

T.C.  
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ  
LİSANSÜSTÜ EĐİTİM ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI

**GÜÇ SİSTEMLERİNİN YÜK TAHMİNİ ANALİZİNDE UZUN KISA  
SÜRELİ BELLEK METODUNUN KULLANILMASI VE UYGULAMASI**

YÜKSEK LİSANS TEZİ

ÜMMÜHAN GÜLSÜM KILIÇ

TEZ DANIŐMANI  
PROF. DR. MEHMET KURBAN

İKİNCİ TEZ DANIŐMANI  
DR. ÖĐR. ÜYESİ EMRAH DOKUR

BİLECİK, 2021

10410758

T.C.  
BİLECİK ŐEHY EDEBALI ÜNİVERSİTESİ  
LİSANSÜSTÜ EĐİTİM ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI

**GÜÇ SİSTEMLERİNİN YÜK TAHMİNİ ANALİZİNDE UZUN KISA  
SÜRELİ BELLEK METODUNUN KULLANILMASI VE UYGULAMASI**

YÜKSEK LİSANS TEZİ

ÜMMÜHAN GÜLSÜM KILIÇ

TEZ DANIŐMANI  
PROF. DR. MEHMET KURBAN

İKİNCİ TEZ DANIŐMANI  
DR. ÖĐR. ÜYESİ EMRAH DOKUR

BİLECİK, 2021

10410758

## BEYAN

“Güç Sistemlerinin Yük Tahmini Analizinde Uzun Kısa Süreli Bellek Metodunun Kullanılması ve Uygulaması” adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir. <input checked="" type="checkbox"/>	
<b>DESTEK ALINMIŞTIR</b>	<b>DESTEK ALINMAMIŞTIR</b>
<b>Destek alındı ise;</b>	
<b>Destekleyen kurum;</b>	
<b>Desteğin Türü</b>	<b>Proje Numarası</b>
<b>1- BAP (Bilimsel Araştırma Projesi)</b>	
<b>2- TÜBİTAK</b>	
<b>Diğer;.....</b> .....	
<b>ETİK KURUL onayı var ise;</b>	
<b>ETİK KURUL karar tarih/sayı:</b>	...../..... .....

Ümmühan Gülsüm KILIÇ

....../....../2021

İmza

## ÖNSÖZ

Tez yazımı süresince ve yüksek lisans öğrenimim boyunca her türlü desteđi ve emeđi veren, minnet borçlu olduđum deđerli hocam Sayın Prof. Dr. Mehmet KURBAN'A en içten dileklerimle teşekkürlerimi sunarım.

Yüksek lisans öğrenimim boyunca her türlü fedakarlığı gösterip bana rehber olan, bilgi ve tecrübesiyle yoluma ışık tutan, danışmanım Sayın Dr. Öğr. Üyesi Emrah DOKUR hocama teşekkür ederim.

Her zaman yanımda olan ve sabırsızlıkla yüksek lisans öğrenimimin bitmesini bekleyen aileme teşekkür ederim.

**Ümmühan Gülsüm KILIÇ**

## ÖZET

### GÜÇ SİSTEMLERİNİN YÜK TAHMİNİ ANALİZİNDE UZUN KISA SÜRELİ BELLEK METODUNUN KULANILMASI VE UYGULAMASI

Yük tahmini, güç sistemlerinin planlanması ve işletilmesinde önemli bir role sahiptir. Enerji piyasalarının özelleştirilmesi, her katılımcının rakipler üzerinde bir tür avantaj elde etmek için daha iyi analiz yapmak ve tahmin modellerini oluşturmak, geliştirmek için çabalamış oldukları rekabetçi pazarların oluşmasına neden olmaktadır. Tahmin, yükü etkileyen faktörlere ve farklı zaman dilimlerine bağlıdır. Bununla birlikte, stokastik ve belirsizlik özellikleri nedeniyle, elektrik hizmetlerinin gelecekteki yük talebini doğru bir şekilde tahmin edilmesi zor bir problem haline gelmiştir. Yük tahmini yaklaşımlarında yapay sinir ağları (YSA) en yaygın kullanılan yöntemlerden biri olmasına rağmen günümüzde hibrit yaklaşımlar ve derin öğrenme teknikleri gibi çeşitli yaklaşımlarda kullanılmaktadır. Uzun-kısa süreli bellek (LSTM), Tekrarlayan Sinir Ağları (RNN) modelleriyle birlikte gelen yok olan gradyan problemini çözdüğü görülmektedir.

Bu tez çalışmasında, kısa ve orta vadeli saatlik yük tahmini için LSTM ve YSA tabanlı iki yöntem kullanılmaktadır. Ayrıca yaygın olarak kullanılan makine öğrenimi yaklaşımları için iki farklı modelin karşılaştırılması yapılmaktadır. Model 1 ve Model 2 olarak adlandırılan iki farklı zaman aralığı için tahmin modelleri oluşturulmuştur. Tahmin modellerinin performansları, ortalama mutlak yüzde hatası (MAPE), ortalama mutlak hata (MAE) ve hata kareler ortalamasının karekökü (RMSE) gibi çeşitli hata performans metrikleri kullanılarak karşılaştırılmıştır. Sonuç olarak, bu tez çalışmasında LSTM ve YSA yöntemleri yardımıyla Türkiye'deki 2017-2019 yılları arasındaki yıllık elektrik enerjisi tüketim verilerinin birden çok zaman diliminde elektrik tüketiminin tahmin edilmesi ve tahmin sonuçlarının performansının belirlenmesi amaçlanmaktadır. Yapılan bu analizler sonucunda normalizeli yük tahmini çalışmasında, en düşük ortalama günlük hata yüzdelerini LSTM yapısının verdiği görülmüştür. Buna ek olarak hata metriklerine göre LSTM ve YSA için önerilen Model 1'in başarımı Model 2'den daha düşük olduğu görülmüştür.

**Anahtar Sözcükler:** YSA, LSTM, Yük Tahmini, MAPE, RMSE

## ABSTRACT

### LOAD FORECASTING ANALYSIS OF POWER SYSTEMS USING LONG SHORT-TERM MEMORY AND APPLICATION

Load forecasting plays an important role in the planning and operation of power systems. The privatization of energy markets results in the creation of competitive markets in which each participant strives to create and develop better analysis and forecasting models in order to gain some kind of advantage over competitors. The forecast is affected by factors affecting the load and actions taken in different time periods. However, due to its stochastic and uncertainty characteristics, it has become a difficult problem for electrical utilities to accurately predict future load demand. Although artificial neural networks (ANN) are used as the most widely used method in load estimation approaches, hybrid approaches and deep learning techniques are among the popular research topics today. Long-short-term memory (LSTM) appears to solve the vanishing gradient problem that comes with RNN models.

