. Bu gibi bir sorunda; ilgili hücre durumu mevcut konunun cinsiyetini içerebilir, bundan ötürü doğru zamirler kullanılabilir. Yeni konu geldiğinde, eski konunun cinsiyetini unutmak isteriz. Denklem 3.1’de unut kapısının formülü verilmiştir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (3.1)$$



Şekil 3.13. LSTM hücresinde “unut kapısı katmanı”

Sonraki adım, hücre durumuna hangi yeni bilginin depolanacağına karar verilmesidir. İki bölümden oluşur. Birincisi “giriş kapısı katmanı” olarak nitelendirilen bir sigmoid katman hangi değerlerin güncelleneceğini tespit eder. Akabinde tanh katmanı yeni aday değerler vektörü oluşturur ve  $\tilde{C}_t$  yeni duruma eklenir (Şekil 3.14). Bir sonraki aşamada, durumu güncellemek için bu iki katman birleştirilir. Dil modeli örneğinde; yeni konunun cinsiyetini hücre durumuna eklemek gerekir, unuttuğumuz eski cinsiyetin yerini alır. Giriş katmanının formülü sırası ile Denklem 3.2 ve 3.3’te verilmiştir.



Şekil 3.14. LSTM hücresinde giriş kapısı katmanı


$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (3.2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (3.3)$$

Böylece  $C_{t-1}$  eski hücre durumunu,  $C_t$  yeni hücre durumunun içine güncellenebilir. Önceki adımlar ile ne yapılacağına karar verilmişti, artık uygulama zamanı geldi.

$f_t$  ile eski durumu çarptık bunu yaparak önceki kararları unutmuş olduk. Akabinde  $i_t * \tilde{C}_t$  ekledik (Denklem 3.4). Her bir durum değerinin ne kadar güncellenmesi gerektiğine karar vermemizi ölçeklendirerek, aday bir değer oluşmasına olanak verir (Şekil 3.15).

Dil modeli durumunda, önceki nesnenin cinsiyet bilgisini hangi kısımda atayacağımızı sağlar ve daha önceki aşamada karar verdiğimiz gibi yeni bir bilgi ekler.



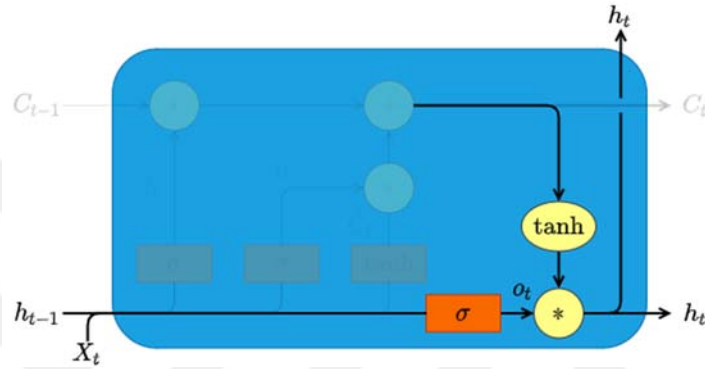
Şekil 3.15. LSTM hücresinde önceki katmanların işlemleri yapıldıktan sonra birleştirilmesi

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.4)$$

En son aşamada, çıkışa ne yollayacağımıza karar veriyoruz. Bu çıkış, hücremizin durumuna bağlıdır. Filtre versiyonu da olabilir. Birincisi, hangi hücre durumunun hangi

bölümlerine çıktı çıkarttığımızı karar verecek sigmoid katmanı çalıştırılır (Şekil 3.16). Sonra, hücrenin durumunu tanh (-1 ila +1 arası olarak şekilde) ve sigmoid kapısının çıktısı ile çarpıp sadece bizim karar verdiğimiz parçaların ortaya çıkması sağlanır (Denklem 3.5, Denklem 3.6).

Dil modeli örneğinde, yalnızca bir konu görüldüğünden, bir fiille alakalı bilgiyi çıktı, sonrasında isteyebilir. Örnek vermek gerekirse konu tekil veya çoğul mu çıktı, buna göre bir sonraki fiilin bir sonraki harf ile birleşmesi gerektiğini bilmemiz mümkün (Olah, 2015).



Şekil 3.16. LSTM hücresinde son aşamada  $h_t$  kapısı oluşturulur

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (3.5)$$

$$h_t = o_t * \tanh(C_t) \quad (3.6)$$

### 3.3.2. Zaman serisi tahmininde kullanılan metotlar

Zaman serisi analizi ile alakalı temel düzeydeki bilgiler, birinci bölümde verilmiştir. Burada, birçok alanda kullanılan (borsa tahmini, pazarlama, satış, hava durumu vb.) ayrıca güneş ve rüzgâr tahmininde sıklıkla kullanılan bazı yöntemlerden bahsedilecektir.

#### 3.3.2.1. AR (Özbağlanım-otoregresif) yöntemi

Otoregresif (özbağlanımlı) model, mevcut değeri geçmiş değerlerin doğrusal bir kombinasyonu ve bir sinyal gürültüsü  $\omega_t$  sunar. AR modelinin  $m$  sırası,  $AR(m)$ , denklem 3.7'de gösterilmiştir:

$$\tilde{x}_t = \sum_{i=1}^m \Phi_i x_{t-i} + \omega_t = \Phi_1 x_{t-1} + \Phi_2 x_{t-2} + \dots + \Phi_m x_{t-m} + \omega_t \quad (3.7)$$

Burada  $x_t$ ; zaman serisi deęerleri,  $\omega_t$ ; gürültü,  $\Phi = \Phi_1, \Phi_2, \dots, \Phi_m$ ; model katsayılarının vektörü ve  $m$  pozitif bir tam sayıdır (Ghofrani ve Alolayan, 2018).

AR sürecini tanımlamak için örneğin bir çaycı olduğunuzu düşünelim. Saatte 30 bardak çay satıldığını düşündüğünüzde, dükkânınızı kapatmak ve çay stoku tükendiği için çay satmaktan vazgeçmek istemiyorsanız, her saatte bir tüketilen çay yerine yeni çay doldurmanız gerekir. Böylelikle her saat 30 bardak çay satılsa bile siz devamlı olarak yenisini ilave ettiğinizden ötürü herhangi bir aksaklık veya kaza yaşanmaması durumunda satışınız sürekli devam edecektir. Bu durum bir otoregresif süreci tanımlar. Çünkü daha az veya çok bardak çay satmanız şeklinde bir şok bir saatteki çay seviyesini etkileyecektir (Hanedar ve ark., 2005).

### 3.3.2.2. MA (Hareketli ortalama) yöntemi

Bir zaman serisi temsili sağlamak için geçmiş deęerlerin ( $\tilde{x}_{t-i}$ ) ağırlıklı toplamını kullanan AR modelinden farklı olarak, hareketli ortalama (MA) modeli, bir zaman serisi süreci geliştirmek için geçmiş  $n$  gürültü deęerlerini ( $\omega_t, \omega_{t-1}, \omega_{t-2}, \omega_{t-n}$ ) birleştirir. MA modelinin  $n$  sırası,  $MA(n)$ , denklem 3.8'de gösterilmiştir (Ghofrani ve Alolayan, 2018):

$$\tilde{x}_t = \sum_{j=0}^n \theta_j \omega_{t-j} = \omega_t + \theta_1 \omega_{t-1} + \theta_1 \omega_{t-1} + \dots + \theta_n \omega_{t-n} \quad (3.8)$$

Burada  $\theta = (\theta_1, \theta_2, \dots, \theta_n)$  model katsayılarının vektörüdür ve  $\theta_0 = 1$ 'dir.

MA sürecini tanımlamak için; nakliye firması sahibi bir yetkili olduğunuzu düşünelim. Her nakliyenin taşınması işlemi bağımsız bir olay olacaktır. Tecrübeleriniz, nakliye mallarının bulunduğu depoya ve mal sahibine hedef noktaya ulaşması ve teslimatı için yaklaşık iki gün gerekli olduğunu göstermiştir. Siz eęer ki yeterince TIR kamyonuna sahip deęilseniz, mal sahipleri taşıma işini başkasına devredecektir. Bir gün içerisinde nakliyesi yapılacak mallar için gerekli araç sayısı size gerekli olan TIR kamyonu için bilgi vermektedir. İki gün ötesinde, bugünkü yaptığımız tercihler, size ileriki dönemde olacaklar hakkında bir şey söylemez. Bu süreç hareketli ortalama süreci olarak ifade edilir (Hanedar ve ark., 2005).

### 3.3.2.3. ARMA (Oto regresif hareketli ortalama) yöntemi

Oto regresif hareketli ortalama (ARMA) modeli, AR ve MA modellerinin bir süreç için önemli bir parametreleştirme sağlamak üzere geliştirilmiştir. ARMA  $m$  ve  $n$ , ARMA( $m,n$ ) denklem 3.9'da verilmiştir:

$$\tilde{x}_t = \sum_{i=1}^m \Phi_i x_{t-i} + \sum_{j=0}^n \theta_j \omega_{t-j} \quad (3.9)$$

Burada  $\Phi_i$  ve  $\theta_j$ , ARMA modelinin oto regresif ve hareketli ortalama katsayılarıdır (Ghofrani ve Alolayan, 2018).

### 3.3.2.4. ARIMA (Oto regresif entegre hareketli ortalama) yöntemi

Oto regresif entegre hareketli ortalama (ARIMA) modeli durağan olmayan (non-stationary) zaman serilerinde kullanılmaktadır. Box-Jenkins yöntemini kullanır (Box ve Jenkins, 1970). Yerel eğilim (trend) veya düzeydeki farklılıkları temsil etmesine rağmen, durağan olmayan süreçlerin farklı bölümleri belirli düzeyde benzerlik gösterir. Zaman serisinin  $d$ . farkı olan sabit bir ARIMA( $m, d, n$ ) modeli denklem 3.10'daki şekliyle temsil edilir:

$$\tilde{x}_t = \sum_{i=1}^m \Phi_i S^d x_{t-i} + \sum_{j=0}^n \theta_j \omega_{t-j} \quad (3.10)$$

Burada  $S = 1 - q^{-1}$  ve  $\Phi_m(q)$  sabit ve ters çevrilebilir bir AR( $m$ ) operatörüdür.  $x_t, \omega_t, \Phi_t$  ve  $\theta_j$  sırasıyla gözlemlenen zaman serisi değerleri, hata, AR ve MA değerleridir.  $d$  mevsimsel olmayan farklılıkların sayısı;  $m$ , oto regresif terimlerin sayısıdır ve  $n$ , gecikmeli tahmin hatalarının sayısıdır (Ghofrani ve Alolayan, 2018)

AR ve MA sürecini tanımlayacak olursak,

“Sahile yakın bir otelinizin olduğunu varsayalım. Otel defterinde bazı rezervasyonlar bulunmaktadır. Detaylıca anlatmak gerekirse müşterilerin bazıları otelinizde bir günden fazla vakit geçirmekte bunun yanında bazı müşteriler sahilde denizde yüzmek veya konferansa katılmak için otelinize gelmiştir (Her ikisi de olabilir hem yüzmeye hem de konferansa katılmak için gelmiştir). Bu müşteriler evlerine dönmeden önce gece kalmak için sizin otelinize gelmektedirler. Belli bir günde

meydana gelecek şok, otelde devamlı olarak kalan müşterileri artan (birden fazla dönem) bir şekilde etkileyecektir. Fakat bu şok, denizde yüzenler veya konferansa katılanlar, bir tatil geçirmelerinden sonra gece konaklamaya gelenler üzerinde bir hafta sonra tek bir etkisi olacaktır”

örnek olarak verilebilir (Hanedar ve ark., 2005).

ARIMA sürecinde zaman serilerinin durağanlık tespiti yapıp düzeltilmesi sonrasında işlem; ARMA modeli ile tahmin edilebilir hale getirilir.

### 3.3.3. Performans ölçümleri

Tahmin yöntemlerinin performansı, tahmin hatası ile ilgili çeşitli metriklerle ölçülür. Daha yüksek hata değerleri, daha az tahmin doğruluğu anlamına gelir. Bu bölümde, tahmin hatasını hesaplamak için yaygın olarak kullanılan bazı performans ölçümlerine değinilecektir. Dikkat edilmesi gereken husus,  $x$  gözlemlenen değeri temsil etmekte olup  $\tilde{x}$ , tahmin edilen değer ve  $n$  toplam örnek sayısına karşılık gelmektedir (Ghofrani ve Alolayan, 2018).

#### 3.3.3.1. MSE (Ortalama kare hata)

Ortalama kare hata (MSE - Mean square error) bir regresyon eğrisinin bir dizi nokta ile arasındaki mesafeyi açıklar. MSE, bir makine öğrenmesi modelinin, tahmin mekanizmasının performansını ölçer, daima pozitif değerli olup MSE sonucu ne kadar sıfıra yakınsa tahmin mekanizmasının daha iyi performans gösterdiği yorumu çıkarılabilir (Denklem 3.11).

$$MSE = \frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - x_i)^2 \quad (3.11)$$

#### 3.3.3.2. NMSE (Normalize edilmiş ortalama kare hata)

Normalize edilmiş ortalama kare hata (NMSE – Normalized mean square error), MSE'nin normalize edilmiş halidir (Denklem 3.12).

$$NMSE = \frac{n \sum_{i=1}^n (\tilde{x}_i - x_i)^2}{\sum_{i=1}^n x_i \sum_{i=1}^n \tilde{x}_i} \quad (3.12)$$

En iyi model için ölçülen NMSE, 0 (sıfır) değerine en yakın olduğu durumlarda modelin başarılı olduğu kabul edilmektedir. Paydada bulunan ortalamaların çarpma terimi ile normalize edilen NMSE, modelin az yahut fazla tahmin etmesinden ötürü yanlışlık göstermez (Zeydan, 2014).

### 3.3.3.3. RMSE (Kök ortalama kare hata)

Kök ortalama kare hata (RMSE - Root mean square error), MSE'nin karekökü alınarak bulunur (Denklem 3.13) Bir makine öğrenmesi modelinin, tahmin mekanizmasının tahmin ettiği değer ile gerçek değerleri arasındaki uzaklığı bulunmasına kullanılan kuadratik bir ölçümdür. RMSE, tahmin hatalarının standart sapmasını açıklar. Başka bir deyişle kalıntılar (residuals), regresyon çizgisinin gerçek veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür. RMSE; birçok matematiksel hesaplamalarda istenmeyen mutlak değerlerin kullanılmasına izin vermez (anonymous, 2017). RMSE tanım olarak 0 (sıfır) değerine ne kadar yakınsa veriler ile mükemmel uyum gösterir denilir. Ancak pratikte hiçbir zaman 0 değerini almaz. Genel olarak, daha düşük bir RMSE, yüksek olandan daha iyidir. RMSE, ölçüm olarak kullanılan sayıların ölçeğine bağlı olması nedeniyle (biz günlük kWh cinsinden kullanacağız ona göre şekillenecek) farklı veri türleri arasında karşılaştırmaların bir geçerliliği olmayacaktır. Model karşılaştırmalarında sıklıkla kullanılır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - x_i)^2} \quad (3.13)$$

### 3.3.3.4. NRMSE (Normalize edilmiş kök ortalama kare hata)

Normalize edilmiş kök ortalama kare hata (NRMSE – Normalized root mean square error), RMSE'nin normalize edilmiş halidir (Denklem 3.14).

$$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - x_i)^2}}{\frac{1}{n} \sum_{i=1}^n x_i} \quad (3.14)$$

### 3.3.3.5. MAE (Ortalama mutlak hata)

Ortalama mutlak hata (MAE – Mean absolute error), iki sürekli değişken arasındaki farkın ölçümüdür (Denklem 3.15). MAE, her bir gerçek değere ile veriye en iyi uyan çizgi arasındaki ortalama dikey ve aynı zamanda ortalama yatay uzaklıktır.

MAE sonucu, kolay yorumlanabilir olmakla birlikte regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır (anonymous, 2017).

$$\frac{1}{n} \sum_{i=1}^n |\tilde{x}_i - x_i| \quad (3.15)$$

### 3.3.3.6. NMAE (Normalize edilmiş ortalama mutlak hata)

Normalize edilmiş ortalama mutlak hata (NMAE – Normalized mean absolute error), MAE'nin normalize edilmiş halidir (Denklem 3.16).

$$NMAE = \frac{1}{n} \sum_{i=1}^n \frac{|\tilde{x}_i - x_i|}{\max(x_i)} \quad (3.16)$$

### 3.3.3.7. MRE (Ortalama bağıl hata)

Ortalama bağıl hata (MRE – Mean relative error), Denklem 3.17'de gösterilmiştir.

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|\tilde{x}_i - x_i|}{x_i} \quad (3.17)$$

### 3.3.3.8. MAPE (Ortalama mutlak yüzde hata)

Ortalama mutlak yüzde hata (MAPE – Mean absolute percentage error), Denklem 3.18'de gösterilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\tilde{x}_i - x_i}{x_i} \right| * 100\% \quad (3.18)$$

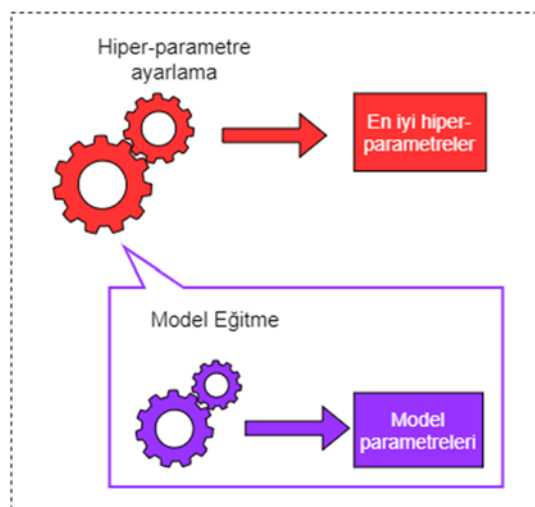
Regresyon ve zaman serileri modellerinde MAPE, tahminlerin doğruluğunu tespit etmek için sıklıkla kullanılmaktadır. Gerçek değerler içerisinde sıfır (0) içerenler bulunuyorsa, sıfırla bölüneceği için MAPE hesaplanamaz (yanlış sonuç üretir). Çok düşük tahmin değerleri için yüzde hata %100'ü aşamaz. Fakat çok yüksek tahmin değerleri üretildiğinde yüzde hatasın üst limiti yoktur. MAPE, tahminde kullanılan modellerin doğruluklarını kıyaslamak için kullanıldığında, tahminleri düşük olan bir modeli sistematik olarak seçmesi sebebi ile önyargılıdır (biased) (anonymous, 2017).

Çalışmamızda kullanılan santral verilerine yönelik tahminleme performans ölçümleri için MSE, RMSE, NMSE, MAE ve MAPE (Santral\_D sıfır değeri içerdiği için MAPE’de değerlendirilmeye alınmadı) yöntemleri kullanılmıştır.

### 3.3.4. Hiper-parametreler

Grafik kartları kullanarak paralel işlemlerin hızlı bir şekilde yapılabilmesiyle araştırmacılar, daha fazla katmandan oluşan karmaşık yapılar modelleyebilmekle birlikte derin öğrenme ile problem çözmek, çok katmanlı ağ yapısını optimize etmek ile eşdeğer duruma gelmiştir. İşte burada araştırmacıların sezgisinden sonra sıklıkla kullandığı araçlar hiper-parametreler olmuştur (Çarkacı, 2018).

Veriden öğrenen MÖ modeli tasarlarlarken tasarımcılar, modelde hangi algoritma veya tekniklerin kullanılmasına karar vermesi gerektiğinde bazı parametreleri kullanma ihtiyacı duyarlar. Örnek vermek gerekirse, KNN sınıflandırma algoritmasında k değerinin ne olacağına tasarımcı karar verir. Aynı şekilde SVM algoritmasında hangi kernel fonksiyonunun kullanılacağına da tasarımcı karar verir. Derin ağ modellerinde seyreltme (dropout) değerini ve nöron sayısını da modeli tasarlayan kişi ayarlar. Bu parametrelerin seçiminde hangi kıstasların kullanılacağı başlangıçta açık değildir. Veri setine, probleme vb. durumlara bağlı olarak değişiklikler göstermektedir. Bundan ötürü ne olması gerektiği, modeli tasarlayan kişinin isteğine bırakılmıştır. İşte problemin, veri setinin karakteristiğine göre değişiklikler gösteren parametreler hiper-parametre (hyperparameters) denilmektedir. Şekil 3.17’ de hiper-parametreler ve model parametrelerin durumu gösterilmiştir (Çarkacı, 2018).



Şekil 3.17. Hiper-parametreler ve model parametrelerin ilişkisi (Okonkwo, 2019)

Derin öğrenme sürecinde kullanılan hiper-parametreler açıklamaları ile birlikte Çizelge 3.2’de ifade edilmiştir.

**Çizelge 3.2.** Hiper-parametre türleri ve açıklamalar (Çarkacı, 2018)

Hiper-parametre	Açıklama
Veri setinin boyutu	Derin öğrenme uygulamalarında veri setinin çeşitliliği ve büyüklüğü öğrenme sürecine olumlu katkılar sunar.
“Mini-Batch” boyutu	Derin öğrenme uygulamalarında, veri setinde bütün verileri aynı sürede işleyerek öğrenme, zaman ve bellek yönetimi açısından maliyetli bir süreçtir. Çünkü öğrenmenin her iterasyonunda geriye yayılım (backpropagation) işlemi ile sinir ağı üzerinde gradyan inişi (gradient descent) hesaplaması yapılır ve ağırlık değerleri bu şekilde güncellenir. Hesaplama işlemi veri sayısı ve hesaplama süreci doğru orantılı bir şekilde artar. Bu soruna çözüm olarak veri setleri küçük gruplara ayrılır ve öğrenme süreci bu gruplar üzerinden yürütülür. Bu şekilde birden fazla girdi değerinin parçalar halinde işlenmesi olayına “mini-batch” denir. Model tasarımında mini-batch parametresi olarak tayin edilen değer; modelin aynı zamanda kaç veriyi işleyeceğine karar vermektedir.
Öğrenme hızı (learning rate)	Derin öğrenme parametrelerinin güncellenmesi, geriye yayılım (backpropagation) işlemi ile yapılır. Bu işlemde güncelleme süreci “chain rule” denilen geriye doğru türev alınarak farkın hesaplanması ve farkın “learning rate” parametresi ile çarpılması, çıkan sonucun ağırlık değerinden çıkarılması ile yeni ağırlık değeri hesaplanır. Bu işlem esnasında “learning rate” parametresi, tasarımcının isteğine göre sabit veya adım adım artan bir değer olarak ta belirlenebilir, momentum değerine de bağlı olabilir ya da adaptif algoritmalar tarafından öğrenme esnasında öğrenilebilir.
Momentum katsayısı (momentum)	Stokastik gradyan inişi (Stochastic gradient descent) gibi fazla salınım oluşturan ve gürültü (noise) üreten metotlar üssel ağırlık ortalaması gibi işlemler ile normalize edilip salınımları azaltılmaktadır. Bu normalizasyon süreci momentum beta katsayıları ile yapılmaktadır. Bu yöntemde, yeni üretilen değeri doğrudan almak yerine, bir önceki değeri de beta katsayısı oranında dâhil ederek yeni değer hesaplanır. Böylece gürültü ve grafikteki salınımlar azaltılır ve hızlı bir yöntem oluşturulur.
Optimizasyon algoritmasının seçimi	Derin öğrenme uygulamalarında öğrenme işlemi esnasında bir optimizasyon problemidir. Doğrusal olmayan (non-linear) problemlerin çözümünde optimum değeri bulmak için optimizasyon metotları kullanılmaktadır. Derin öğrenmede yaygın olarak kullanılan; stokastik gradyan inişi, adagrad, adadelta, adam, RMSProp, adamax gibi optimizasyon algoritmaları kullanılmaktadır.
Eğitim tur (Epoch) sayısı	Model eğitiminde verilerin hepsi aynı anda eğitime tabii tutulmaz. Belli sayıda parçalar halinde eğitimde yer alırlar. İlk parça eğitilir sonra modelin başarımı test edilir. Başarıma göre geriye yayılım (backpropagation) vasıtasıyla ağırlıklar güncellenir. Daha sonra yeni eğitim kümesi ile model tekrar eğitilir ve ağırlıklar güncellenir. Bu işlemler tekrarlanarak model için en uygun ağırlık değerleri hesaplanır. Bu eğitim adımlarının her biri “epoch” olarak adlandırılır.
Ağırlık (weight) başlangıç değerinin belirlenmesi	Modelin ağırlık değerleri, model çalıştırıldığında hepsi 0 olacak şekilde, 0.5 gibi standart sapmaya sahip olacak şekilde, 0.5 ile 0.9 arasında uniform dağılıma sahip olacak şekilde veya daha önceki bir modelin ağırlık değerleri başlangıç değeri olacak şekilde kullanılabilir. Farklı ağırlık yöntemleri de mevcuttur. Ağırlıkların belirlenmesi, modelin öğrenmesine ve hızına etki etmektedir.
Aktivasyon fonksiyonu	Aktivasyon fonksiyonları, modele, (non-linear) bir yapı sunmaktadır.

	Gizli katmanlarda (Hidden layer) $y = f(x, w)$ şeklindeki lineer fonksiyonumuzda matris çarpımı ile nöronların ağırlıkları hesaplandıktan sonra çıktı, doğrusal olmayan (non-linear) bir yapıya evrilir. Çünkü tabiatı gereği derin öğrenme metotları doğrusal olmayan (non-linear) yapıya sahip problemlerin analizi ve çözümünde daha etkili sonuçlar vermekte olduğu için derin öğrenme yöntemleri ile çözülmeye çalışılan problem, genel olarak doğrusal olmayan (non-linear) bir problemidir. Aktivasyon fonksiyonları çok katmanlı YSA'larda doğrusal olmayan (non-linear) dönüşüm işlemleri için kullanılmaktadır. Sigmoid, tanh, ReLU ve PReLU gibi çeşitleri vardır.
Seyreltme (dropout) değeri ve seyreltme uygulanacak katmanlar	Tam bağlı (fully connected) katmanlarda belli eşit (threshold) değer altındaki düğümlerin seyreltilmesi, başarıyı artırdığını göstermiştir. Başka bir deyişle zayıf bilgilerin unutulması öğrenime pozitif katkı sağlamaktadır.
Katman sayısı ve gizli katman nöron sayısı	Derin öğrenme metodunu diğer YSA'lardan ayıran özellikle de karmaşık problemlerin çözümünde iyi sonuç vermesini sağlayan en önemli özelliği, katman sayısıdır. Derinlik tanımı bu kısımdan gelmektedir. Geçmişte yapılmış olan çalışmalarda katman sayısının artışı ile modelin daha iyi öğrendiği gözlemlenmiştir. Örnek vermek gerekirse, resim tanıma problemlerinde modeli başlarında elde edilen görüntülerin analizi ile çok katmanlı YSA'larda başlangıçta veriye ait genel hatların öğrenildiği sonraki katmanlarda gittikçe verinin yavaş yavaş diğer özelliklerinin öğrenildiği gözlemlenmiştir.

### 3.3.5. Zaman serilerinde durağanlık tespitleri

Zaman serilerinin ideal şartlarda ve istatistiksel anlamda tahminlenebilmesi için, durağan olması beklenir. Serilerin durağan olup olmadığını bazı tespitler sonucunda çıkarmamız mümkündür. Bu tespitlerden iki tanesi, korelogram ve Dickey-Fuller testine değinilecektir.

#### 3.3.5.1. Görsel saptama - korelogram

Durağanlık testleri otokorelasyon fonksiyonu (ACF) ile belirlenir. Otokorelasyon fonksiyonu, zaman serisinin bazı değerleri ile gecikmeli (lag) değerleri arasındaki ilişkinin (korelasyon) büyüklüğünü belirler. Değişik zaman aralıkları (k) için saptanacak ACF(k) katsayısı değerleri ilişkilendirildiğinde, korelogram elde edilmektedir. ACF(k)'nin değer aralığı -1 ve +1'dir ve denklem 3.19'da ACF gösterilmiştir.

$$ACF(k) = \frac{S(X_t - X_{bar})(X_{t-k} - X_{bar})}{S(X_t - X_{bar})^2} \quad (3.19)$$

Durağanlığın tespitinde korelogramdan şu şekilde yararlanılır; ACF değeri çok yüksekten başlayıp yavaş yavaş azalma gösteriyor ise bu serinin durağan olmadığını göstermektedir. Bahsi geçen hipotez testi için her bir ACF değeri için  $\pm 1,96(1/\sqrt{n})$

değeri bulunarak yapılmaktadır. Eğer ki ACF(k) değeri, güven aralığı sınırları dışında ise otokorelasyon vardır denir. Kısmi otokorelasyon fonksiyonu ise (PACF) gecikmeli değişkenler arası ilişkiyi açıklamaktadır. PACF ile korelasyon, Y ve Y<sub>t-k</sub> değerleri arasındaki terimlerin etkisi çıkarılarak elde edilir (Hanedar ve ark., 2005).

### 3.3.5.2. Dickey-Fuller testi

Dickey-Fuller testi gözlemlenen zaman serilerinde birim kökün varlığının (serinin durağan olmadığını açıklar) olup olmadığını belirleyen bir testtir. Bu metod; ilk kez 1979 yılında D. A. Dickey, ve W. A. Fuller, tarafından 'Journal of American Statistical Association' adlı dergide yayınlanan bir makale ile duyurulmuştur. Dickey-Fuller testinde birinci dereceden otoregresif (AR(1)) denklem 3.20'de gösterilmiştir. 'ut' stokastik hata terimini, 'y<sub>t</sub>' gözlenen değeri, 't' zaman endeksini ifade eder.

$$\Delta y_t = \gamma y_{t-1} + ut \quad (3.20)$$

Birim kökün varlığının testi için kullanılan iki hipotez bulunmaktadır. Bunlar;

- H1:  $\gamma < 0$  ( $p < 1$ ) (seride birim kök yoktur, seri durağandır.)
- H0:  $\gamma = 0$  ( $p = 1$ ) (seride birim kök vardır, seri durağan değildir.)

Yukarıda bahsedilen DF test modeli, otoregresif süreç sayısı AR(1) için geçerli olmakla birlikte bu durum her zaman serisinde bu şekilde olmamaktadır. Bundan ötürü Dickey ve Fuller 1981 yılında 'Econometrica' dergisinde mevcut modellerini genişleterek Artırılmış Dickey-Fuller (ADF) denklemi (denklem 3.21) haline getirmişlerdir.

$$\Delta y_t = \alpha + \beta_t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \dots + \delta_{p-1} \Delta y_{t-p+1} + \varepsilon_t \quad (3.21)$$

Bu şekli ile oluşan regresyon, günlük hayatta kullanılan zaman serilerinin birim kök taşıyıp taşımadığını ifade ederken daha yüksek işlevsellik kazanmıştır (Hanedar ve ark., 2005).

### 3.3.6. Zaman serisi için istatistiksel model seçiminde kullanılan Akaike Bilgi Kriteri (AIC)

Akaike bilgi kriteri (ya da Akaike bilgi ölçütü) 1974 yılında Hirotugu Akaike tarafından geliştirmiştir. Oluşturulan modele eklenen parametrelerin yarattığı yükselmeye sınırlama getirmek için düzenlenmiştir. Göreceli tahminde bulunur. Temel denklem 3.22’de gösterilmiştir. ‘k’ sabit terim, ‘L’ benzerlik (likelihood) sayısını ifade etmektedir.