In this thesis, two methods based on LSTM and ANN are used for aggregate demand-side load forecasting in short and medium-term monthly horizons. Two different models are compared for widely used machine learning approaches. Forecast models are created for two different time horizons called Model 1 and Model 2. The performances of the prediction models were compared using various error performance metrics such as mean absolute percent error (MAPE), mean absolute error (MAE), and root mean square error (RMSE). With the help of ANN methods, it is aimed to test the success of estimating electricity consumption in more than one time period of consumption amounts in Turkey. In the normalized load estimation study, it was seen that the LSTM structure gave the lowest average daily error percentages. According to the results of all error performance metrics, it was observed that the LSTM model gave better results than the classical ANN model. In addition, according to some error metrics, the performance of Model 1 proposed for LSTM and ANN is lower than Model 2.

**Keywords:** ANN, LSTM, load forecasting, MAPE, RMSE

# İÇİNDEKİLER

	Sayfa No
ÖN SÖZ.....	i
ÖZET .....	ii
ABSTRACT .....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER LİSTESİ.....	v
TABLolar LİSTESİ.....	vi
SİMGELER VE KISALTMALAR.....	vii
1.GİRİŞ.....	1
1.1 Literatür İncelemesi.....	2
1.2. Tezin Amacı ve Yapısı .....	6
2.YÜK TAHMİNİ.....	7
2.1. Yük Tahmini Nedir? .....	7
2.2. Elektrik Enerjisi Endüstrisi ve Elektrik Şebekeleri .....	9
2.3. Günlük Enerji Yük Miktarı .....	10
2.4. Yük Tahmini Gereksinimleri .....	11
2.5. Yük Tahmininin Hedefleri ve Metrikleri.....	12
2.5.1. Gecikme.....	14
2.6.Yük Tahminini Etkileyen Faktörler .....	14
2.6.1. Meteorolojik koşullar.....	15
2.6.2. Zaman faktörü.....	17
2.6.3. Ekonomik ve demografik faktörler .....	17
2.6.4. Rastlantısal faktörler .....	18
2.6.5. Ekonomik faktörler.....	18
3.YÜK TAHMİNİNDE KULLANILAN YÖNTEMLER .....	19

<b>3.1. Analitik Yöntemler.....</b>	<b>20</b>
3.1.1. Benzer gün yaklaşımı.....	21
3.1.2. En küçük kareler yöntemi.....	22
3.1.3. Regresyon analizi .....	21
3.1.4. Dalgacık dönüşümü.....	24
<b>3.2. Yapay Zeka Yöntemleri.....</b>	<b>25</b>
3.2.1. Bulanık mantık.....	26
3.2.2. Destek Vektör Makineleri (SupportVectorMachines – SVM).....	27
<b>3.3. Yük Tahmini Çeşitleri .....</b>	<b>28</b>
3.3.1. Kısa Dönem Yük Tahmini.....	29
3.3.2. Orta Dönem Yük Tahmini .....	30
3.3.3. Uzun Dönem Yük Tahmini .....	31
3.3.4.Çok Kısa Dönem Yük Tahmini.....	32
<b>3.5.Talep Tahmin Tekniklerinin Sınıflandırılması .....</b>	<b>33</b>
3.5.1. Geleneksel tahmin teknikleri .....	34
3.5.2. Değiştirilmiş geleneksel teknikler .....	35
3.5.3 Esnek hesaplama teknikleri .....	36
<b>3.6. Makine Öğrenmesi .....</b>	<b>37</b>
3.6.1. Denetimli öğrenme .....	39
3.6.2. Denetimsiz öğrenme .....	40
3.6.3. Pekiştirmeli öğrenme .....	30
3.6.4. Terminoloji .....	42
3.6.5. Fazla uyum (overfitting) ve yetersiz uyum (underfitting) .....	43
<b>3.7. Yapay Sinir Ağları .....</b>	<b>44</b>
3.7.1. Öğrenme süreci.....	45
3.7.2. Sinir ağlarının geleceği .....	46

<b>3.8.Uzun Kısa Süreli Bellek (LTSM)</b> .....	<b>47</b>
<b>3.8.1 LSTM modeli</b> .....	<b>48</b>
<b>3.8.2. İlgili uygulamalar</b> .....	<b>49</b>
<b>3.8.3. Zaman serisi tahmini</b> .....	<b>50</b>
<b>3.8.4. Doğal dil işleme</b> .....	<b>51</b>
<b>3.8.5. Bilgisayarlı görme</b> .....	<b>52</b>
<b>3.9. Matlab Çerçevesi</b> .....	<b>53</b>
<b>4.UYGULAMA</b> .....	<b>54</b>
<b>4.1. Günlük Yük Tüketimi Verileri</b> .....	<b>55</b>
<b>4.2. Veri Ön işleme</b> .....	<b>56</b>
<b>4.3. Yük Tahmininde YSA Modeli</b> .....	<b>57</b>
<b>4.4. Yük Tahmininde LSTM Modeli</b> .....	<b>58</b>
<b>4.4.1 Bulgular</b> .....	<b>59</b>
<b>5.SONUÇLAR</b> .....	<b>60</b>
<b>KAYNAKLAR</b> .....	<b>61</b>

## ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 2.1. Normalize edilen elektrik yükü ile günlük ortalama sıcaklığı arasındaki ilişki .....	17
Şekil 3.1. Elektrik şebekesi ve paydaşları.....	19
Şekil 3.2. Talep Tahmin Yöntemleri.....	20
Şekil 3.3. Denetimli öğrenme. ....	28
Şekil 3.4. Denetimsiz öğrenme .....	29
Şekil 3.5. Pekiştirmeli öğrenme .....	31
Şekil 3.6. Fazla uyumun, optimal noktanın ve yetersiz uyumun görselleştirilmesi.....	34
Şekil 3.7. Biyolojik bir nöronun çalışması.....	36
Şekil 3.8. Yapay sinir ağı yapısı .....	37
Şekil 3.9. Sinir ağı öğrenme süreci .....	38
Şekil 3.10. Basit LSTM ağ mimarisi.....	42
Şekil 3.11. Regresyon için basit bir LSTM ağının mimarisi .....	42
Şekil 3.12. t zaman adımındaki veri akışı .....	44
Şekil 4.1. Tahminde kullanılan tüm eğitim verisi .....	48
Şekil 4.2. Kayan pencere yaklaşımının Model 1 için gösterimi .....	49
Şekil 4.3 Kayan pencere yaklaşımının Model 2 için gösterimi .....	49
Şekil 4.4 YSA yapısı blok diyagramı.....	50
Şekil 4.5. Tansig ve purelin aktivasyon fonksiyonları.....	51
Şekil 4.6. Veri eğitiminin ve öğrenmesinin görseli .....	52
Şekil 4.7. YSA ve LSTM için saatlik normalize edilmiş gerçek ve tahmin eğrileri.....	53
Şekil 4.8. YSA ve LSTM için saatlik normalize edilmiş gerçek ve tahmin eğrileri.....	54

## TABLULAR LİSTESİ

	<b>Sayfa No</b>
<b>Tablo 2.1.</b> Tahmin Doğruluğu Ölçütleri .....	<b>12</b>
<b>Tablo 3.1.</b> Katman bileşenleri.....	<b>43</b>
<b>Tablo 4.1.</b> Modeller için kayan pencere tanımları.....	<b>50</b>
<b>Tablo 4.2.</b> Hata değerlerinin YSA ve LSTM için karşılaştırması. ....	<b>55</b>

## SİMGELER VE KISALTMALAR

**KWh:** Kilowatt saat

**₺:** Türk Lirası

**EMK:** Elektro Motor Kuvveti

**I:** Akım (Amper)

**W:** Watt

**V:** Gerilim

**mV:** Milivolt

**YSA:** Yapay Sinir Ağları

**MAPE:** Ortalama Mutlak Yüzde Hatası

**ANFIS:** Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi

**LSTM:** Uzun Kısa Süreli Bellek

**MAE:** Ortalama Mutlak Hata

**RMSE:** Kök Ortalama Kare Hata

## 1.GİRİŞ

Elektrik enerjisi, diğler ihtiyaç ürünleri gibi gereksinimlere cevap vermek ve kullanılmak üzere satılmaktadır. Fakat diğler satışı olan ürünlerden farklı olarak büyük çaplı depolanamaması sebebiyle talep edilen ile arz edilen arasındaki fark ciddi kayıplara sebep olmaktadır. Bu özelliğı sebebiyle tüketileceğı kadar üretilmesi gerekmektedir. Tüketilecek kadar üretiminin gerçekleştirilmesi için de tüketim miktarının önceden tahmin edilmesi gerekmektedir.

Elektrik yükünün tahmin yöntemleri elektrik üreticisi olan kurumlar için büyük avantaj sağlamaktadır. Tahminin sağladığı avantajlar şunlardır: Arz ve talep arasındaki dengeyi sağlamak, üretim maliyetini düşürmek ve kapasite planlamasını yönetmek.

Elektrik enerjisi tüketimi, ekonomik büyüme, endüstriyel emek, günün saatleri, haftanın günleri, hafta sonları, ay, mevsim, tatiller ve hava koşulları gibi birçok faktöre bağlıdır. Enerji piyasalarının özelleştirilmesi, her katılımcının rakipler üzerinde bir tür avantaj elde etmek için daha iyi analiz yapmak ve tahmin modellerini oluşturmak, geliştirmek için çabalamış oldukları rekabetçi pazarların oluşmasına neden olmaktadır. (Alam, 2018:12).

Hedeflenen tahminler için iki zorluk bulunmaktadır. Kısa vadeli durumda, elektrik gücü dağıtımının optimum günlük operasyonel verimliliğı için doğruluk çok önemlidir ve orta vadeli durumda, tüketim kaynaklarının hassas programlanması ve zamanında bakım işlemleri için tahmin kararlılığı gereklidir. Tahmin istikrarı amacıyla, orta vadeli aralık için düşük bir tahmin hatası korunmalıdır. Bu nedenle, tahmin modelinin doğru performans göstermeye devam etmesi veya en azından orta vadeli çerçeve içinde geçen zamana aşırı duyarlı olmaması gerekir (Alfares ve Mohammad, 2002).

Geleneksel istatistiksel teknikler, zaman serisi analizi ve yeni makine öğrenimi kullanan birkaç elektrik yükü tahmin yaklaşımı önerilmiş olsa da, daha doğru ve kararlı yük tahmin modellerine olan ihtiyaç hala çok önemlidir. Son zamanlarda, derin öğrenmeye dayalı yaklaşımlara özel bir önem verilmektedir (Bouktif vd., 2018:5).

Tahminler , derin mimarilere sahip yapay sinir ağlarına (YSA) dayanmaktadır, karmaşık doğrusal olmayan kalıpları ve büyük miktarda veriyi dikkate alırken veri davranışını yakalama yetenekleri nedeniyle birçok araştırma topluluğunun dikkatini çekmiştir. Sığ öğrenmenin aksine, derin öğrenme genellikle daha fazla sayıda gizli katmana sahip olmayı ifade eder. Derin ağdaki bu gizli katmanlar, modelin karmaşık girdi-çıkı ilişkilerini doğru bir şekilde

öğrenmesini sağlar (Lasfer, 2013).

Uzun kısa süreli bellek (LSTM), derin Yapay Sinir Ağlarının (YSA) bir varyasyonu, ilk olarak Hochreiter ve Schmidhuber (1997:1745), katmanlar arasında ileri ve geri yayılan ağırlıkların korunmasına izin vermek için geliştirmiştir. LSTM tabanlı YSA'lar, geçmiş girdilerden gelen bağlamsal bilgileri birleştirdikleri için zaman serileri gibi sıralı verileri modellemek için çekici bir seçimdir. Özellikle, zaman serisi tahmini için LSTM tekniği, uçtan uca modelleme, karmaşık doğrusal olmayan kalıpları öğrenme ve otomatik özellik çıkarma yetenekleri nedeniyle popülerlik kazanmıştır.

### **1.1 Literatür İncelemesi**

Yük tahmini için farklı modeller, genel olarak mühendislik yöntemleri ve veriye dayalı yöntemler olarak sınıflandırılabilir. Fizik tabanlı modeller olarak da bilinen mühendislik yöntemleri; enerji tüketimini tahmin etmek ve analiz etmek için termodinamik kuralları kullanmaktadır. Genel olarak, bu modeller enerji tüketimini hesaplamak için bina yapısı, hava durumu bilgileri, ısıtma, havalandırma ve klima (HVAC) sistemi bilgileri gibi bağlam özelliklerine dayanmaktadır. EnergyPlus ve eQuest gibi binalar için enerji simülatörü yazılımında fizik tabanlı modeller kullanılmaktadır. Bu modellerin sınırlaması, girdi bilgilerinin mevcudiyetine ve doğruluğuna bağlı olmalarından kaynaklanmaktadır (Wang, vd. 2017:797).

(Dong vd. 2020:5), belirsizliği yakalamak ve elektriksel yük dalgalanması aralığını yansıtmak için K-en yakın komşularına dayalı bir derin öğrenme yaklaşımı önererek iki problemi çözmeyi amaçlamaktadır. İlk olarak, K-en yakın komşular algoritması, eğitim ve test veri kümeleri arasındaki mesafeyi hesaplayarak gelecekteki değerlere benzer tarihsel elektrik yük süresi serilerinin özelliklerini aramak için kullanılmıştır. Daha sonra, K-en yakın komşuların en yüksek tahmin doğruluğunu bulmak için çok amaçlı optimizasyon adına sıralama genetik algoritması kullanılmıştır. Önerilen modelin etkililiğini ölçmek için Avustralya'dan toplanan beş veri seti kullanılmıştır. Diğer modellerle bir dizi karşılaştırma yapılmıştır. Deneysel sonuçlar önerilen aralık tahmin modelinin yalnızca tahmin verimliliğini ve doğruluğunu iyileştirmediğini, aynı zamanda derin öğrenme yaklaşımlarının tahmin sürecini basitleştirdiğini doğrulamaktadır.