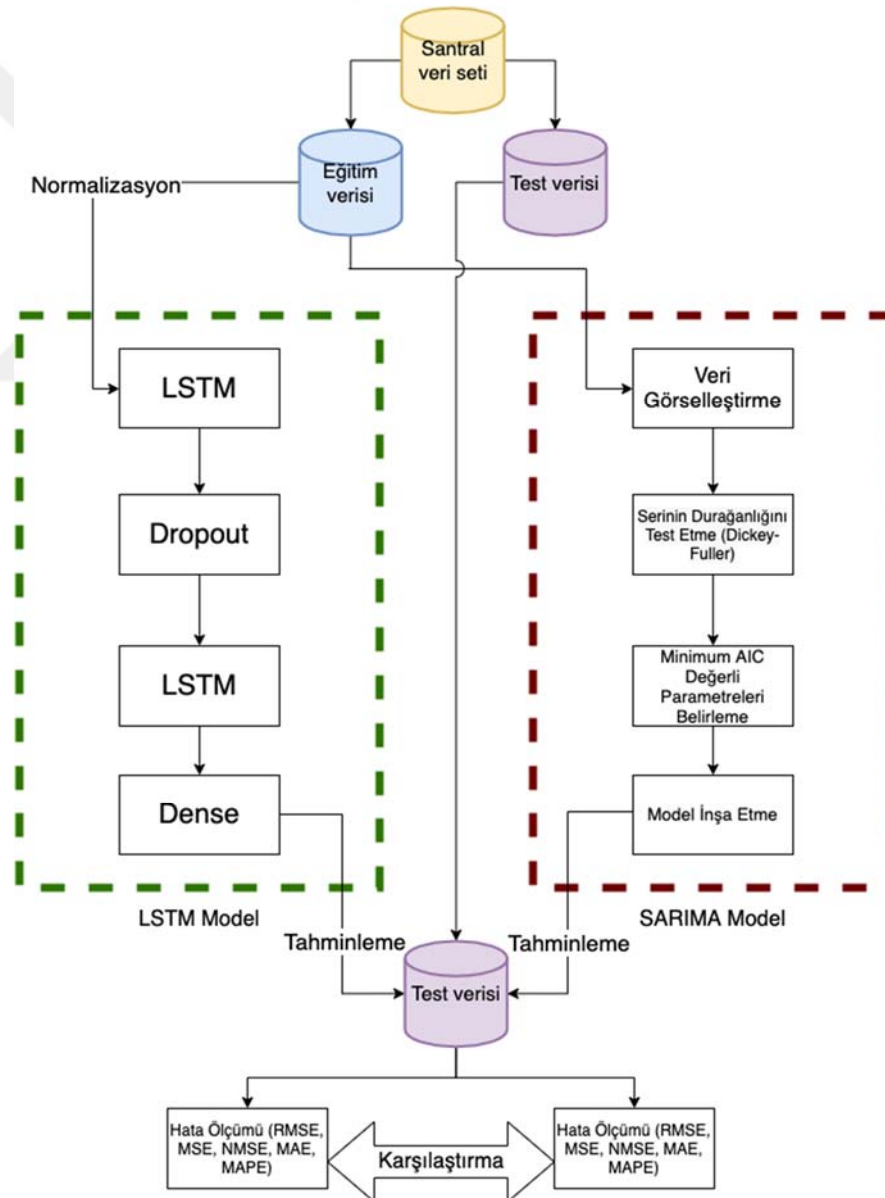
$$AIC = -2 \log(L) + 2k \quad (3.22)$$

AIC’nin bazı özellikleri:

- Model kıyaslamalarında daima en düşük AIC değerini veren tercih edilir.
- AIC, yalnızca seçili örnek büyüklüğü içinde değil aynı zamanda seçili örnek büyüklüğü dışındaki gelecek tahmini içinde geçerlidir.
- Yuvalanmış, yuvalanmamış ve gecikmeli modellerde tercih edilebilir (Ucal, 2006).

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Çalışmada her bir veri seti (bu veriler tek değişkenli zaman serileridir) için LSTM ve Mevsimsel ARIMA (SARIMA) modelleri kullanılmıştır. Her veri seti için her bir modele ait tahmin grafikleri, gerçek değerler ile birlikte verilmiştir. Bu modellerin tahmin doğruluklarını kıyaslamak adına MSE, RMSE, NMSE, MAE ve MAPE hata ölçümlerinden yararlanılmıştır. En son olarak INSOS bakım mühendislerinin yapmış oldukları tespitler neticesinde İç Anadolu, Ege ve Akdeniz’de bulunan GES’lere ait analizleri (arıza, bakım ve öneri) hakkında yorumlar yapılmıştır. LSTM ve SARIMA modellerine ait temel akış diyagramı Şekil 4.1’de gösterilmiştir.



Şekil 4.1. Çalışmaya ait LSTM ve SARIMA temel akış diyagramı

#### 4.1. LSTM Modeli

Keras kütüphanesinde bulunan Sequential (Ardışık) temel modeli tercih edilmiş, bu modelin katmanları arasında esas olarak LSTM modeli kullanılmıştır. Modelin genel yapısı Çizelge 4.1’de gösterilmiştir.

**Çizelge 4.1.** LSTM modelinin genel yapısı

<b>Model Türü:</b> Sequential (Ardışık model)		
<b>Katman</b>	<b>Çıktı Boyutu*</b>	<b>Parametre sayısı</b>
Lstm	32	4864
Dropout	32	0
Lstm_1	25	5800
Dense	1	26
Toplam parametre: 10.690		
Eğitilebilir parametre sayısı: 10.690		
* Boyutlar ve diğer değerler hiper-parametrelerdir.		

Model dört katmandan oluşan bir yapıya sahiptir. Birinci katmanda LSTM için girdi sayısı 32 olarak belirlenmiştir (Hiper-parametre olduğu için duruma göre değiştirmek mümkündür). Zayıf bilgilerin unutulması, tahmin mekanizması için olumlu sonuç döndürdüğü için dropout (seyreltme) katmanı eklenmiştir ve değer olarak 0.5 verilmiştir. (Genelde bu değerden başlanmaktadır, duruma göre değişebilir, tasarımcının inisiyatifine bırakılmıştır). Seyreltme işleminin ardından üçüncü katmanda yeni bir LSTM katmanı oluşturulmuştur ve ara girdi sayısı 25 olarak belirlenmiştir. En son olarak Dense (geleneksel YSA modeli) katmanı eklenmiştir ve çıktı boyutu 1 olarak verilmiş ve aktivasyon fonksiyonu olarak ReLU (hiper-parametre) kullanılmıştır. Optimizasyon için RMSProp algoritması eklenmiştir. Batch boyutu (hiper-parametre) olarak 16 verilmiştir. Her adım 200 epoktur (hiper-parametre). Standart LSTM modelinden yararlanılmıştır.

#### 4.2. SARIMA Modeli

Bu modelin oluşturulmasında Python destekli Statsmodels kütüphanesinden yararlanılmıştır. Bunun yanında SARIMA parametrelerinin günlük veri içeren GES’lerde en uygun şekilde bulunması için pmdarima (Smith, 2020) kütüphanesinde ‘auto\_arima’ metodu sadece kontrol amaçlı kullanılmıştır. Bunun yanında AIC yöntemi kullanılarak farklı modeller arasından en uygun (AIC değeri en düşük olan) model

seçilmiştir (Akaike, 1974). SARIMA'nın çalışma sürecinde parametrelerin belirlenmesi için istatistiksel anlamda dikkat edilmesi gereken (otokorelasyon ve kısmi otokorelasyon fonksiyonlarının analiz edilmesi ardından parametrelerin belirlenmesi vb.) bir süreçtir. Bunun için AIC'den ayrı olarak, üçüncü bölümde de bahsedilen, zaman serinin durağanlığı sağlayıp sağlamadığını kontrol etmek amacıyla Dickey-Fuller birim kök testi uygulanmıştır. Bu test, durağan veya durağan olmayan zaman serilerinin tespiti için geliştirilen bir metottur. Zaman serileri birim kök içerip içermediği, bu test ile bulunabilmektedir (Dickey ve Fuller, 1979). SARIMA'da durağan zaman serilerinde tahmin mekanizmasının çalıştırılması tavsiye edilmektedir. Durağan olmayan zaman serilerinin ise parametrelerin tespiti için durağan hale getirilmesi (fark alma, logaritmik işlem vs.) gerekir.

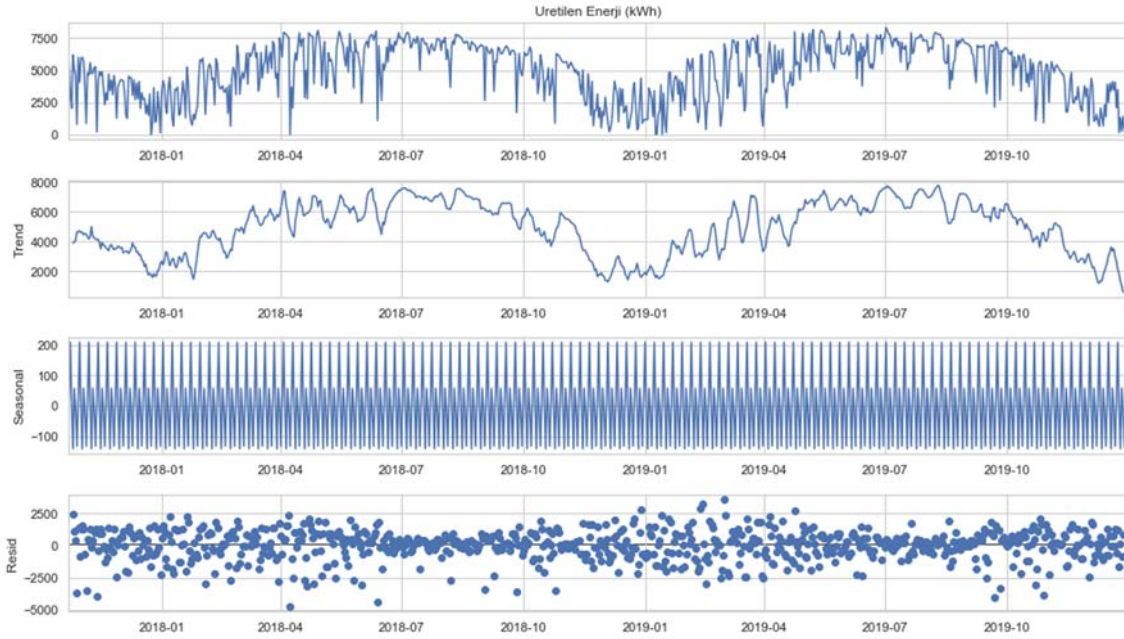
Veri setleri sezonsal (mevsimsel) bir etki içerdiği için Sezonsal ARIMA (SARIMA) modeli üzerinden değerlendirme yapılmıştır. Standart ARIMA (ARIMA(m, d, n)) dan farklı olarak SARIMA(m, d, n) x (M, D, N, s) şeklinde ifade edilir. 's' değeri burada mevsimsel olduğunu belirten bir tam sayıya karşılık gelmektedir. M, D, N ise sezonsal ARIMA için kullanılan parametrelerdir. Belirtilen bu değer, diğer ARIMA ifadeleri gibi bir hiper-parametredir.

### 4.3. Veri Setlerine Ait Sonuçlar

Bu kısımda SARIMA ve LSTM modelleri, her veri setinde uygulanmış ve modellerin sonuçları her bir veri setinden ayrı ayrı uygulanmıştır. Her veri setinin %70'i eğitim, %30'u test olarak ayrılmıştır.

#### 4.3.1. Santral\_A ve tahmin sonuçları

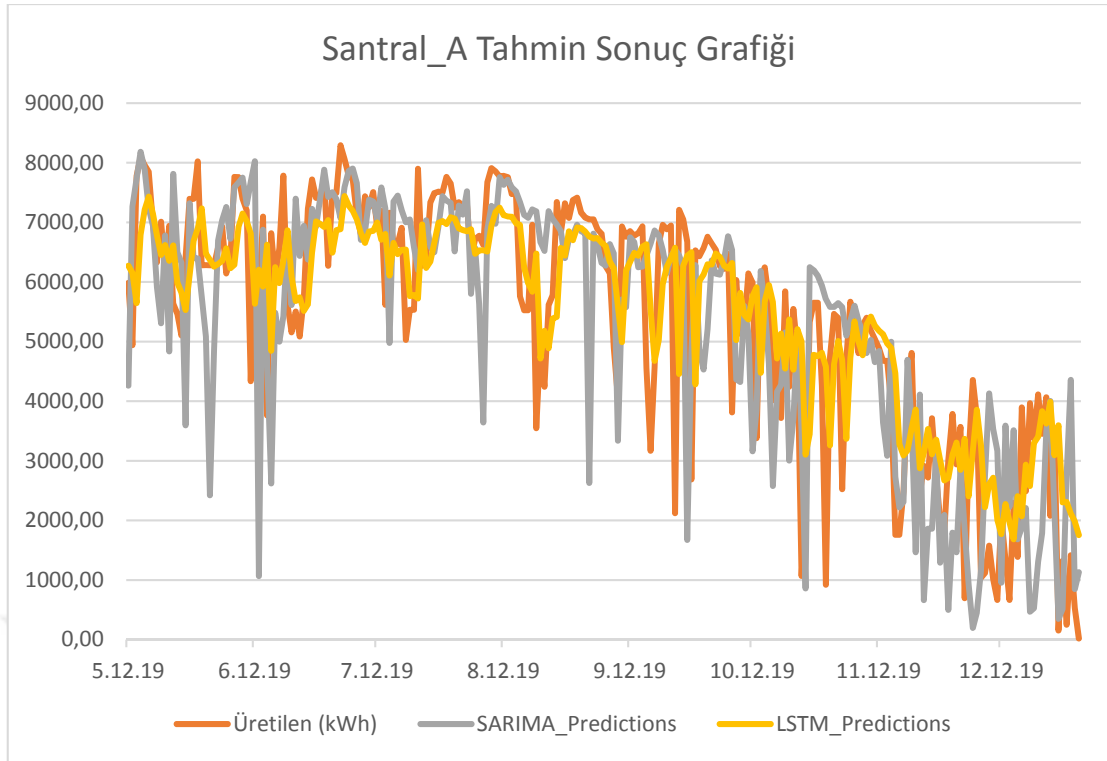
Santral\_A (Şekil 3.2), 800 günlük veri içermektedir. Santral\_A'nın hareketli ortalaması ile mevsimsel ayrışmaya (seasonal decompose) ait grafik Şekil 4.2'de gösterilmiştir. Bu grafik zaman serisine ait mevsimsellik, eğilim (trend) ve veri kalıntılarının (artıklar) bir arada bulunmasını sağlar.



Şekil 4.2. Santral\_A'nın mevsimsel ayrışma grafiği

Şekil 4.2'de ilk sırada gözlemlenen (gerçek) değer grafiği, ikinci sırada eğilim (trend) grafiği üçüncü sıradaki mevsimsellik grafiği gösterilmiştir (Zaman serisinin yıllık, günlük ayırık frekansına göre mevsimsel grafik ayarlanabilir). Son grafikte ise artık (residual veya noise) değerlerin grafiği bulunmaktadır. Artık değerler, gözlemlenen, trend ve mevsimsel değerlerin farkından elde edilmektedir (statsmodels.org, 2020). Zaman serisi; ilk grafik hariç diğer üç grafiğin bileşiminden gelmektedir. Akabinde önceki bölümde de belirtildiği gibi 'auto\_arima' metodu, Dickey-Fuller testi, sonrasında AIC testi uygulanmış ve parametreler belirlenmiştir. İşlemler sonucu oluşturulan model, SARIMA (1, 1, 1) x (0, 1, 1, 365) 'dir. Modelin sezonsal tam sayı değeri 's', AIC kriteri için 12 olarak belirtilip test edilmesine karşın daha sonra 365 olarak değiştirilmiştir. Çünkü GES, yılda 365 gün üretim yaptığı için bu değer atanmıştır (Hiper-parametre). İlave olarak, modelin çalıştırıldığı makinede 's' değerine büyük sayı verilmesi; AIC test sonucu için (bu işlem döngüsel çalışmaktadır), işlemci ve belleğin çok fazla çalışmasına ve makinenin yanıt vermemesine neden olmaktadır.