(Nobari 2020:5) çalışmasının esas amacı kısa vadede yük tahmininin yapılmasıdır. Geliştirilen modelin eğitilmesi için Gebze'ye ait beş yıldan fazla veriden faydalanılmıştır. Hava durumu ile ilgili kullanılan veriler iki farklı meteoroloji istasyondan elde edilmiştir. Yük tahmini için geliştirilen modelin dört adımı bulunmaktadır. Bu çalışmada üç farklı doğrulama

fonksiyonu kullanılmıştır. Bunlar; RSQ(R-kare), Ortalama mutlak hata (MAE) ve Ortalama kare hatası (RMSE) olacak şekilde sıralanmıştır. Bu çalışmada, sonuçları karşılaştırmak ve en iyi algoritmayı bulmak için diğer üç algoritma kullanılmıştır. Bu algoritmalar K Yakın Komşular, Doğrusal Kayıt ve Karar Ağacıdır. Sinir ağları yönteminin en iyi sonuçları verdiği görülmüştür.

(Taik ve Cherkaoui 2020:3), derin öğrenme modellerini eğitmek için kullanılan verilerin hacmini ve çeşitliliğini artırmaya izin veren merkezi olmayan bir makine öğrenimi şeması olan Edge bilişim ve federe öğrenmenin kullanımını değerlendirmektedir. Federe öğrenme, birden fazla birbirinden bağımsız cihazdan gelen verilerin anonimleştirilmiş bir şekilde tutulduğu sunucu ya da sunucular üzerinde algoritma eğiten bir makine öğrenmesi tekniğidir. Bu makalede, konut tipi elektrik yükü tahmini için federe öğrenme ilk defa kullanılmakta ve umut verici sonuçlar elde etmektedir. Simülasyonlar, Teksas, ABD'den 200 evden alınan veriler üzerinde Tensorflow Federated kullanılarak yapılmıştır.

(Butekin 2019:5), Kısa Dönem Yük Tahmini (KDYT) için Yapay Sinir Ağları (YSA) yöntemi kullanılmıştır. Yaşar Üniversitesi içerisinde bulunan Y-blok binasının elektrik tüketimi tahmini yapılmıştır. Binanın elektrik tüketiminin doğrusal modelde olmaması binada gerçekleştirilen faaliyetlerden dolayıdır. Bu problem gün tipi ayırımı ve günlük çalışma programları sayesinde çözülebilir hale gelmektedir.

(Fernandes vd. 2019:1275), geçmiş yük eğilimlerini ve ortam sıcaklığının yük üzerindeki etkilerini analiz etmiştir. Yerel sıcaklık bilgisi ile birleştirilen bu geçmiş dönem verileri, sinir ağlarını kullanarak kısa dönem ve orta dönem yük tahmini yapmak adına bir tahmin modeli oluşturmak için kullanılmıştır. Tahmin modeli, 1'den küçük bir ortalama kare hatasıyla iyi performans göstermiştir.

(Liu vd. 2019:1520), üç modülden oluşan kısa dönem bir karma tahmin yaklaşımı önermektedir. Üç modül; veri ön işleme, parametre optimizasyon algoritması ve tahmin algoritması olarak gösterilmiştir. Bu hibrit model, geleneksel modelin dezavantajlarının üstesinden gelmiş ve yüksek tahmin performansı elde etmiştir. Hibrit yöntemin tahmin etkinliğini doğrulamak için, New South Wales ve Queensland'daki güç istasyonlarından alınan 30 dakikalık elektrik yükü verileri tahmin yapmak için kullanılmıştır. Hibrit yaklaşımın yeteneğini doğrulamak için Diebold-Mariano testi ve tahmin etkinliğini içeren kapsamlı bir değerlendirme uygulanmıştır. Deneysel sonuçlar, yeni hibrit yöntemin, akıllı şebekeleri yönetmede güçlü bir yardımcı olarak doğru elektrik yükü tahmini yapabileceğini göstermiştir.

(Özger vd. 2019:110) çalışmasında, Holt-Winters Üstel Düzeltme yöntemi yardımıyla elektrik yük tahmini yapmıştır. Winters yönteminin doğru tahmininin gerçekleştirilmesi için yardım alınan katsayılar Genetik Algoritma kullanılarak belirlenmiştir. Bu çalışmada Holt-Winters Üstel Düzeltme yöntemi ve Genetik Algoritma Matlab programları kullanılarak yapılmış ve entegrasyonu sağlanmıştır. Entegre sistem sayesinde elektrik yük tahmini gerçekleştirilmiş ve elektrik yük tahmini için uygun bir yöntem olduğu görülmüştür.

(Sobhani vd. 2019:1510), 2012 Küresel Enerji Tahmin Yarışması verilerini kullanarak yedi alternatif yöntemin performansını basit ortalama yöntemini kullanarak karşılaştırmıştır. Meteoroloji istasyonlarının birleştirilmesiyle elde edilen sonuçlar bazı yöntemlerden daha iyi performans elde edilmesini sağlamıştır. Diğer bir ifadeyle tekniğin performansından ziyade istasyon verilerinin birleştirilmesiyle daha tahmin gücü yüksek veriler elde edilmektedir. Buna ek olarak, bu yöntemlerden gelen tahminlerin ortalamasını almak, çoğu tek başına kullanılan yöntemin performansını geride bırakmıştır.

(Khan 2018:12), geçmiş elektriksel yük ve hava sıcaklığı ile ilgili verilerin kullanılmasıyla çok sayıda öznelikten diğerlerine göre daha etkin olan öznelikler tespit edilmiş ve farklı öznelik seçim tekniklerinin YSA'ların performansına etkileri incelenmiştir. Sonuç olarak, korelasyon analizi sayesinde tespit edilen değişkenlerin yardımıyla kullanılan sinir ağlarının performansı daha yüksek olacak şekilde tespit edilmiştir.

(Kim vd. 2018:136), kısa dönemli bir elektrik tüketimi tahmin yöntemi önermiştir. Önerilen yöntem, bir ay önceki elektrik tüketimi tahminini gerçekleştirmek için geçmiş tüketim profillerinin bir sırasını alan LongShort-Term-Memory (LSTM) ağını kullanmıştır. Performans analizi için, gerçek bir veri setiyle bir deney yapılır ve deneysel sonuç, önerilen yöntemin yaklaşık % 82,5'lik tahmin doğruluğu ile iyi performans gösterdiğini doğrulamıştır. Test doğruluğu, daha uzun bir eğitim süresi ve bilinçli hiperparametre ayarı ile iyileştirilebilir.