SARIMA işlemi gerçekleştirildikten sonra Çizelge 4.1'de belirtilen LSTM modelinde tahminleme mekanizması çalıştırılmış ve 12.05.2019 - 31.12.2019 tarihleri arası Şekil 4.3'deki sonuç ortaya çıkmıştır.



Şekil 4.3. Santral\_A'ya ait tahmin sonuçları


Çumra'da kurulu gücü 1MW olan Santral\_A GES'ine ait performans sonuçlarını (hata ölçümleri) incelediğimizde oluşturduğumuz LSTM modeli, SARIMA'ya göre (MAPE hariç) başarılı bir performans göstermiştir (Çizelge 4.2).

Çizelge 4.2. Santral\_A'ya ait performans sonuçları

Model	RMSE	MSE	NMSE	MAE	MAPE
SARIMA	1525.37	2326754	0.08	1104.16	%61
LSTM	1163.62	1354012	0.05	870.46	%78


#### 4.3.2. Santral\_B ve tahmin sonuçları

Santral\_B (Şekil 3.3), 730 günlük veri içermektedir. Santral\_B'nin mevsimsel ayrışma grafiği Şekil 4.4'te gösterilmiştir. Santral\_A'da yapılan işlemler, Santral\_B için de uygulanmıştır. Neticede oluşturulan model SARIMA (1, 1, 1) x (1, 1, 1, 365) 'dir.



Şekil 4.4. Santral\_B'nin mevsimsel ayrışma grafiği

Bu modelin parametreleri belirlendikten sonra SARIMA ve LSTM modelleri veri setine uygulanmış ve 01.06.2019 - 31.12.2019 tarihleri arası Şekil 4.5'teki sonuç ortaya çıkmıştır.



Şekil 4.5. Santral\_B'ye ait tahmin sonuçları


Tuzlukçu bölgesinde kurulu gücü 1MW olan Santral\_B GES'ine ait performans sonuçlarını incelediğimizde oluşturduğumuz LSTM modeli, SARIMA modeline göre Santral\_A'da olduğu gibi Santral\_B'de de gerçek verilere yakın bir sonuç ortaya koymuştur (Çizelge 4.3).

**Çizelge 4.3.** Santral\_B'ye ait performans sonuçları

Model	RMSE	MSE	NMSE	MAE	MAPE
SARIMA	1994.28	3977153	0.12	1556.63	%58
LSTM	1341.93	1800776	0.06	1005.14	%44

#### 4.3.3. Santral\_C ve tahmin sonuçları


Santral\_C'de (Şekil 3.4), Santral\_B'deki gibi 730 günlük veri bulunmaktadır. Santral\_C'ye ait mevsimsel ayrışma grafiği, Şekil 4.6'da gösterilmiştir.



**Şekil 4.6.** Santral\_C'nin mevsimsel ayrışma grafiği

İlk iki santralin veri desenleri (pattern) ile Santral\_C'nin veri desenleri benzediği için yapılan işlemlerde benzer sonuçlar ortaya çıkmıştır. Oluşturulan model, SARIMA (1, 1, 1) x (0, 1, 1, 365)'dir.

Modelin parametreleri belirlendikten sonra SARIMA ve LSTM modelleri veri setine uygulanmış ve 01.06.2019 - 31.12.2019 tarihleri arası Şekil 4.7'deki sonuç ortaya çıkmıştır.



Şekil 4.7. Santral\_C'ye ait tahmin sonuçları

Yunak bölgesinde kurulu gücü 1MW olan GES'e ait performans sonuçları incelendiğinde LSTM modeli, SARIMA modelinden daha tatmin edici sonuçlar çıkarmıştır (Çizelge 4.4).


Çizelge 4.4. Santral\_C'ye ait performans sonuçları

Model	RMSE	MSE	NMSE	MAE	MAPE
SARIMA	1756.39	3084906	0.1	1324.56	%52
LSTM	1301.53	1693980	0.06	1004.43	%44

#### 4.3.4. Santral\_D ve tahmin sonuçları


Santral\_D (Şekil 3.5), diğer veri setlerinden farklı olarak 8777 saatlik veri içermektedir. Santral\_A'daki orijinal (veriler sisteme normal şartlarda 15 dk'lık periyotlar halinde otomatik olarak kaydedilmektedir) verilerin saatlik frekansa çevrilmesi ile oluşturulmuştur. Santral\_D'ye ait mevsimsel ayrışma grafiği Şekil 4.8'de ifade edilmiştir.

Santral\_D'nin veri deseni diğer üç GES'e ait verilerden oldukça farklı bir davranış sergilemektedir. Dolayısı ile parametre belirlenmesinde farklı sonuçlar söz konusudur. Parametre seçim işlemi için Santral\_D'de sadece AIC testi uygulanmıştır.



Şekil 4.8. Santral\_D'nin mevsimsel ayrışma grafiği

Test sonucunda elde edilen model, SARIMA (1, 0, 1) x (1, 1, 1, 24)'tür. 's' değeri, GES'te günlük 24 saat üretim yapıldığı için 24 olarak ayarlanmıştır (Hiperparametre). Bu işlemden sonra LSTM ve SARIMA modellerinin 06.07.2018 – 23.10.2018 tarihleri arası tahmin sonuçları Şekil 4.9'da gösterilmiştir.



Şekil 4.9. Santral\_D'ye ait tahmin sonuçları


Santral\_D GES'ine ait hata performansları (Çizelge 4.5) gözlemlendiğinde LSTM modelindeki hata verisi SARIMA modelindeki hata verisinden daha düşük olup başarılı bir sonuç sergilemektedir. MAPE değeri, esas veride sıfır (0) değeri bulunduğu için eklenmemiştir.

**Çizelge 4.5.** Santral\_D'ye ait performans sonuçları

Model	RMSE	MSE	NMSE	MAE
SARIMA	167.93	28200.48	0.38	102.86
LSTM	86.26	7440.79	0.11	38.58

#### 4.4. İç Anadolu Bölgesindeki Bazı GES'lere Ait Analizler

Bölüm 3.2'deki veri setleri incelendiğinde bazı noktalarda enerji üretim verilerinin ani bir şekilde sıfıra yaklaştığı ve ara ara hızlı yükselişler yaptığı noktalar görülmektedir. Bu durum, veri setinde veri kirliliğine sebep oluşturmakta, veri kaybına neden olmakta, tahminleme yapılmasını zorlaştırmakta ve veri setinde düzenleme yapılmasına ihtiyaç duymaktadır. Buna neden olabilecek problemlerin yorumlanması için, INSOS bakım mühendisleri tarafından 17.06.2018 – 26.08.2019 tarihleri arasında analizleri yapılan İç Anadolu Bölgesi ağırlıklı olmak üzere Akdeniz ve Ege bölgelerinde Şekil 4.10'daki haritada gösterilen GES'lerden bazı çıkarımlar yapılmıştır.




**Şekil 4.10.** Mavi nokta ile gösterilen GES'lerin konumları

GES analiz çalışmasında alarm kodları oluşturularak sınıflandırılmıştır. Bu sınıflandırmaları arıza ve bakım olarak iki ana kategoride değerlendirmek mümkün. Çizelge 4.6'da alarm kodları ve alarm oluş sıklıkları (frekansı) gösterilmiştir. Bu çizelgede deneme amaçlı yapılan kayıtlar çıkarılmıştır.

Çizelge 4.6. Alarm kodları, frekansı ve açıklamaları

Kategori	Alarm Kodu	Frekansı	Açıklama
Arıza	10	53	RTU (Uzak terminal cihazı) haberleşmesi kesildi
Arıza	11	127	İnvertör (Çevirici) haberleşmesi kesildi
Arıza	12	7	GES üretimi durdu
Arıza	13	25	İnvertör üretimi durdu
Bakım	14	18	Duman dedektörünün aktifliğini kontrol et
Bakım	15	3	Trafo köşkünde kapı açık mı, değil mi kontrol et
Bakım	19	1	OG (orta gerilim) hücre kesici aç / kapat
Arıza	27	2	Güç sınırını aşınca alarm ver
Bakım	28	25	Santral PR (Performans oranı) 'si belirlenen sınırın altında
Bakım	29	34	İnvertör PR'si belirlenen sınırın altında
Arıza	30	28	AG (alçak gerilim) pano gerilim yok – yüksek gerilim
Arıza	31	109	AG pano gerilim yok – düşük gerilim
Arıza	32	6	AG pano gerilim yok – kaçak akım açık
Bakım	34	3	AG – trafo kademe düşük
Bakım	35	14	AG – trafo kademe yüksek
Arıza	37	220	xx. nolu invertörün AC gerilimi yok
Arıza	38	2	xx. nolu invertörün DC gerilimi yok
Arıza	39	149	xx. nolu invertörde arıza var
Arıza	40	232	xx. nolu invertörde düşük üretim var
Arıza	41	92	Modem (Santral ile iletişimi sağlar) haberleşmesi kesildi
Arıza	42	98	Data logger haberleşmesi kesildi
Arıza	43	91	Stringde (İnvertöre giren her bir dizi) üretim yok
Arıza	44	3	İzolasyon hatası mevcut
Bakım	45	117	PV panelde (herhangi) sorun var
Bakım	48	14	PV panele mermi isabeti belirlendi
Bakım	49	42	Ekipman bilgisi (sahada bulunan ekipmanların bilgisi)
Arıza	50	12	Redresör (sahada haberleşme ekipmanlarını besler) arızası
Bakım	52	111	Saha bilgisi (genel saha bilgisi, ekipman kontrolü vs.)

Bu bilgiler ışığında alarmların oluş sıklığı, grafik şeklinde Şekil 4.11'de gösterilmiştir.



Şekil 4.11. Alarm sıklık grafiği (azalan yönde gösterilmiştir)

Grafikten de anlaşılacağı üzere invertörlerden kaynaklı sorunlar (alarm kodları frekansına göre; 40, 37, 39 başta olmak üzere diğer alarm kodları da dâhil) belirlenen GES'ler içerisinde en sık karşılaşılan arıza türlerinden olduğunu söyleyebiliriz. Bunun yanında string invertör arızaları (alarm kodu 43) ve invertör haberleşmesinin kesilmesi (alarm kodu 11) de kategoriye dâhil edilebilir. Bu durumdan yola çıkarak sahada invertörlerin bakımı, istikrarlı çalışmasının sağlanması; enerji üretimi yaparken ve üretim tahmini için veri seti oluştururken önem teşkil etmektedir.

İnvertör arızalarından sonra grafiği incelediğimizde PV panellerin arızası (alarm kodu 45) da önemli bir sorun olup üretime negatif yönde etki edebilmektedir. PV paneller, hassas ve maliyetli ekipmanlardır. Dolayısıyla korunmalı ve bakımları yapılmalıdır (Panel temizliği, değişimi vb.).


Saha ve ekipmanlar hakkında son durumun tespiti (alarm kodu 52, 49), GES sahalarının sağlıklı bir şekilde işletilmesinde önemli bir konudur. Saha ekipmanlarının yeterli olması (yangın tüplerinin dolu ve çalışır olması, trafoların fiziksel olarak korunmuş olması, hırsızlığa karşı kameraların aktif olması vs.) bu bakım kategorisinde değerlendirmek mümkündür.

AG (alçak gerilim) panolarında gerilim arızaları da (gerilimin kesilmesi şeklinde) grafikte üst sıralarda yer almaktadır (alarm kodu 31 başta olmak üzere diğer kodlar da dahil).

Diğer bir alarm kodu (alarm kodu 42) data logger (veri kaydedicisi) haberleşmesinin kesilmesidir. Data logger, gerçek anlamda verilere erişimin mümkün olmadığı yerlerde veri erişimini internet alt yapısı ile sağlayan ekipmanlardır. Sıcaklık, nem, rüzgâr hızı vb. verileri kaydeder. Gücünü bataryalardan almaktadır. Data loggerların kesintisiz çalışması elzemdir, dikkat edilmesi gerekir.

Modemlerin stabil çalışması, merkez ile santral arasındaki iletişimin düzgün sağlanmasında hayati öneme sahiptir. Modem iletişiminin kesilmesi (alarm kodu 41) santrale ait birçok verinin alınamamasına neden olur.

Yukarıda bahsettiğimiz majör alarm türleri haricinde irili ufaklı toplam 88 adet bakım mühendisleri tarafından sisteme kayıt edilmiş alarm türleri mevcuttur. Bütün bu alarm türlerini belirli başlıklarda gruptandıracak olursak Şekil 4.12'deki pasta grafiğini elde etmiş oluruz.



Şekil 4.12. Alarm gruplarının yüzde şeklinde dağılımı

Sonuç olarak GES'ler üzerinde yapılan bakım çalışmaları bize şunu göstermektedir, invertör arızaları ve haberleşme kesintileri pastanın yaklaşık %70'ine tekabül etmektedir. Bu sonucu Türkiye geneline yaymak yeterli olmayabilir, fakat üzerinde dikkat edilmesi gereken bir konu olarak düşünülebilir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Güneş Enerji Santralleri baz alınarak elektrik üretim tahmini yapılan olan bu çalışmada; derin öğrenme, istatistik ve ekonometride kullanılan yöntemlerden (LSTM ve SARIMA) faydalanarak zaman serileri analizi üzerinde durulmuştur. Bu yöntemler, 4 farklı GES veri setinde uygulanmış ve sonuçlar performans ölçümlerinde sıklıkla kullanılan olan RMSE, MSE, NMSE, MAE ve MAPE üzerinde sonuçlar üzerinden kıyaslamaya gidilmiştir.

Dördüncü bölümde açıklanan Santral\_A, Santral\_B, Santral\_C ve Santral\_D'ye ait testler incelenmiş ve her iki yöntemde gerçeğe yakın sonuçlar çıkarılmış (NMSE ölçümü baz alındığında bütün modeller sıfır değerine yakın sonuçlar üretmiştir) olmasına karşın LSTM sonuçları, SARIMA'ya kıyasla başarılı değerler elde etmiştir. Burada hiper-parametrelerin etkili olduğunu belirtmek gerekir çünkü hiper-parametreler, tahminin gidiş yönünü belirlemede önemli rol oynamaktadır. İkinci olarak, bu çalışmada kullanılan GPU'nun hesaplama gücü sayesinde (Günümüzde CPU'lar hesaplama gücü olarak GPU'dan yavaş çalışmaktadırlar) hem kısa sürede hem de istenilen değerlerin tutarlı bir şekilde elde edilmesine olumlu katkılar sunmuştur. Çalışmada kullanılan LSTM kütüphanesi, GPU desteğinden yararlanırken SARIMA kütüphanesi sadece CPU'dan faydalanmıştır (statsmodels kütüphanesi GPU'yu desteklemiyor). Derin öğrenme tasarımında karşılaşılan engel, hızlı ve etkili işlemlerin sağlanabilmesi için pahalı donanımlara (yüksek hesaplama gücü gerektiren GPU veya TPU) ihtiyaç duyulmaktadır. Bir başka konu, veri kirliliklerinin düzeltilmesidir (anlamsız verilerin çıkarılması ve serininin eğilimine göre değerler verilmesi vs.). Veri kirliliğinin optimize edilerek düzenlenmesi tahmin işlevini kolaylaştıran bir faktördür. Veri analiz edilirken sıklıkla bu işlemler yapılmaktadır. Son olarak GES'lere ait verilerdeki tutarsızlıkların hangi nedenlerden kaynaklanabileceği kısaca üzerinde durulmuş, dördüncü bölümde bu konu hakkında küçük bir istatistik yapılmış ve ağırlıklı olarak santrallere ait invertörler ve haberleşmeden kaynaklı kesintilerden ötürü veri akışının düzensiz ve tutarsız olabileceği ve tahmin çıktısına olumsuz etki edebileceği sonucuna varılmıştır.