(Mutsena 2018:5), bulanık mantığa temelli KDYT tekniği geliştirilmiş ve tekniğin kullanımıyla analiz yapmıştır. Geliştirilen KDYT tekniği, Rhode Island'daki Providence şehrindeki gerçek bir sistemde hayata geçirilmiştir. Providence'deki dört mevsimin her biri için bir tane olan dört bulanık çıkarım sistemi, Bulanık Mantık Araç Kutusu kullanılarak Matlab'da modellenmiştir. Sonrasında Simulink Editör yazılımı yardımıyla dört tane Simulink modeli geliştirilmiştir. Dört modelin her birinin performansı değerlemesini gerçekleştirmek adına ortalama mutlak yüzdesi hatası (MAPE) kullanılmıştır.

(Matthew ve Satyanarayana 2016:296), geleneksel olmayan bir yöntem olan bulanık mantık yaklaşımı kullanılarak kısa dönemli yük tahmini yapılmıştır. Bu makale, önerilen çalışmanın doğruluğunu kontrol etmek için sonuçların yanı sıra bulanık mantık kullanarak yük tahmini alanında önceki çalışmalar hakkında kısa bir giriş oluşturmuştur.

(Khuntia vd. 2016:1375), elektrik güç sistemlerinin orta ve uzun dönemleri için geliştirilen farklı yük tahmin tekniklerini gözden geçirmeyi amaçlamaktadır.

(Ozoh vd. 2015:5), Malezya'daki yerel bir üniversitenin günlük elektrik tüketimini tahmin tahminleri, regresyon modeli, yapay sinir ağı (YSA) ve kalman filtre uyarılama algoritması kullanarak hesaplanmıştır. Yöntemlerin performansı, gerçek ve tahmin edilen değerler arasındaki farkın belirlenmesinden elde edilen istatistiksel parametrelere dayalı performans ölçümleri kullanılarak değerlendirilmiştir. Sonuç olarak, kalman filtre adaptasyon algoritmasını gelecekteki elektrik tüketimi için tahminlerde bulunmada en iyi performans gösteren yöntem olarak tanımlamıştır.

(Kaplan 2014:7) çalışmasında, YSA kullanılarak Antalya iline ait elektrik yük tahmini baz alınıp algoritmaların performansları karşılaştırılmıştır. Çalışmada geliştirilen elektrik yük modeli MATLAB programı YSA araç kutusu ile geri beslemeli 3 katmanlı bir ağ olarak tasarlanmış ve uygulanmıştır. Modelde giriş verisi olarak 2001-2011 yılları arasındaki aylık ortalama elektrik, nem, sıcaklık, nüfus ve basınç değerleri kullanılmıştır. Çalışmanın orijinalitesi, YSA modeli üç veya dört girişli olarak çalıştırılmış ve sıklıkla kullanılan YSA algoritmaları Antalya ili verileri kullanılarak birçok-kriterli karar verme aracı olan AHS tekniği yardımıyla değerlendirmeye tabi tutulmuştur.

(Çevik 2013:5) çalışmasında Türkiye'nin 24 saatlik elektrik yükü bir gün öncesinden tahmin edilmiştir. Türkiye'nin 2009-2011 yılları arası yük ve sıcaklık verileri kullanılarak 2012 yılı için tahmin yapılmıştır. 2012 yılının tüm günleri için MAPE değeri bulanık mantık ve uyarılmalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) yöntemlerinden 2.1 ve 1.85 değerleri bulunmuştur.

(Oğurlu 2011:6) çalışmasında, elektrik yük tahmini için gerçekleştirilecek uygulama teknikleri detaylı şekilde ele alınmış ve 2010-2025 yılları arasındaki yıllık tüketilen toplam enerji miktarları ve puant günde tüketilen enerji miktarları tahmin edilmiştir. Bu çalışmada geçmiş yıllara ait, enerji tüketimi hakkında olan verilerin kullanılmasıyla mümkün matematiksel modeller geliştirilmiş ve gelecek yıllara ait tahminler rapor edilmiştir.

(Özkara 2009:4) çalışmasında kullanılan veriler 2004-2007 yılları için Ankara merkez metropol alanı aylık puant elektrik yük değerleridir. Puant yük değerleri zaman serisi olarak ele alınmış, bu yüklerin mevsimsel dalgalanmaya sahip olduğu belirlenmiş ve mevsimsel ayrıştırma yöntemi tercih edilmiş, bu yöntemin içerdiği toplamsal ayrıştırma ve çarpımsal ayrıştırma yaklaşımları ayrı ayrı uygulanarak doğrusal regresyon ve gri tahmin yöntemi ile mevsimsellikten arındırılan trend serisinin tahmini yapılmıştır.

## **1.2. Tezin Amacı ve Yapısı**

Bu tez çalışmasında, kısa ve orta vadeli saatlik yük tahmini için LSTM ve YSA tabanlı iki yöntem kullanılmaktadır. Ayrıca yaygın olarak kullanılan makine öğrenimi yaklaşımları için iki farklı modelin karşılaştırılması yapılmaktadır. İki farklı model kayan pencere temellidir. 120 saatlik verilerle sonraki 24 saat tahmin edilmektedir. 144 saatlik verilerle sonraki 24 saat tahmin edilmektedir. Bu yaklaşımlar tez çalışmasında Model 1 ve Model 2 olarak ifade edilmektedir. Tahmin tekniklerinin performansları, ortalama mutlak yüzde hatası (MAPE), ortalama mutlak hata (MAE) ve kök ortalama kare hatası (RMSE) gibi çeşitli değerlendirme ölçütleri kullanılarak Model 1 ve Model 2'nin performansı incelenmiştir. Bu tez çalışmasında LSTM ve YSA yöntemleri yardımıyla Türkiye'deki 2017-2019 yılları arasındaki yıllık elektrik enerjisi tüketim verilerinin birden çok zaman diliminde elektrik tüketiminin tahmin edilmesi ve tahmin sonuçlarının performansının belirlenmesi amaçlanmaktadır. Girdi parametrelerine göre LSTM ve YSA yöntemleri ile elde edilen sonuçlar gerçek verilerle karşılaştırılmakta ve hata performans metriklerine göre yöntemlerin performansı gözlenmektedir. LSTM'nin başarısının diğer bir önemli faktörünün ağ topolojisi ve her katmandaki LSTM hücrelerinin sayısı olduğuna inanılmaktadır. Bu tez çalışması aynı zamanda farklı ağ topolojilerini göz önünde bulunduran YSA ve LSTM arasında karşılaştırmalı bir analiz yapmayı da amaçlamaktadır. Bu tez çalışmasında kullanılan Türkiye'deki elektrik enerjisi tüketim verileri 1 Ocak 2017 ile 31 Aralık 2019 tarihleri aralığını kapsamaktadır.

Bu tez çalışması, giriş ve sonuç bölümü hariç toplamda üç bölümden oluşmaktadır. İkinci bölümde, Yük Tahmini konusu ele alınmıştır. Burada, elektrik endüstrisi, enerji piyasası, yük tahmininden bahsedilmiştir. Üçüncü bölümde Yük Tahmininde Kullanılan Yöntemler anlatılmaktadır. Birçok yük tahmini yöntemi ele alınmıştır. Dördüncü bölüm ise tez çalışmasının esası olan uygulamayı tüm yönleriyle ele almaktadır. Bunun yanında uygulamadan elde edilen veriler şekiller ve tablolarla gösterilmektedir.

## 2.YÜK TAHMİNİ

Bu bölümde, elektrik enerjisinin üretim ve tüketiminde enerji kalitesinin arttırılmasına yönelik olarak; yük tahmini tanımı, elektrik enerjisi endüstrisi ve elektrik şebekeleri, günlük enerji yükü miktarı, yük tahminleri için önemli faktörler, yük tahmini gereksinimleri ve yük tahmininin hedefleri ve metrikleri konuları detaylı şekilde anlatılmaktadır.

### 2.1. Yük Tahmini Nedir?

Güç sistemi planlamasındaki ilk adım, geçmişteki kullanım istatistiklerinden de yararlanarak gelecekteki yük talebini tahmin etmektir. Yük tahmini, geçmiş ve şimdiki koşulları gözlemleyerek ve değişen özelliklerini çıkararak gelecekteki koşullar hakkında varsayımlara dayanır. Etkili ve verimli bir sistem tasarımı için maksimum güç yükü ve enerji talebi tahmin edilmelidir. Bir üretim sistemi tasarımı oluşturmak açısından gerekli olan enerjinin tahmin edilmesi çok önemlidir. Pik güç göz önüne alındığında, gelecekte belirlenen enerji talebini karşılamak için santrallerin ve yeni santrallerin yapımına eklenmesi gerektiği belirlenmiştir. Yük tahmininin çıktısına göre yatırım maliyetinin oluşumu, iletim ve dağıtım sistemindeki ve elektrik üretim kapasitesindeki artışın belirlediği artışa bağlıdır. (Yoldaş, 2006: 10).

Tahmin işlemi, bir çok matematiksel işlemin değeri hakkında bilgi içeren veya bir bilgisayar programına girilerek; bir alanın tahmini değerini, geçmiş ve şimdiki değeri, her saat, ay veya her yıl oluşabilecek yük talebini hesaplama yöntemidir. Güç sisteminin normal bir şekilde kurulması, tüketicilere daha kaliteli ve daha ucuz enerji sağlanması ve enerji kaynaklarının kaybının önlenmesi için güç yükü tahmini büyük önem taşımaktadır (Som, 2010: 9).

Elektrik enerjisi piyasasının planlanması ve elektrik üretiminden kullanıcılara en güvenilir şekilde ulaştırılması gerekmektedir. Planlamada en önemli durum, gelecekte ihtiyaç duyulan güç yükünün yüksek doğrulukla tahmin edilmesidir. Tahmin süresinin uzatılması, doğruluk oranını düşürecek ve belirsizliğe neden olacaktır. Bu nedenle kısa vadeli tahminler, orta vadeli tahminler ve uzun vadeli tahminler olarak üçe ayrılmaktadır (Evren, 2021: 18).

Nüfusun artması, kentleşme, sanayileşme, teknolojinin yaygınlaşması ve refahın artmasıyla birlikte enerji tüketimi de artmaktadır (Akar, 2005: 58). Bu sebeple, yük tahmini mümkün olduğunca gerçek duruma çok yakın olacak şekilde hesaplanmalıdır. Çok düşük yük tahminleriyle planlama, tüketicilerin kullanabileceği enerjiyi sınırlayabileceği gibi, aşırı yüksek değerlerde hesaplanan yük tahminlerini kullanarak planlama, işletmesi tam yükün çok altında olan, ekonomik olmayan bir işletmeye sahip olunmasına neden olabilir.

Düşük yük tahminlerine dayalı planlama, düşük sistem güvenilirliği, tüketici için sınırlı enerji arzı ve düşük enerji kalitesi ile sonuçlanacaktır. Öte yandan aşırı yük tahminine dayalı planlama, tam yükte çalışmama, düşük kapasitede çalışma ve dolayısıyla ekonomik olmayan çalışma koşulları ile sonuçlanacaktır. Bu durumda sisteme yapılacak büyük ölçekli yatırımlar, enerji kurumu içinde ciddi mali sorunlara yol açacaktır (Yoldaş, 2006: 11).

Yük tahmini, geçmiş ve şimdiki koşulları inceleyerek ve değişimlerin özelliklerini çıkararak, gelecekte ne olacağının varsayımına dayanır. Tahminin yapıldığı zaman dilimine göre farklı faydalar sağlar. Gelecekteki talebi karşılamak için; elektrik üretim, iletim ve dağıtım sistemlerinin kapasite artışlarının belirlenmesi gerekmektedir. Planlama araştırmasının daha doğru yapılabilmesi için kullanılacak tahmin verileri, tahmin için mümkün olduğunca gerçeğe yakın olmalıdır. Etkin bir sistem planlaması için gerekli enerji talebinin ve pik yükün doğru tahmin edilmesi esastır (Çilliyüz, 2006: 10-11).

Üretim sistemi planlaması için gerekli olan enerjinin tahmini çok önemlidir. Beklenen enerji talebini karşılamak için santralleri artırma veya yeni santraller inşa etme ihtiyacı duyulmaktadır. Bu tesislere uygun tesis türleri ve üretim olanakları araştırılarak, yük tahmini sonuçlarına göre üretim sisteminin kapasitesi arttıkça iletim ve dağıtım sisteminde ihtiyaç duyulan kapasite artışı ve bu artışlara bağlı yatırım maliyetleri belirlenir (Aksel, 2000). Ayrıca mevcut üretim tesislerinin bakım ve onarım süresi, üretim tesislerinin iş planı, ekonomik ömrünü tamamlaması beklenen santral bilgileri, birincil enerji tedarik imkanı, güç yüküne göre ithalat ve ihracattır. (Keleş, 2005: 2- 3)

Yüksek rekabet ortamında, güç tedarikçileri için doğru yük tahmini çok önemlidir. Enerji şirketlerinin sorumluluğu, tüketicilere yüksek kaliteli elektrik enerjisini güvenli ve ekonomik bir şekilde sağlamaktır. Enerji şirketleri, gücün işletilmesi, planlanması ve kontrolünde birçok ekonomik ve teknik sorunla karşı karşıya kalmaktadır. Yük tahmini, güç tedarikçilerinin güç üretimi, güç tedariki, yük değiştirme ve altyapı geliştirme gibi önemli konularda karar vermelerine yardımcı olur (Shu, 2009: 1-2).