## 5.2. Öneriler

Makine öğrenimi ve derin öğrenme; yeni teknolojiler olmamakla birlikte sürekli gelişim gösteren ve rağbet gören konulardır. Çalışmada bu konudan faydalanıldı ve 21. yüzyılda yenilenebilir enerji sistemlerin kısıtlı yer altı kaynaklarından dolayı oldukça fazla talep görmesinden ötürü bu tip sistemlerin verimliliklerinin artırılmasındaki araştırmalara katkı sunulması hedeflenmiştir. Bu çalışma genişletilip düzenli olarak güncellenmesi ve modellerin iyileştirilmesi kaydıyla, gelecekte güneş santrallerinin elektrik üretiminin yıllar içerisinde verimliliğin düşüşünü azaltmak adına gelecekteki üretim değerleri tahmin edilip santral bakımının gecikmeden, zamanında ve az maliyet ile yapılmasına bir ön ayak olabilir. İlerleyen yıllarda ise tahminleme alt yapısı aylık periyodlara kadar indirgenerek geçmiş yıllardaki aynı ay dilimlerinde karşılaşılan problemlerin süratli tespitinde kullanılabilir. Bu çalışma ile GES'lerden üretilen elektrik verilerinin aylık olarak üretimin temel alındığı elektrik dağıtım şirketlerince yapılan anlaşmalarda, kişilerin (gerçek veya tüzel) elektrik üretiminde hedeflenen aylık üretimin az veya çok olmasının sonucunda ödeyeceği cezayı minimize etmek için bu sistem, aylık üretim tahmini ile önlem alabilme şansı vardır. Yine bu çalışma paket uygulamalar bütünü haline getirilerek elektrik dağıtım şirketlerinde kullanılan SCADA sistemlerine veri sağlayabileceği gibi SCADA sistemlerinden gelen farklı verileri de kapsayarak yardımcı çıkarımlarda bulunabilmesine destek sağlayacaktır. Bunun yanında derin öğrenme modelinin sürekli olarak geliştirilmesi, optimize edilmesi önem taşımaktadır. Bu çalışma, temel (başlangıç) düzeyde sistemlerden elde edilen anlık veriler kullanılarak sürekli eğitilebilir. Eğitimler sayesinde modelin öğrenme kabiliyeti geliştirilebilir. GES'lerin standart ömürlerinin 25 yıl olduğunu düşünürsek ve geriye dönük 3 yıllık verilerin optimum seviyede çalışma yapmak için yeterli olduğu düşünülürse, GES'ler için bu tip çalışmaların önemli olduğunu söyleyebiliriz.

## 6. KAYNAKLAR

- Abdel-Nasser, M. ve Mahmoud, K., 2017, Accurate photovoltaic power forecasting models using deep LSTM-RNN, *Neural Computing and Applications*, 31 (7), 2727-2740.
- Agrawal, R. K., Muchahary, F. ve Tripathi, M. M., 2018, Long term load forecasting with hourly predictions based on long-short-term-memory networks, *2018 IEEE Texas Power and Energy Conference (TPEC)*, 1-6.
- Akaike, H., 1974, A new look at the statistical model identification, *IEEE transactions on automatic control*, 19 (6), 716-723.
- Anaconda\_Navigator, 2020, Anaconda Navigator, Desktop Portal to Data Science, <https://docs.anaconda.com/anaconda/navigator/>: [07.03.2020].
- anonymous, 2017, MSE, RMSE, MAE, MAPE ve Diğer Metrikler, <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>: [07.03.2020].
- Balluff, S., Bendfeld, J. ve Krauter, S., 2015, Short term wind and energy prediction for offshore wind farms using neural networks, *2015 International Conference on Renewable Energy Research and Applications (ICRERA)*, 379-382.
- Box, G. E. P. ve Jenkins, G. M., 1970, Time series analysis: forecasting and control, Holden-Day, p.
- BrainCreators, 2017, An introduction to AI & BrainCreators, <https://www.slideshare.net/braincreators/artificial-intelligence-braincreators>: [16.05.2020].
- Cenek, M., Haro, R., Sayers, B. ve Peng, J., 2018, Climate change and power security: Power load prediction for rural electrical microgrids using long short term memory and artificial neural networks, *Applied Sciences*, 8 (5), 749.
- International Electrotechnical Commission, 2018. Artificial intelligence across industries p. 37.
- Çarkacı, N., 2018, Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>: [16.05.2020].
- Dickey, D. A. ve Fuller, W. A., 1979, Distribution of the estimators for autoregressive time series with a unit root, *Journal of the American statistical association*, 74 (366a), 427-431.
- Dodge, J., 2018, How silicon carbide helps to get the best from a solar PV system, <https://www.eenewspower.com/news/how-silicon-carbide-helps-get-best-solar-pv-system>: [16.05.2020].
- Donat, W., 2015, What is Python: An Intro to a Cross-Platform Programming Language, <https://www.atlantic.net/vps-hosting/what-is-python-intro-cross-platform-programming-language/>: [16.05.2020].
- Flickr\_photo, 2007, SOLUCAR PS10, <https://www.flickr.com/photos/afloresm/1448540190>: [16.05.2020].
- Gensler, A., Henze, J., Sick, B. ve Raabe, N., 2016, Deep Learning for solar power forecasting—An approach using AutoEncoder and LSTM Neural Networks, *2016 IEEE international conference on systems, man, and cybernetics (SMC)*, 002858-002865.
- Ghofrani, M. ve Alolayan, M., 2018, Time series and renewable energy forecasting, *Time series analysis and applications*, 77-92.

- Gupta, R., 2019, 6 Deep Learning models — When should you use them?, <https://towardsdatascience.com/6-deep-learning-models-10d20afec175>: [16.05.2020].
- Hanedar, A. Ö., Akkaya, O. ve Bizim, Ç., 2005, Durağanlık Analizi, Birim Kök Testleri ve Trend, <http://debis.deu.edu.tr/userweb/onder.hanedar/dosyalar/Metin.pdf>: [16.05.2020].
- Heidmann, L., 2019, AI vs. Machine Learning vs. Deep Learning, <https://blog.dataiku.com/ai-vs.-machine-learning-vs.-deep-learning>: [07.03.2020].
- Hochreiter, S. ve Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation*, 9 (8), 1735-1780.
- Huang, C.-J. ve Kuo, P.-H., 2018, A deep cnn-lstm model for particulate matter (PM<sub>2.5</sub>) forecasting in smart cities, *Sensors*, 18 (7), 2220.
- Kaelbling, L. P., Littman, M. L. ve Moore, A. W., 1996, Reinforcement learning: A survey, *Journal of artificial intelligence research*, 4, 237-285.
- Kaplan, K., 2019, Python ve Anaconda Kurulumu, <https://medium.com/kodcular/python-ve-anaconda-kurulumu-b8931bd80e64>: [07.03.2020].
- Karabacak, K. ve Cetin, N., 2014, Artificial neural networks for controlling wind-PV power systems: A review, *Renewable & Sustainable Energy Reviews*, 29, 804-827.
- Keras, 2020, About Keras, <https://keras.io/about/#about-keras>: [07.03.2020].
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y. ve Zhang, Y., 2017, Short-term residential load forecasting based on LSTM recurrent neural network, *IEEE Transactions on Smart Grid*, 10 (1), 841-851.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *nature*, 521 (7553), 436-444.
- Lee, D. ve Kim, K., 2019, Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information, *Energies*, 12 (2), 215.
- Li, Z., Rahman, S., Vega, R. ve Dong, B., 2016, A hierarchical approach using machine learning methods in solar photovoltaic energy production forecasting, *Energies*, 9 (1), 55.
- Lütkepohl, H., Krätzig, M. ve Phillips, P. C., 2004, Applied time series econometrics, Cambridge university press, p.
- Marino, D. L., Amarasinghe, K. ve Manic, M., 2016, Building energy load forecasting using deep neural networks, *IECON 2016-42nd Annual Conference of the IEEE Industrial Electronics Society*, 7046-7051.
- mgm.gov.tr, 2018, Türkiye Global Güneş Radyasyonu Uzun Yıllar Ortalaması (2004-2018), [https://www.mgm.gov.tr/kurumici/radyasyon\\_iller.aspx](https://www.mgm.gov.tr/kurumici/radyasyon_iller.aspx): [16.05.2020].
- Okonkwo, T., 2019, Hyperparameter Optimization-Building an Optimal Model, [https://medium.com/@THOR\\_mas/hyperparameter-optimization-building-an-optimal-model-b11677bf3dfc](https://medium.com/@THOR_mas/hyperparameter-optimization-building-an-optimal-model-b11677bf3dfc): [16.05.2020].
- Olah, C., 2015, Understanding LSTM Networks, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>: [07.03.2020].
- Öztemel, E., 2012, Yapay sinir ağları, *Papatya Yayıncılık, İstanbul*.
- Paterakis, N. G., Mocanu, E., Gibescu, M., Stappers, B. ve van Alst, W., 2017, Deep learning versus traditional machine learning methods for aggregated energy demand prediction, *2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*, 1-6.

- PMR\_Press\_Release, 2019, Global Solar Thermal Collector Market Research analysis and Forecast – 2024, <https://pmpressrelease.com/global-solar-thermal-collector-market/>: [16.05.2020].
- Proente, 2019, Makine Öğrenimi Derin Öğrenme ve Yapay Zeka Arasındaki Fark, <https://proente.com/makine-ogrenimi-derin-ogrenme-ve-yapay-zeka-arasindaki-fark/>: [16.05.2020].
- Roy, R., 2019, AI, ML, and DL: How not to get them mixed!, <https://towardsdatascience.com/understanding-the-difference-between-ai-ml-and-dl-cceb63252a6c>: [16.05.2020].
- Samuel, A. L., 1959, Some studies in machine learning using the game of checkers, *IBM Journal of research and development*, 3 (3), 210-229.
- Saraçoğlu, O. G., 2018, Yapay Fotosentez Ve Enerji Üretimi, <https://www.bilgiustam.com/yapay-fotosentez-enerji-uretimi/>: [16.05.2020].
- Seabold, S. ve Perktold, J., 2010, Statsmodels: Econometric and Statistical Modeling with Python.
- Sharadga, H., Hajimirza, S. ve Balog, R. S., 2020, Time series forecasting of solar power generation for large-scale photovoltaic plants, *Renewable Energy*, 150, 797-807.
- Smith, T. G., 2020, pmdarima: ARIMA estimators for Python, <http://alkaline-ml.com/pmdarima/index.html>: [16.05.2020].
- statsmodels.org, 2020, Seasonal-Trend decomposition using LOESS (STL), [https://www.statsmodels.org/stable/examples/notebooks/generated/stl\\_decomposition.html](https://www.statsmodels.org/stable/examples/notebooks/generated/stl_decomposition.html): [16.05.2020].
- Şafak, H. İ., 2017, Makine Öğrenmesi Nedir ?, <https://medium.com/t%C3%BCrkiye/makine-%C3%B6%C4%9Frenmesi-nedir-20dee450b56e>: [07.03.2020].
- Şencan, U., 2018, Short term electricity price forecasting using Long Short-Term Memory, Master of Science Thesis, *Bahçeşehir University*, Graduate School of Natural and Applied Sciences.
- TRAI, 2018, Yapay Zeka Zaman Çizelgesi, <https://turkiye.ai/yapay-zeka-zaman-cizelgesi/>: [16.05.2020].
- Ucal, M. Ş., 2006, Ekonometrik Model Seçim Kriterleri Üzerine Kısa Bir İnceleme, *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*.
- Van Otterlo, M. ve Wiering, M., 2012, Reinforcement learning and markov decision processes, In: Reinforcement Learning, Eds: Springer, p. 3-42.
- Wikimedia Commons, 2017, Reinforcement learning diagram, [https://commons.wikimedia.org/wiki/File:Reinforcement\\_learning\\_diagram.svg](https://commons.wikimedia.org/wiki/File:Reinforcement_learning_diagram.svg): [07.03.2020].
- Yarris, L., 2015, Another milestone in hybrid artificial photosynthesis, <https://phys.org/news/2015-08-milestone-hybrid-artificial-photosynthesis.html>: [16.05.2020].
- Yavuz, A., 2017, Zaman Serisi Analizleri, <http://www.mku.edu.tr/files/339-8868446a-e4c0-4070-8530-b8beccc1b0ec.pdf>: [07.03.2020].
- Zeydan, Ö., 2014, Zonguldak bölgesi pm10 konsantrasyonu dağılımının modellenmesi, Doktora Tezi, *Kocaeli Üniversitesi*.

**EKLER****EK-1 Santral\_A üretilen enerji ve tahmin sonuçları (Son 234 gün).**

Günler	Üretilen Enerji (kWh)	SARIMA Predictions	LSTM Predictions
2019-05-12	5985,00	4260,33	6272,11
2019-05-13	4941,00	7267,76	6149,98
2019-05-14	7774,00	7733,11	5647,48
2019-05-15	8096,00	8183,02	6788,78
2019-05-16	7959,00	7875,11	7216,17
2019-05-17	7844,00	7233,11	7432,98
2019-05-18	6989,00	6947,35	7141,30
2019-05-19	6327,00	5915,80	6785,14
2019-05-20	7009,00	5307,28	6454,15
2019-05-21	6246,00	6778,81	6617,30
2019-05-22	6941,00	4835,66	6354,04
2019-05-23	5634,00	7811,85	6613,54
2019-05-24	5464,00	6496,80	5986,22
2019-05-25	5105,00	6324,20	5822,21
2019-05-26	6406,00	3594,86	5531,47
2019-05-27	7393,00	7318,66	6108,45
2019-05-28	7394,00	6400,55	6688,25
2019-05-29	8021,00	6396,48	6899,25
2019-05-30	6280,00	5754,44	7233,48
2019-05-31	6282,00	5085,42	6475,98
2019-06-01	6281,00	2421,41	6369,87
2019-06-02	6280,00	4858,40	6257,35
2019-06-03	6574,00	6689,40	6302,31
2019-06-04	6926,00	7038,40	6355,96
2019-06-05	6142,00	7257,39	6565,52
2019-06-06	6385,00	6725,39	6232,89
2019-06-07	7762,00	7591,39	6291,50
2019-06-08	7760,00	7667,39	6924,42
2019-06-09	7397,00	7747,39	7146,81
2019-06-10	7198,00	7307,39	7020,54
2019-06-11	4335,00	7673,39	6813,30
2019-06-12	6440,00	8025,39	5635,28
2019-06-13	5735,00	1067,39	6203,57
2019-06-14	7096,00	6876,39	5924,04
2019-06-15	3761,00	4707,39	6624,70
2019-06-16	6818,00	2619,39	4845,75
2019-06-17	6070,00	5482,39	6247,82
2019-06-18	6568,00	4998,39	5981,43
2019-06-19	7783,00	5422,39	6363,15
2019-06-20	5616,00	6785,39	6866,43
2019-06-21	5156,00	5615,39	6093,28
2019-06-22	5503,00	7397,39	5681,35
2019-06-23	5086,00	6438,39	5740,55
2019-06-24	5734,00	6941,39	5515,15
2019-06-25	7229,00	6376,39	5621,71
2019-06-26	7720,00	7225,39	6489,07
2019-06-27	7410,00	6930,39	7016,85
2019-06-28	7410,00	7388,39	6976,20
2019-06-29	7740,00	7882,39	6924,26
2019-06-30	6272,00	7427,39	7038,31
2019-07-01	7494,00	7503,39	6491,43
2019-07-02	7494,00	7388,39	6868,38
2019-07-03	8293,00	7074,39	6886,43
2019-07-04	8066,00	7591,39	7440,46

2019-07-05	7789,00	7861,39	7280,53
2019-07-06	7723,00	7901,39	7193,68
2019-07-07	7122,00	7650,39	7045,48
2019-07-08	6802,00	6706,39	6825,32
2019-07-09	7436,00	6848,39	6656,06
2019-07-10	7252,00	7378,39	6847,41
2019-07-11	7508,00	7349,39	6857,83
2019-07-12	6926,00	7052,39	6996,58
2019-07-13	7192,00	7585,39	6708,41
2019-07-14	5617,00	7231,39	6804,73
2019-07-15	7160,00	4978,39	6107,04
2019-07-16	6655,00	7349,39	6656,02
2019-07-17	6636,00	7447,39	6467,97
2019-07-18	6909,00	7202,39	6538,28
2019-07-19	5029,00	7002,39	6542,65
2019-07-20	5533,00	7047,39	5764,73
2019-07-21	5534,00	6580,39	5780,76
2019-07-22	7898,00	6198,39	5725,08
2019-07-23	6273,00	6782,39	6963,63
2019-07-24	6431,00	7035,39	6237,38
2019-07-25	7333,00	6590,39	6342,62
2019-07-26	7490,00	6499,39	6660,67
2019-07-27	7516,00	6934,39	6991,10
2019-07-28	7504,00	7440,39	7021,81
2019-07-29	7763,00	7365,39	6972,88
2019-07-30	7651,00	7326,39	7085,18
2019-07-31	7248,00	6512,39	7063,06
2019-08-01	7338,00	7282,39	6900,34
2019-08-02	7288,00	7131,39	6871,09
2019-08-03	7304,00	7520,39	6851,17
2019-08-04	6387,00	5802,39	6885,11
2019-08-05	6724,00	6570,39	6474,09
2019-08-06	6775,00	5631,39	6530,67
2019-08-07	6620,00	3643,39	6532,20
2019-08-08	7665,00	6876,39	6511,81
2019-08-09	7910,00	7276,39	6948,94
2019-08-10	7857,00	6978,39	7169,91
2019-08-11	7771,00	7757,39	7247,29
2019-08-12	7782,00	7630,39	7120,39
2019-08-13	7759,00	7713,39	7097,45
2019-08-14	7475,00	7587,39	7092,05
2019-08-15	7475,00	7521,39	6986,47
2019-08-16	5759,00	7341,39	6955,91
2019-08-17	5525,00	7125,39	6250,10
2019-08-18	5526,00	7076,39	5978,21
2019-08-19	6959,00	7216,39	5837,94
2019-08-20	3546,00	7184,39	6477,16
2019-08-21	5004,00	6664,39	4716,17
2019-08-22	4242,00	6521,39	5179,67
2019-08-23	5614,00	7188,39	4889,91
2019-08-24	5775,00	7056,39	5384,76
2019-08-25	7341,00	6965,39	5414,66
2019-08-26	6813,00	6858,39	6569,70
2019-08-27	7319,00	6400,39	6444,62
2019-08-28	7075,00	6723,39	6848,59
2019-08-29	7372,00	6788,39	6702,12
2019-08-30	7414,00	6959,39	6913,98
2019-08-31	7163,00	6851,39	6903,83
2019-09-01	7081,00	6814,39	6842,84
2019-09-02	7051,00	2627,39	6759,96

2019-09-03	7051,00	6809,39	6729,60
2019-09-04	6885,00	6622,39	6736,74
2019-09-05	6810,00	6319,39	6658,23
2019-09-06	6267,00	6273,39	6605,70
2019-09-07	6150,00	6634,39	6342,05
2019-09-08	4895,00	6476,39	6226,59
2019-09-09	4045,00	3338,39	5585,74
2019-09-10	6930,00	5705,39	4991,04
2019-09-11	6760,00	5580,39	6192,41
2019-09-12	6853,00	6748,39	6337,83
2019-09-13	6777,00	6666,39	6485,92
2019-09-14	6819,00	6248,39	6441,67
2019-09-15	6931,00	6258,39	6590,13
2019-09-16	4560,00	6443,39	6632,70
2019-09-17	3169,00	6641,39	5547,15
2019-09-18	4566,00	6863,39	4676,18
2019-09-19	6639,00	6783,39	5024,84
2019-09-20	6956,00	6533,39	5968,86
2019-09-21	6883,00	6148,39	6255,18
2019-09-22	6945,00	6439,39	6397,55
2019-09-23	2122,00	6542,39	6571,28
2019-09-24	7208,00	6447,39	4457,64
2019-09-25	7046,00	6251,39	6270,98
2019-09-26	6674,00	1673,39	6440,79
2019-09-27	2688,00	4831,39	6498,44
2019-09-28	6530,00	6283,39	4282,00
2019-09-29	6434,00	4867,39	6017,22
2019-09-30	6570,00	4533,39	6123,14
2019-10-01	6757,00	5209,39	6295,34
2019-10-02	6645,00	6361,39	6294,03
2019-10-03	6539,00	6139,39	6476,02
2019-10-04	6269,00	6125,39	6418,73
2019-10-05	6222,00	6348,39	6276,85
2019-10-06	6470,00	6766,39	6227,02
2019-10-07	3812,00	6529,39	6317,00
2019-10-08	6034,00	4365,39	5026,57
2019-10-09	5134,00	4321,39	5815,95
2019-10-10	5312,00	5595,39	5446,74
2019-10-11	6143,00	5131,39	5372,52
2019-10-12	5993,00	3159,39	5767,20
2019-10-13	3380,00	3861,39	5908,62
2019-10-14	6049,00	6182,39	4476,84
2019-10-15	6244,00	5614,39	5672,53
2019-10-16	5702,00	4631,39	5945,97
2019-10-17	4016,00	2578,39	5657,72
2019-10-18	4742,00	4158,39	4716,63
2019-10-19	3718,00	4272,39	5133,58
2019-10-20	5842,00	5153,39	4548,49
2019-10-21	4241,00	3004,39	5368,54
2019-10-22	5547,00	3704,39	4529,21
2019-10-23	4859,00	5068,39	5207,92
2019-10-24	1070,00	3485,39	5001,99
2019-10-25	2385,00	859,39	3103,23
2019-10-26	5332,00	6246,39	3452,99
2019-10-27	5651,00	6196,39	4777,34
2019-10-28	5651,00	6100,39	4757,61
2019-10-29	4255,00	5938,39	4812,07
2019-10-30	920,00	5714,39	4583,73
2019-10-31	4749,00	5581,39	3258,24
2019-11-01	5465,00	5581,39	4624,33

2019-11-02	5397,00	5644,39	5009,67
2019-11-03	2524,00	5575,39	4684,58
2019-11-04	4706,00	5100,39	3369,28
2019-11-05	5669,00	5344,39	4728,30
2019-11-06	5239,00	5599,39	5337,63
2019-11-07	4805,00	5345,39	4997,22
2019-11-08	5279,00	5150,39	4771,18
2019-11-09	5398,00	4809,39	5289,37
2019-11-10	5187,00	5026,39	5418,42
2019-11-11	5040,00	4656,39	5265,22
2019-11-12	4887,00	4841,39	5180,91
2019-11-13	4678,00	3644,39	5123,66
2019-11-14	4677,00	3085,39	4969,75
2019-11-15	3964,00	4995,39	4895,85
2019-11-16	1758,00	2732,39	4462,38
2019-11-17	1759,00	2219,39	3282,10
2019-11-18	2493,00	2311,39	3091,21
2019-11-19	4159,00	4693,39	3177,27
2019-11-20	4809,00	3604,39	3550,21
2019-11-21	2548,00	1465,39	3858,63
2019-11-22	2434,00	4111,39	2874,41
2019-11-23	2915,00	662,39	3136,43
2019-11-24	2720,00	1861,39	3532,28
2019-11-25	3712,00	1861,39	3109,63
2019-11-26	2748,00	3129,39	3354,85
2019-11-27	2002,00	1290,39	3008,48
2019-11-28	1801,00	2092,39	2671,87
2019-11-29	3015,00	500,39	2714,17
2019-11-30	3787,00	1792,39	3100,35
2019-12-01	2940,00	1466,39	3306,19
2019-12-02	3568,00	2886,39	2849,48
2019-12-03	696,00	1844,39	3368,27
2019-12-04	3107,00	920,39	2407,00
2019-12-05	4356,00	197,39	3173,09
2019-12-06	3742,00	457,39	3856,52
2019-12-07	1036,00	1158,39	3254,83
2019-12-08	1116,00	2748,39	2223,45
2019-12-09	1575,00	4130,39	2611,17
2019-12-10	1018,00	3537,39	2715,55
2019-12-11	667,00	3171,39	2012,56
2019-12-12	2063,00	956,39	1772,57
2019-12-13	1343,00	3589,39	2275,25
2019-12-14	667,00	2225,39	1973,57
2019-12-15	2297,00	3511,39	1683,40
2019-12-16	1389,00	1683,39	2405,12
2019-12-17	3897,00	1880,39	2070,48
2019-12-18	2489,00	2206,39	2933,71
2019-12-19	3967,00	471,39	2577,83
2019-12-20	3376,00	530,39	3298,38
2019-12-21	4112,00	1308,39	3405,62
2019-12-22	3452,00	1789,39	3830,58
2019-12-23	4065,00	3498,39	3624,83
2019-12-24	2079,00	4002,39	3988,81
2019-12-25	3488,00	2145,39	3092,78
2019-12-26	152,00	349,39	3595,82
2019-12-27	1320,00	519,39	2304,99
2019-12-28	250,00	2757,39	2308,02
2019-12-29	1414,00	4358,39	2116,41
2019-12-30	531,00	848,39	1983,57
2019-12-31	20,00	1131,39	1754,56

## EK-2 Santral\_B üretilen enerji ve tahmin sonuçları (Son 214 gün).

Günler	Üretilen Enerji (kWh)	SARIMA Predictions	LSTM Predictions
2019-06-01	7302,00	6291,01	6940,21
2019-06-02	7301,00	5745,80	6946,58
2019-06-03	4912,00	9491,57	6920,89
2019-06-04	5122,00	8709,83	5899,78
2019-06-05	6796,00	9073,82	5749,57
2019-06-06	7540,00	8048,67	6456,08
2019-06-07	7770,00	7772,06	6771,27
2019-06-08	7646,00	7976,25	6802,84
2019-06-09	7450,00	7912,32	6880,57
2019-06-10	6214,00	8431,73	6957,09
2019-06-11	6257,00	8234,91	6533,60
2019-06-12	4610,00	7245,00	6478,51
2019-06-13	7525,00	8421,64	5631,86
2019-06-14	4912,00	8483,86	6770,31
2019-06-15	5566,00	7314,94	5597,80
2019-06-16	6913,00	6794,38	5619,49
2019-06-17	4707,00	5011,80	6306,52
2019-06-18	5488,00	7885,93	5468,01
2019-06-19	5489,00	6296,57	5478,45
2019-06-20	5490,00	5333,59	5677,28
2019-06-21	4085,00	7144,88	5646,05
2019-06-22	2678,00	5982,36	4709,82
2019-06-23	5007,00	8003,99	3813,30
2019-06-24	4832,00	6531,72	4948,30
2019-06-25	6947,00	7857,52	4923,43
2019-06-26	6946,00	5441,38	5825,91
2019-06-27	7273,00	8158,28	6064,69
2019-06-28	6978,00	7052,20	6548,18
2019-06-29	7396,00	8623,15	6538,59
2019-06-30	5887,00	8232,11	6883,80
2019-07-01	6442,00	8369,08	6285,73
2019-07-02	8069,00	8281,06	6457,24
2019-07-03	8011,00	7782,04	7046,37
2019-07-04	7906,00	7660,03	7116,39
2019-07-05	7735,00	8535,03	7063,66
2019-07-06	7685,00	8620,02	7054,42
2019-07-07	7345,00	8507,02	7131,23
2019-07-08	7752,00	8351,01	7007,21
2019-07-09	7540,00	8228,01	7122,17
2019-07-10	7551,00	8243,01	7035,73
2019-07-11	7224,00	8364,01	7046,85
2019-07-12	6976,00	7946,01	6904,22
2019-07-13	5228,00	8261,01	6825,47
2019-07-14	5595,00	8363,01	6036,02
2019-07-15	7290,00	6650,01	6026,34
2019-07-16	6728,00	7914,01	6688,18
2019-07-17	6662,00	8273,01	6467,18
2019-07-18	6249,00	8386,00	6335,29
2019-07-19	4614,00	8048,00	6257,44
2019-07-20	3518,00	7777,00	5546,75
2019-07-21	7322,00	7661,00	4667,38
2019-07-22	7643,00	7182,00	6448,00
2019-07-23	6991,00	7064,00	6654,67
2019-07-24	6361,00	6826,00	6344,92
2019-07-25	7791,00	6537,00	6169,27
2019-07-26	6561,00	7364,00	7030,51
2019-07-27	7135,00	6886,00	6609,83

2019-07-28	7522,00	7447,00	6767,37
2019-07-29	7561,00	8354,00	6876,14
2019-07-30	7473,00	7378,00	7013,71
2019-07-31	7384,00	7282,00	6925,51
2019-08-01	7442,00	6239,00	6940,74
2019-08-02	6838,00	8164,00	6981,30
2019-08-03	6787,00	8160,00	6759,05
2019-08-04	7298,00	8384,00	6701,38
2019-08-05	7272,00	5918,00	6861,50
2019-08-06	6326,00	7531,00	6861,12
2019-08-07	3715,00	7680,00	6447,99
2019-08-08	6371,00	6633,00	5097,30
2019-08-09	7658,00	8021,00	6222,60
2019-08-10	7529,00	8165,00	6774,32
2019-08-11	7522,00	7386,00	6735,13
2019-08-12	7469,00	8780,00	6688,94
2019-08-13	7441,00	8534,00	6918,63
2019-08-14	7507,00	8378,00	6995,24
2019-08-15	6832,00	8386,00	7005,70
2019-08-16	4707,00	8303,00	6759,57
2019-08-17	4922,00	8168,00	5766,71
2019-08-18	6545,00	7884,00	5638,48
2019-08-19	5588,00	8086,00	6313,51
2019-08-20	3479,00	8062,00	5772,25
2019-08-21	5141,00	8008,00	4314,39
2019-08-22	3927,00	7233,00	5206,33
2019-08-23	4231,00	7456,00	4758,03
2019-08-24	4733,00	7971,00	4437,18
2019-08-25	7071,00	7944,00	4704,75
2019-08-26	6982,00	7912,00	6084,40
2019-08-27	6814,00	7555,00	6159,11
2019-08-28	7172,00	7160,00	6251,20
2019-08-29	7213,00	7604,00	6590,65
2019-08-30	6317,00	7085,00	6810,07
2019-08-31	7006,00	7737,00	6448,41
2019-09-01	6526,00	7836,00	6688,56
2019-09-02	6991,00	7352,00	6518,59
2019-09-03	6385,00	7859,00	6681,82
2019-09-04	6646,00	7866,00	6383,30
2019-09-05	6040,00	7643,00	6514,98
2019-09-06	6318,00	7617,00	6215,94
2019-09-07	5421,00	6650,00	6314,55
2019-09-08	5950,00	6830,00	5839,32
2019-09-09	6601,00	7547,00	6009,17
2019-09-10	6963,00	1076,00	6285,76
2019-09-11	6836,00	6894,00	6494,36
2019-09-12	6772,00	6200,00	6442,37
2019-09-13	6315,00	7462,00	6507,97
2019-09-14	6764,00	6207,00	6375,13
2019-09-15	6792,00	6187,00	6562,87
2019-09-16	3896,00	5881,00	6566,50
2019-09-17	4273,00	7509,00	5127,74
2019-09-18	3942,00	7180,00	4984,36
2019-09-19	6807,00	7068,00	4829,52
2019-09-20	6748,00	7892,00	6047,72
2019-09-21	6666,00	7802,00	5986,97
2019-09-22	6614,00	7595,00	6080,72
2019-09-23	2035,00	7591,00	6233,16
2019-09-24	7047,00	7611,00	4121,74
2019-09-25	6886,00	7493,00	6333,24