Ayrıca, güç tüketiminin tahmini akıllı şebeke teknolojisinde ilk adımdır. Tanım olarak, akıllı şebeke, şebekeye bağlı tüm üreticilerin ve tüketicilerin maliyetleri en aza indirecek şekilde hareket etmelerini sağlayan teknolojik araçlar tarafından yönlendirilen bir şebekedir. TEİAŞ (Türkiye Elektrik Anonim Şirketi), Türkiye'nin artan enerji talebini çeşitli senaryolara göre tahmin etmekte ve bu tahminler PMUM (Piyasa Mali Uzlaştırma Merkezi) aracılığıyla yayınlanmaktadır.

Türkiye için genel tahmin bölgesel planlama için yetersizdir. Dağıtım şirketi ayrıca kendi bölgesindeki elektrik tüketimi talebine göre çeşitli senaryolara dayalı olarak yıllık ve günlük tahminler yaparak şebekesini planlamaktadır (Toker ve Korkmaz, 2011: 32-35).

Türk enerji sistemi işletmecisi, TEİAŞ'a bağlı Milli Yük Tevziye Merkezi'dir (MYTM). Elektrik piyasası işletmecisi, yine TEİAŞ'ın bir parçası olan PMUM'dur. PMUM, gün öncesi planlama, gün öncesi piyasası operasyonu, takas yönetimi ve veri yayını gerçekleştirilen birimdir. PMUM'un temel amacı, Türkiye'de elektrik arz ve talep dengesini korumaktır (EPDK, 2009: 78).

Gün öncesi planı, PMUM koordinasyonunda yürütülen bir faaliyettir. Amaç, bir gün önce öngörülen saatlik talebin gün öncesi piyasasının aktif hale gelmesine kadar dengelenmesidir. Operasyonel güvenlik ve sistem bütünlüğünü sağlamak, tedarik güvenilirliği ve tedarik kalitesi standartlarını karşılamak ve denge maliyetini en aza indirmek için bir sonraki günün saatlik talebinin dengelenmesi esasına göre gün öncesi planı yapılır. Günün her saati dahil olmak üzere her gün ve her saat 00:00'da başlayıp ertesi gün 00:00'da sona erer. Tüm piyasa katılımcıları gün öncesi planına katılmalıdır. Önümüzdeki planın bir sonucu olarak önceki gün için ulusal ölçekte bir üretim/tüketim planı oluşturulmuştur (EPDK, 2009). Gün Öncesi Planlama sistemine talep tarafının verdiği tahmin değerine göre tüm sistemi bir gün önceden dengeler. Bir tahmin hatası nedeniyle sistem dengesizliğe düşer. Sistem dengesizliği nedeniyle oluşan maliyetler, dengesiz tarafça karşılanır. Sistem dengesizliğinden kaynaklanan maliyeti en aza indirmek için saatlik talep tahminindeki hata payı çok düşük olmalıdır. Talebi düşük hata oranı ile tahmin etmek ve gerçek zamanlı olarak dengesizliğe düşmemek, diğer perakende şirketleri ile rekabet avantajı sağlayacaktır (Çevik, 2013: 9).

## **2.2. Elektrik Enerjisi Endüstrisi ve Elektrik Şebekeleri**

Elektrik bir enerji birimi ve kaynağıdır. Elektrik üretimi ihtiyaçları karşılamak için yapılmaktadır. Bunun için birincil enerji benzer bir kaynak yakıt veya bir birincil enerji akışı kullanılmaktadır. Bu yakıtlar ve akışlar genellikle elektrik gücünü şebekeye ileten elektrik akımına dönüştürülmektedir (Yıldız vd., 2017:1105).

Elektrik, elektronların konfigürasyonu veya hareketinden elde edilen enerjidir. Elektrik kullanırken, cihazın elektronları "kullanmadığına" dikkat etmek önemlidir. Bunun yerine, elektronlar tarafından geçici olarak "tutulan" enerjiyi kullanmaktadır. Elektrik, enerjiyi bir elektrik santralinden (birincil enerji) bir eve aktarmaktadır, bu aktarımla son kullanım enerjisi rotasına ulaşmaktadır (Eljazzar ve Hemayed, 2017:829).

Elektrik santralleri, birincil enerjiden elektrik üretmek için en yaygın olarak kullanılan enerji dönüştürme teknolojisidir. Dünyada yaygın olarak bulunan elektrik santrali türleri arasında kömür, nükleer ve hidro santralleri yer almaktadır.

Elektrik enerjisi üretimi farklı şekillerde yapılmaktadır. Bu üretim şekillerinin tümü ya bir yakıtta ya da birincil enerji akışına ihtiyaç duymaktadır. Üretim için birincil yakıtlar arasında kömür, doğal gaz ve uranyum bulunmaktadır. Elektrik üretimi için yararlanılan birincil akışlar gelgitler, rüzgar ve güneş enerjileri bulunmaktadır (Özkara, 2009:16).

Elektrik enerjisi için kullanılan santraller çoğunlukla şehirlerin dışına kurulurken bazı durumlarda şehrin içerisinde yer almaktadır. Bunun çeşitli sebepleri vardır. Bazen o bölgeye santral kurulduktan sonra yakın alanlara yerleşim yerlerinin kurulması gibi sebepler de söz konusu olabilmektedir. Ayrıca bir bölgeye santral kurulma durumu söz konusu olduğu zamanlarda çoğunlukla bölge halkı bu girişime karşı gelmektedir. Köylerinin veya buldukları bölgenin santral yüzünden olumsuz etkileneceği hayvancılığın ve tarımın yapılamayacağı şeklinde oluşmuş olan düşünceler sebebiyle çoğunlukla yaşam alanlarından uzak yerlere santraller kurulmaktadır (Matthew ve Satyanarayana, 2016:298).

### **2.3. Günlük Enerji Yük Miktarı**

Elektrik sistemlerinde gün öncesi planlama yapımı konusu halen verimsizliğini devam ettirmektedir. Kesin planlama yöntemine bakılmaksızın, geçerli paradigma, generatörlerin her saat boyunca enerji talebini minimum maliyetle karşılaması gerektiğidir. Bunun gerçekleşmesi için elektrik sistemi modeli, generatörlerin özelliklerini, esnek olmayan talebi ve yenilenebilir elektrik kaynaklarının değişen çıktılarını doğru bir şekilde içeriğinde bulundurması gerekmektedir.

Ancak mevcut modellerin bazı temel eksiklikleri yahut kısıtlı yönleri vardır. Birincisi, elektrik talebinin saat başına enerjiye ayrıştırılması, mevcut olabilecek anlık beklenen tüketim hakkındaki bilgileri yok saymaktadır (Morales vd., 2017:224).