2019-09-26	6404,00	7472,00	6384,12
2019-09-27	3507,00	2112,00	6027,26
2019-09-28	6390,00	4069,00	4385,57
2019-09-29	4686,00	6837,00	6166,57
2019-09-30	6867,00	5578,00	5413,67
2019-10-01	6710,00	3755,00	6172,00
2019-10-02	6540,00	3756,00	6127,09
2019-10-03	6487,00	7032,00	6304,47
2019-10-04	5574,00	7089,00	6241,78
2019-10-05	5641,00	6778,00	6003,95
2019-10-06	6312,00	6778,00	5922,43
2019-10-07	3436,00	6767,00	6193,25
2019-10-08	2830,00	7107,00	4667,77
2019-10-09	4419,00	7157,00	3838,22
2019-10-10	2932,00	3673,00	4730,97
2019-10-11	5572,00	6487,00	3826,72
2019-10-12	4438,00	5012,00	4762,10
2019-10-13	4535,00	6244,00	4525,03
2019-10-14	5937,00	2621,00	4474,45
2019-10-15	6183,00	5405,00	5388,40
2019-10-16	6051,00	6902,00	5845,47
2019-10-17	5292,00	6091,00	5743,85
2019-10-18	4698,00	5285,00	5486,72
2019-10-19	4785,00	4854,00	5262,50
2019-10-20	5345,00	5456,00	5232,05
2019-10-21	5772,00	6055,00	5431,41
2019-10-22	5634,00	4977,00	5578,07
2019-10-23	5531,00	4945,00	5511,81
2019-10-24	1070,00	6202,00	5524,80
2019-10-25	2624,00	5197,00	3139,43
2019-10-26	5954,00	1780,00	3422,23
2019-10-27	5919,00	7344,00	5369,29
2019-10-28	5722,00	7316,00	5256,46
2019-10-29	4234,00	7220,00	4896,88
2019-10-30	4745,00	7124,00	4634,36
2019-10-31	5429,00	6715,00	5128,74
2019-11-01	5511,00	6508,00	5483,40
2019-11-02	5213,00	6509,00	5443,53
2019-11-03	879,00	6742,00	5198,14
2019-11-04	5231,00	6854,00	2885,09
2019-11-05	5825,00	6449,00	4887,49
2019-11-06	5176,00	6603,00	5508,81
2019-11-07	4566,00	6518,00	4822,78
2019-11-08	5439,00	6480,00	4444,77
2019-11-09	5498,00	6314,00	5438,95
2019-11-10	5392,00	5926,00	5540,51
2019-11-11	5077,00	5926,00	5384,98
2019-11-12	5019,00	5981,00	5227,67
2019-11-13	4860,00	6192,00	5263,59
2019-11-14	4890,00	3189,00	5155,15
2019-11-15	3530,00	6568,00	5104,40
2019-11-16	3241,00	4710,00	4296,25
2019-11-17	469,00	3005,00	3927,98
2019-11-18	3114,00	1685,00	2448,37
2019-11-19	5093,00	3465,00	3326,27
2019-11-20	2620,00	4616,00	4511,21
2019-11-21	3195,00	3973,00	3037,64
2019-11-22	5347,00	2637,00	3057,20
2019-11-23	4727,00	4381,00	4846,33
2019-11-24	3191,00	1961,00	4694,58

2019-11-25	4070,00	6312,00	3551,41
2019-11-26	3326,00	5407,00	4208,49
2019-11-27	2785,00	3316,00	4063,80
2019-11-28	1023,00	2363,00	3402,83
2019-11-29	2179,00	1618,00	2435,22
2019-11-30	4746,00	1350,00	2820,81
2019-12-01	1176,00	1700,00	4169,30
2019-12-02	3747,00	2586,00	2396,83
2019-12-03	532,00	3781,00	3160,45
2019-12-04	4539,00	2850,00	2435,83
2019-12-05	4854,00	2846,00	3823,93
2019-12-06	1982,00	4127,00	4339,11
2019-12-07	1679,00	1316,00	2677,33
2019-12-08	5051,00	2209,00	2390,68
2019-12-09	1268,00	3874,00	4639,34
2019-12-10	1558,00	3884,00	2765,64
2019-12-11	626,00	3021,00	2064,15
2019-12-12	4458,00	4142,00	2249,21
2019-12-13	1520,00	1944,00	3854,49
2019-12-14	1134,00	5848,00	2557,80
2019-12-15	2122,00	2172,00	1806,78
2019-12-16	2237,00	4136,00	2690,07
2019-12-17	2692,00	2638,00	2865,08
2019-12-18	3256,00	2754,00	2772,03
2019-12-19	4579,00	3326,00	3150,30
2019-12-20	4743,00	2429,00	4000,66
2019-12-21	4759,00	2688,00	4304,41
2019-12-22	3470,00	5677,00	4467,98
2019-12-23	4455,00	3834,00	3978,16
2019-12-24	877,00	4481,00	4552,32
2019-12-25	516,00	5272,00	2771,15
2019-12-26	1334,00	1645,00	1978,03
2019-12-27	465,00	990,00	2541,93
2019-12-28	829,00	1016,00	2035,79
2019-12-29	1170,00	2187,00	1860,83
2019-12-30	521,00	3869,00	2112,33
2019-12-31	389,00	1730,00	1856,40

## EK-3 Santral\_C üretilen enerji ve tahmin sonuçları (Son 214 gün).

Günler	Üretilen Enerji (kWh)	SARIMA Predictions	LSTM Predictions
2019-06-01	7377,00	8818,41	6847,59
2019-06-02	7378,00	5785,55	6771,13
2019-06-03	5545,00	8251,34	6719,39
2019-06-04	5283,00	8801,94	6074,21
2019-06-05	6856,00	9195,22	5851,45
2019-06-06	7244,00	6910,29	6334,70
2019-06-07	8091,00	5653,24	6464,21
2019-06-08	7684,00	7562,87	6967,10
2019-06-09	7932,00	8724,54	6930,21
2019-06-10	7434,00	8227,00	7011,61
2019-06-11	5674,00	6242,31	6808,01
2019-06-12	5506,00	7917,77	6172,55
2019-06-13	6905,00	8731,85	5991,80
2019-06-14	5360,00	8670,14	6370,61
2019-06-15	7015,00	6907,35	5753,70
2019-06-16	7789,00	5956,25	6402,66
2019-06-17	6143,00	5459,67	6770,62
2019-06-18	6351,00	7415,48	6202,22
2019-06-19	5710,00	6966,58	6295,09
2019-06-20	5864,00	5437,91	5993,86
2019-06-21	4037,00	5184,40	5978,63
2019-06-22	4895,00	5321,02	5031,03
2019-06-23	5688,00	6611,73	5247,05
2019-06-24	6825,00	6493,51	5525,29
2019-06-25	7804,00	7472,35	6084,72
2019-06-26	7988,00	6126,23	6696,25
2019-06-27	7414,00	8456,13	6976,74
2019-06-28	7316,00	7604,06	6850,52
2019-06-29	7384,00	8635,01	6794,08
2019-06-30	7739,00	7319,97	6727,86
2019-07-01	7534,00	8013,94	6817,17
2019-07-02	8245,00	7528,92	6793,87
2019-07-03	8149,00	8530,90	7057,23
2019-07-04	8090,00	8653,89	7016,43
2019-07-05	7963,00	8822,88	7016,76
2019-07-06	7845,00	8743,87	6991,99
2019-07-07	7800,00	8787,87	6893,62
2019-07-08	7882,00	2860,86	6878,82
2019-07-09	7561,00	7496,86	6898,95
2019-07-10	7798,00	7608,86	6807,63
2019-07-11	7432,00	7971,86	6890,84
2019-07-12	6628,00	8316,86	6760,55
2019-07-13	5475,00	8388,85	6494,24
2019-07-14	6162,00	8509,85	6024,58
2019-07-15	6921,00	8050,85	6159,63
2019-07-16	7086,00	8454,85	6365,85
2019-07-17	6257,00	8688,85	6474,93
2019-07-18	6550,00	8719,85	6200,61
2019-07-19	3958,00	3787,85	6350,68
2019-07-20	4444,00	7109,85	5236,51
2019-07-21	7380,00	8240,85	5196,26
2019-07-22	7942,00	8413,85	6336,66
2019-07-23	7755,00	8380,85	6641,02
2019-07-24	6714,00	8206,85	6869,80
2019-07-25	7995,00	5950,85	6580,97
2019-07-26	6901,00	6244,85	6968,26
2019-07-27	7429,00	7179,85	6527,53

2019-07-28	7738,00	7848,85	6754,85
2019-07-29	7759,00	8460,85	6871,71
2019-07-30	7496,00	8277,85	6829,40
2019-07-31	7523,00	7916,85	6836,25
2019-08-01	7563,00	6644,85	6818,50
2019-08-02	6901,00	8376,85	6795,59
2019-08-03	7167,00	8420,85	6574,22
2019-08-04	7572,00	7403,85	6661,18
2019-08-05	7467,00	6966,85	6758,74
2019-08-06	5674,00	7821,85	6736,75
2019-08-07	3918,00	8102,85	6119,29
2019-08-08	6716,00	7858,85	5278,18
2019-08-09	7919,00	7947,85	6226,52
2019-08-10	7858,00	7764,85	6608,90
2019-08-11	7837,00	7572,85	6826,58
2019-08-12	7809,00	8689,85	7072,42
2019-08-13	7784,00	8580,85	6974,49
2019-08-14	7855,00	8289,85	6881,12
2019-08-15	7555,00	8594,85	6905,08
2019-08-16	4915,00	8352,85	6812,33
2019-08-17	5409,00	8180,85	5898,81
2019-08-18	6948,00	7811,85	5916,27
2019-08-19	6341,00	7862,85	6332,76
2019-08-20	4438,00	8157,85	6106,07
2019-08-21	5480,00	8112,85	5125,78
2019-08-22	4859,00	7599,85	5607,60
2019-08-23	5794,00	7872,85	5365,61
2019-08-24	6228,00	7986,85	5633,66
2019-08-25	7448,00	7794,85	5801,73
2019-08-26	7184,00	7856,85	6523,28
2019-08-27	7262,00	7593,85	6554,72
2019-08-28	7303,00	7084,85	6700,21
2019-08-29	7486,00	7729,85	6734,62
2019-08-30	6548,00	7037,85	6755,00
2019-08-31	6898,00	7735,85	6440,42
2019-09-01	7108,00	7784,85	6547,68
2019-09-02	7209,00	7711,85	6571,59
2019-09-03	6704,00	7632,85	6609,34
2019-09-04	6789,00	7730,85	6467,26
2019-09-05	6377,00	7298,85	6490,75
2019-09-06	6661,00	7259,85	6299,57
2019-09-07	4921,00	5777,85	6377,45
2019-09-08	6927,00	7530,85	5634,36
2019-09-09	7240,00	7618,85	6386,02
2019-09-10	7062,00	728,85	6489,47
2019-09-11	7087,00	8009,85	6517,23
2019-09-12	6977,00	6802,85	6632,93
2019-09-13	6918,00	7465,85	6570,72
2019-09-14	6891,00	6640,85	6534,28
2019-09-15	6944,00	5440,85	6517,98
2019-09-16	6022,00	6749,85	6528,43
2019-09-17	6087,00	7632,85	6168,72
2019-09-18	2697,00	7269,85	6143,83
2019-09-19	6655,00	6771,85	4610,41
2019-09-20	6771,00	7858,85	6063,30
2019-09-21	6687,00	7715,85	6080,19
2019-09-22	6320,00	7429,85	6166,10
2019-09-23	4331,00	7542,85	6038,54
2019-09-24	6858,00	7685,85	5362,69
2019-09-25	6883,00	7392,85	6310,05

2019-09-26	6350,00	7328,85	6285,61
2019-09-27	1840,00	1628,85	6149,54
2019-09-28	4749,00	4366,85	3783,39
2019-09-29	4786,00	7305,85	5144,22
2019-09-30	6937,00	6318,85	5094,02
2019-10-01	6741,00	5404,85	5932,16
2019-10-02	6560,00	6043,85	5884,79
2019-10-03	6797,00	6914,85	6197,97
2019-10-04	6436,00	7077,85	6422,45
2019-10-05	6204,00	7271,85	6292,89
2019-10-06	6491,00	7377,85	6185,75
2019-10-07	3787,00	7610,85	6271,85
2019-10-08	3497,00	880,85	5095,23
2019-10-09	4803,00	7074,85	4628,21
2019-10-10	1655,00	6086,85	5049,08
2019-10-11	5429,00	6793,85	3591,13
2019-10-12	5988,00	5895,85	4635,50
2019-10-13	5045,00	6456,85	5250,50
2019-10-14	6022,00	2618,85	4944,01
2019-10-15	6106,00	6090,85	5347,04
2019-10-16	5989,00	6716,85	5885,55
2019-10-17	5499,00	6284,85	5887,59
2019-10-18	3112,00	4908,85	5640,50
2019-10-19	4706,00	4361,85	4531,30
2019-10-20	4287,00	5194,85	5026,76
2019-10-21	5647,00	5938,85	4782,36
2019-10-22	5653,00	3871,85	5257,73
2019-10-23	5097,00	3791,85	5213,00
2019-10-24	1375,00	2323,85	5179,93
2019-10-25	4871,00	4599,85	3219,95
2019-10-26	5905,00	1570,85	4807,53
2019-10-27	5905,00	7385,85	5375,40
2019-10-28	5717,00	7087,85	5368,30
2019-10-29	4128,00	6835,85	5144,92
2019-10-30	4950,00	6836,85	4859,75
2019-10-31	5470,00	6422,85	5236,21
2019-11-01	5627,00	6531,85	5439,73
2019-11-02	4996,00	6531,85	5487,41
2019-11-03	728,00	6617,85	5089,46
2019-11-04	5913,00	6672,85	3050,82
2019-11-05	5628,00	6195,85	5268,27
2019-11-06	5152,00	6262,85	5286,90
2019-11-07	3651,00	6318,85	4931,17
2019-11-08	5495,00	6276,85	3649,03
2019-11-09	5406,00	6180,85	5400,86
2019-11-10	5464,00	5675,85	5357,10
2019-11-11	5157,00	4343,85	5337,94
2019-11-12	5114,00	5845,85	5137,72
2019-11-13	4923,00	5942,85	5316,12
2019-11-14	4911,00	4207,85	5187,88
2019-11-15	4015,00	4754,85	5141,26
2019-11-16	3826,00	4321,85	4624,06
2019-11-17	617,00	2864,85	4397,89
2019-11-18	3445,00	1699,85	2805,93
2019-11-19	1688,00	2964,85	3649,32
2019-11-20	1229,00	4171,85	2965,64
2019-11-21	3262,00	3930,85	2298,10
2019-11-22	2842,00	1765,85	2708,87
2019-11-23	2505,00	3143,85	3163,73
2019-11-24	2560,00	1416,85	2516,10

2019-11-25	3852,00	4135,85	2570,83
2019-11-26	2216,00	3590,85	3625,54
2019-11-27	2958,00	2965,85	2864,04
2019-11-28	1015,00	1469,85	2947,32
2019-11-29	1438,00	1368,85	2304,26
2019-11-30	3604,00	1216,85	2439,66
2019-12-01	1489,00	1307,85	3194,87
2019-12-02	2882,00	2056,85	2497,76
2019-12-03	820,00	2935,85	2407,23
2019-12-04	4874,00	2280,85	2003,78
2019-12-05	4778,00	2164,85	3928,56
2019-12-06	1172,00	2693,85	4025,08
2019-12-07	1652,00	1148,85	2314,63
2019-12-08	4564,00	1961,85	1916,41
2019-12-09	764,00	3375,85	4282,72
2019-12-10	1035,00	3249,85	2694,64
2019-12-11	761,00	3201,85	1505,00
2019-12-12	3497,00	2866,85	1970,05
2019-12-13	1093,00	2278,85	3353,57
2019-12-14	636,00	4746,85	1945,95
2019-12-15	2238,00	1482,85	1407,42
2019-12-16	2779,00	3734,85	2252,29
2019-12-17	460,00	2052,85	3020,65
2019-12-18	4193,00	1886,85	1597,23
2019-12-19	1478,00	3322,85	2995,97
2019-12-20	1426,00	1903,85	2549,77
2019-12-21	3600,00	2727,85	2069,77
2019-12-22	2107,00	3145,85	2927,91
2019-12-23	455,00	5197,85	3014,98
2019-12-24	729,00	3732,85	1540,88
2019-12-25	1536,00	4899,85	1722,75
2019-12-26	1149,00	1180,85	2503,10
2019-12-27	493,00	960,85	2066,71
2019-12-28	1068,00	1918,85	1449,99
2019-12-29	2665,00	3301,85	1711,59
2019-12-30	1096,00	3725,85	2526,95
2019-12-31	582,00	1241,85	1914,52

## EK-4 Santral\_D üretilen enerji ve tahmin sonuçları (Son 200 saat).

Saatler	Üretilen Enerji (kWh)	SARIMA Predictions	LSTM Predictions
2018-10-15 09:00:00	44,00	436,46	0,00
2018-10-15 10:00:00	327,00	648,29	209,64
2018-10-15 11:00:00	562,00	769,07	599,69
2018-10-15 12:00:00	734,00	849,33	715,11
2018-10-15 13:00:00	818,00	827,50	792,79
2018-10-15 14:00:00	880,00	790,84	827,82
2018-10-15 15:00:00	604,00	692,01	820,48
2018-10-15 16:00:00	651,00	575,80	482,17
2018-10-15 17:00:00	635,00	426,65	436,80
2018-10-15 18:00:00	290,00	299,79	428,42
2018-10-15 19:00:00	85,00	133,22	107,04
2018-10-15 20:00:00	3,00	25,67	0,00
2018-10-15 21:00:00	0,00	0,44	0,00
2018-10-15 22:00:00	0,00	0,00	0,00
2018-10-15 23:00:00	0,00	0,00	0,00
2018-10-16 00:00:00	0,00	0,00	0,00
2018-10-16 01:00:00	0,00	0,00	0,00
2018-10-16 02:00:00	0,00	0,00	0,00
2018-10-16 03:00:00	0,00	0,00	0,00
2018-10-16 04:00:00	0,00	0,00	0,00
2018-10-16 05:00:00	0,00	0,00	0,00
2018-10-16 06:00:00	0,00	1,40	0,00
2018-10-16 07:00:00	0,00	40,93	0,00
2018-10-16 08:00:00	0,00	213,10	0,00
2018-10-16 09:00:00	30,00	436,46	0,00
2018-10-16 10:00:00	249,00	648,29	140,50
2018-10-16 11:00:00	428,00	769,07	514,19
2018-10-16 12:00:00	672,00	849,33	622,81
2018-10-16 13:00:00	645,00	827,50	760,36
2018-10-16 14:00:00	890,00	790,84	671,12
2018-10-16 15:00:00	633,00	692,01	818,44
2018-10-16 16:00:00	670,00	575,80	558,67
2018-10-16 17:00:00	334,00	426,65	474,56
2018-10-16 18:00:00	78,00	299,79	196,40
2018-10-16 19:00:00	21,00	133,22	9,70
2018-10-16 20:00:00	0,00	25,67	0,00
2018-10-16 21:00:00	0,00	0,44	0,00
2018-10-16 22:00:00	0,00	0,00	0,00
2018-10-16 23:00:00	0,00	0,00	0,00
2018-10-17 00:00:00	0,00	0,00	0,00
2018-10-17 01:00:00	0,00	0,00	0,00
2018-10-17 02:00:00	0,00	0,00	0,00
2018-10-17 03:00:00	0,00	0,00	0,00
2018-10-17 04:00:00	0,00	0,00	0,00
2018-10-17 05:00:00	0,00	0,00	0,00
2018-10-17 06:00:00	0,00	1,40	0,00
2018-10-17 07:00:00	0,00	40,93	0,00
2018-10-17 08:00:00	0,00	213,10	0,00
2018-10-17 09:00:00	21,00	436,46	0,00
2018-10-17 10:00:00	170,00	648,29	88,97
2018-10-17 11:00:00	344,00	769,07	389,16
2018-10-17 12:00:00	359,00	849,33	562,36
2018-10-17 13:00:00	565,00	827,50	440,95
2018-10-17 14:00:00	469,00	790,84	638,31
2018-10-17 15:00:00	345,00	692,01	394,49
2018-10-17 16:00:00	159,00	575,80	310,68
2018-10-17 17:00:00	118,00	426,65	36,62

2018-10-17 18:00:00	30,00	299,79	0,00
2018-10-17 19:00:00	17,00	133,22	0,00
2018-10-17 20:00:00	0,00	25,67	0,00
2018-10-17 21:00:00	0,00	0,44	0,00
2018-10-17 22:00:00	0,00	0,00	0,00
2018-10-17 23:00:00	0,00	0,00	0,00
2018-10-18 00:00:00	0,00	0,00	0,00
2018-10-18 01:00:00	0,00	0,00	0,00
2018-10-18 02:00:00	0,00	0,00	0,00
2018-10-18 03:00:00	0,00	0,00	0,00
2018-10-18 04:00:00	0,00	0,00	0,00
2018-10-18 05:00:00	0,00	0,00	0,00
2018-10-18 06:00:00	0,00	1,40	0,00
2018-10-18 07:00:00	0,00	40,93	0,00
2018-10-18 08:00:00	0,00	213,10	0,00
2018-10-18 09:00:00	22,00	436,46	0,00
2018-10-18 10:00:00	170,00	648,29	94,86
2018-10-18 11:00:00	369,00	769,07	388,38
2018-10-18 12:00:00	539,00	849,33	592,09
2018-10-18 13:00:00	628,00	827,50	669,49
2018-10-18 14:00:00	651,00	790,84	674,32
2018-10-18 15:00:00	641,00	692,01	607,23
2018-10-18 16:00:00	592,00	575,80	529,84
2018-10-18 17:00:00	377,00	426,65	433,70
2018-10-18 18:00:00	166,00	299,79	265,04
2018-10-18 19:00:00	22,00	133,22	37,19
2018-10-18 20:00:00	0,00	25,67	0,00
2018-10-18 21:00:00	0,00	0,44	0,00
2018-10-18 22:00:00	0,00	0,00	0,00
2018-10-18 23:00:00	0,00	0,00	0,00
2018-10-19 00:00:00	0,00	0,00	0,00
2018-10-19 01:00:00	0,00	0,00	0,00
2018-10-19 02:00:00	0,00	0,00	0,00
2018-10-19 03:00:00	0,00	0,00	0,00
2018-10-19 04:00:00	0,00	0,00	0,00
2018-10-19 05:00:00	0,00	0,00	0,00
2018-10-19 06:00:00	0,00	1,40	0,00
2018-10-19 07:00:00	0,00	40,93	0,00
2018-10-19 08:00:00	0,00	213,10	0,00
2018-10-19 09:00:00	27,00	436,46	0,00
2018-10-19 10:00:00	200,00	648,29	123,75
2018-10-19 11:00:00	490,00	769,07	436,17
2018-10-19 12:00:00	489,00	849,33	688,90
2018-10-19 13:00:00	886,00	827,50	573,89
2018-10-19 14:00:00	760,00	790,84	879,80
2018-10-19 15:00:00	754,00	692,01	750,26
2018-10-19 16:00:00	237,00	575,80	643,40
2018-10-19 17:00:00	109,00	426,65	83,66
2018-10-19 18:00:00	304,00	299,79	43,55
2018-10-19 19:00:00	35,00	133,22	191,69
2018-10-19 20:00:00	0,00	25,67	0,00
2018-10-19 21:00:00	0,00	0,44	0,00
2018-10-19 22:00:00	0,00	0,00	0,00
2018-10-19 23:00:00	0,00	0,00	0,00
2018-10-20 00:00:00	0,00	0,00	0,00
2018-10-20 01:00:00	0,00	0,00	0,00
2018-10-20 02:00:00	0,00	0,00	0,00
2018-10-20 03:00:00	0,00	0,00	0,00
2018-10-20 04:00:00	0,00	0,00	0,00
2018-10-20 05:00:00	0,00	0,00	0,00

2018-10-20 06:00:00	0,00	1,40	0,00
2018-10-20 07:00:00	0,00	40,93	0,00
2018-10-20 08:00:00	0,00	213,10	0,00
2018-10-20 09:00:00	22,00	436,46	0,00
2018-10-20 10:00:00	136,00	648,29	94,86
2018-10-20 11:00:00	595,00	769,07	339,46
2018-10-20 12:00:00	683,00	849,33	773,47
2018-10-20 13:00:00	786,00	827,50	760,33
2018-10-20 14:00:00	821,00	790,84	808,67
2018-10-20 15:00:00	731,00	692,01	800,36
2018-10-20 16:00:00	580,00	575,80	619,43
2018-10-20 17:00:00	457,00	426,65	405,91
2018-10-20 18:00:00	277,00	299,79	291,92
2018-10-20 19:00:00	83,00	133,22	121,72
2018-10-20 20:00:00	1,00	25,67	0,00
2018-10-20 21:00:00	0,00	0,44	0,00
2018-10-20 22:00:00	0,00	0,00	0,00
2018-10-20 23:00:00	0,00	0,00	0,00
2018-10-21 00:00:00	0,00	0,00	0,00
2018-10-21 01:00:00	0,00	0,00	0,00
2018-10-21 02:00:00	0,00	0,00	0,00
2018-10-21 03:00:00	0,00	0,00	0,00
2018-10-21 04:00:00	0,00	0,00	0,00
2018-10-21 05:00:00	0,00	0,00	0,00
2018-10-21 06:00:00	0,00	1,40	0,00
2018-10-21 07:00:00	0,00	40,93	0,00
2018-10-21 08:00:00	0,00	213,10	0,00
2018-10-21 09:00:00	31,00	436,46	0,00
2018-10-21 10:00:00	306,00	648,29	145,97
2018-10-21 11:00:00	169,00	769,07	583,46
2018-10-21 12:00:00	104,00	849,33	219,72
2018-10-21 13:00:00	77,00	827,50	48,65
2018-10-21 14:00:00	374,00	790,84	0,00
2018-10-21 15:00:00	880,00	692,01	343,08
2018-10-21 16:00:00	521,00	575,80	844,49
2018-10-21 17:00:00	425,00	426,65	438,00
2018-10-21 18:00:00	83,00	299,79	364,21
2018-10-21 19:00:00	53,00	133,22	0,00
2018-10-21 20:00:00	0,00	25,67	5,05
2018-10-21 21:00:00	0,00	0,44	0,00
2018-10-21 22:00:00	0,00	0,00	0,00
2018-10-21 23:00:00	0,00	0,00	0,00
2018-10-22 00:00:00	0,00	0,00	0,00
2018-10-22 01:00:00	0,00	0,00	0,00
2018-10-22 02:00:00	0,00	0,00	0,00
2018-10-22 03:00:00	0,00	0,00	0,00
2018-10-22 04:00:00	0,00	0,00	0,00
2018-10-22 05:00:00	0,00	0,00	0,00
2018-10-22 06:00:00	0,00	1,40	0,00
2018-10-22 07:00:00	0,00	40,93	0,00
2018-10-22 08:00:00	0,00	213,10	0,00
2018-10-22 09:00:00	28,00	436,46	0,00
2018-10-22 10:00:00	151,00	648,29	129,39
2018-10-22 11:00:00	316,00	769,07	355,01
2018-10-22 12:00:00	386,00	849,33	532,43
2018-10-22 13:00:00	646,00	827,50	507,15
2018-10-22 14:00:00	507,00	790,84	708,27
2018-10-22 15:00:00	296,00	692,01	437,59
2018-10-22 16:00:00	561,00	575,80	264,00
2018-10-22 17:00:00	563,00	426,65	405,77

2018-10-22 18:00:00	194,00	299,79	386,10
2018-10-22 19:00:00	74,00	133,22	22,83
2018-10-22 20:00:00	1,00	25,67	0,00
2018-10-22 21:00:00	0,00	0,44	0,00
2018-10-22 22:00:00	0,00	0,00	0,00
2018-10-22 23:00:00	0,00	0,00	0,00
2018-10-23 00:00:00	0,00	0,00	0,00
2018-10-23 01:00:00	0,00	0,00	0,00
2018-10-23 02:00:00	0,00	0,00	0,00
2018-10-23 03:00:00	0,00	0,00	0,00
2018-10-23 04:00:00	0,00	0,00	0,00
2018-10-23 05:00:00	0,00	0,00	0,00
2018-10-23 06:00:00	0,00	1,40	0,00
2018-10-23 07:00:00	0,00	40,93	0,00
2018-10-23 08:00:00	0,00	213,10	0,00
2018-10-23 09:00:00	60,00	436,46	0,00
2018-10-23 10:00:00	289,00	648,29	263,99
2018-10-23 11:00:00	547,00	769,07	551,82
2018-10-23 12:00:00	720,00	849,33	709,25
2018-10-23 13:00:00	788,00	827,50	783,09
2018-10-23 14:00:00	709,00	790,84	795,57
2018-10-23 15:00:00	729,00	692,01	651,48
2018-10-23 16:00:00	620,00	575,80	599,08

**EK-5** Santral verilerinin kullanımını için alınan izin yazısı.

**NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**  
**ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALINA**

**KONYA**

Öğrenciniz Yunus Emre Kıymaz' ın "Güneş Enerji Santrallerinde Derin Öğrenme Kullanılarak Elektrik Üretimi Tahmini Yapılması" isimli yüksek lisans tez çalışması kapsamında şirketimiz bünyesinde işletme faaliyetlerini yürüttüğümüz santrallerin verilerini kullanmak üzere talepte bulunmuştur.

Şirketimizden talep edilen verilerin bilimsel çalışma amacıyla kullanılması uygun görülmüş olup dijital ortamda veriler paylaşılmıştır.

Bilgilerinize sunarız.

**INSOS ENERJİ**  
**YATIRIM DANIŞMANLIĞI SAN. VE TİC. A.Ş.**  
Fevzi Çakmak Mah. 10576. Sk. No:1/201 Karatay / KONYA  
Selçuk V.D.No: 299 5406 - Oda Sicil No: 62551  
Ticaret Sicil No: 49730 Mersis No: 0465043540600014  
www.insos.net - Tel: +90 332 246 00 40 - Fax: +90 332 246 00 50

**Kenan KAHYA**  
**Operasyonel Teknolojiler**  
**Koordinatörü**

Adres : Fevzi Çakmak Mah. 10576. Sk. No:1/201  
Karatay/Konya  
Web : [www.insos.net](http://www.insos.net)  
Tel : 0332 246 00 40  
e-mail : [kenan.kahya@insos.net](mailto:kenan.kahya@insos.net)

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Yunus Emre KIYMAZ  
**Uyruğu** : T.C.  
**Doğum Yeri ve Tarihi** : Ankara 06.06.1989  
**Telefon** : 0 536 484 98 75  
**Faks** :  
**E-mail** : yunus@ae yazilim.com

### EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Selçuklu Cumhuriyet Lisesi, Selçuklu, Konya	2008
Üniversite	: Selçuk Üniversitesi, Selçuklu, Konya	2013
Üniversite	: Selçuk Üniversitesi, Selçuklu, Konya	2018
Yüksek Lisans	: Selçuk Üniversitesi, Selçuklu, Konya	2018
Yüksek Lisans	: N. Erbakan Üniversitesi, Selçuklu, Konya	-

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2011-	AE KOD TEKNOLOJİSİ	Uygulama Geliştirici

### UZMANLIK ALANI

Mobil programlama (iOS, Android), Unity3D (Orta seviye)

### YABANCI DİLLER

İngilizce (Orta)

### YAYINLAR

1. SELEK, M. & KIYMAZ, Y. E., 2020, Implementation of the augmented reality to electronic practice, *Comput Appl Eng Educ*, 28, 420-434. (SCI-E)
2. KIYMAZ Y. E. ve OĞUZ H., 2019, Endüstri 4.0'da Yapay Sinir Ağları Kullanımının İncelenmesi, *VII. Uluslararası Fen, Mühendislik ve Mimarlık Bilimlerinde Akademik Çalışmalar Sempozyumu*, Ankara/TÜRKİYE.
3. SELEK, M. & KIYMAZ, Y. E., 2017, Realization of Augmented Reality Application on Cross-Platforms, *II. International Academic Research Congress*, Alanya/TURKEY, 1039-1046.