Elektrik piyasaları, şebekede anlık bir denge sağlamakla görevlendirildiğinden, gün öncesi piyasalarda bu tür bilgileri yok saymak verimsiz taahhüt kararlarına veya uygulanabilir olmayan programların zorlanarak uygulanmasına sebep olabileceği için verimsiz sonuçlar oluşturabilmektedir. Dahası, generatör tarafında oluşan eksiklikler generatör esnekliğinin yanlış beyan edilmesine zemin oluşturmaktadır ve elektrik talebini tam olarak takip etmek için gerekli olabilecek herhangi bir saat içi esnekliği barındırmamaktadır (Philipsen vd., 2016:6). Sonuç olarak, bu sistemlerin günlük çalışması oldukça verimsizdir ve elektriğin ulaştığı son

kullanıcılar açısından oldukça maliyetlidir. Bu maliyetler esas olarak daha fazla yedek kapasite ihtiyacından kaynaklanmaktadır. Gün öncesi programları hatalı varsayımlar üzerine yapıldığından, generatör esnekliğini olduğundan fazla tahmin ettiğinden ve anlık yükü temsil etmediğinden, gün öncesi programdan sapmaları telafi etmek için gerçek zamanlı olarak daha fazla yedek kapasite beklemede olmalıdır. Bu sorunların hem merkezi hem de kendi kendine zamanlama sistemlerinde var olduğu bilinmektedir (NERC, 2002:8). İlkinde bu verimsizlikler daha az verimli bir gönderime yol açarken, ikincisinde sistem güvenliğini ve güvenilirliğini önemli ölçüde etkileyen deterministik frekans sapmalarına yol açmaktadır (ENTSO-E ve Eurelectric, 2011). 1300 MW'lık bir üretim kesintisi 50 mHz'lik bir frekans düşüşüne neden olabilmektedir. Eşzamanlı bölge akşam saatlerinde piyasa ile ilgili frekans düşüşleri ortalama olarak 100 mHz'i aşmaktadır (UCTE, 2008:10). Bu geçici kıtlık ve aşırı üretim olayları, öngörülemeyen olayların üstesinden gelmeyi amaçlayan pahalı rezervler aracılığıyla çözülmektedir.

Bu sorunların tamamen, anlık üretim veya tüketim seviyelerini hesaba katmayan, ancak zaman birimi başına yalnızca enerjiyi hesaba katan elektrik programlarından kaynaklandığını belirtmek önemlidir. Bu nedenle bu hatalar, elektrik programlarının nasıl yapılandırıldığına bakılmaksızın, anlık üretimi göz ardı eden elektrik programları olan herhangi bir sistemin içerisine dahildir. Bu yüzden bu konu üzerine aracı olan piyasaların sayısını çoğaltmak yahut azaltmak bu sorunu çözemez ki zaten de çözmemelidir. Aracı piyasaların görevleri, tarafların belirsizlikle başa çıkmasına izin vermek başka bir yol bulmalarına olanak sağlamaktır.

Bulunan çözüm, elektrik programlarının anlık üretim ve tüketimi önceden belirleyerek ve öngörerek daha iyi temsil etmesini sağlamalıdır. Halihazırda gerçek dünya sistemlerinde çeşitli yollarla uygulanmakta olan mevcut durum, enerji programlarının anlık girişi ve çıkışı daha iyi temsil ettiği noktaya kadar elektrik programlarının çözünürlüğünü artırmaktır. Bununla birlikte, çözünürlükteki bu artış, hesaplamada katlanarak artan bir maliyetle gelmektedir.

#### **2.4. Yük Tahmini Gereksinimleri**

Bu bölüm, kullanıcı dostu ve iyi bir yük tahmin aracı geliştirmek için gereksinimleri listelemekte ve açıklamaktadır. İyi bir yük tahmin aracı, doğruluk, hızlı hız, kullanıcı dostu arayüz ve otomatik veri erişimi gereksinimlerini karşılamalıdır.

**Doğruluk:** Bir yük tahmin aracı tasarlamanın en önemli gerekliliği, tahmin doğruluğudur. Daha önce belirtildiği gibi, iyi doğruluk, ekonomik dağıtım, sistem güvenilirliği ve elektrik piyasalarının temelidir (Morales vd., 2017:230).

**Yüksek hız:** En son tarihsel verilerin kullanılması, doğruluğun artmasına yardımcı olmaktadır. Öngörülen sonucun son tarihi sabitlendiğinde, tahmin programının çalışma süresi ne kadar uzun olursa, program tarafından daha önceki geçmiş veriler kullanılabilir. Bu nedenle, tahminin hızı, tahmin programının temel bir gereksinimidir. Eğitim süresi çok uzun olan programlardan vazgeçilmeli ve eğitim süresini kısaltacak yeni teknikler kullanılmalıdır (Çevik, 2013:15).

**Kullanıcı Dostu Arayüz:** Yük tahmin aracının grafik kullanıcı arayüzü kolay, kullanışlı ve pratik olmalıdır. Kullanıcılar tahmin etmek istediklerini grafik veya tablolar aracılığıyla kolayca tanımlayabilmektedirler. Çıktı, kullanıcıların kolayca erişebilmesi için grafik ve sayısal formatta olmalıdır (Oğurlu, 2011:15).

**Otomatik Veri Erişimi:** Geçmiş veriler veri tabanında saklanmaktadır. Yük tahmin aracı, ona otomatik olarak erişebilmeli ve gerekli verileri alabilmelidir.

## 2.5. Yük Tahmininin Hedefleri ve Metrikleri

Bilimsel anlamda tahmin ve tahmine dayalı analitik, bir olasılıkla karakterize edilen ve istatistiksel veri analizine ve mevcut gelişmeye dayanan bir kişinin davranışını veya eğilimi tahmin etmek anlamına gelmektedir. Buna karşılık, tahmin, bir (toplu) tarihsel veri analizine, mevcut duruma ve bazen tahmine dayalı analitiklere dayanan değer veya belirli bir zaman noktasında bir olayın meydana gelmesi demektir (URL-1).

Elektrik yükü tahminleri, belirli bir zamanda tüketilen elektrik miktarının tahminini sağlamaktadır. Elektrik yükü tahmininin amacı çoğu durumda verimli bir ekonomi ve kalite planlamadır. İyi tahminler, hizmetin ekonomik karlılığını ve ağın güvenliğini sağlamaktadır.

**Tablo 2.1.** Tahmin doğruluğu ölçütleri

İsim	Kısaltması
Ortalama Kare Hata	MSE
Kök Ortalama Kare Hata	RMSE
Ortalama Tahmin Hatası	MFE
Ortalama Mutlak Sapma	MAD
Ortalama Mutlak Yüzde Hatası	MAPE
Ağırlıklı Ortalama Mutlak Yüzde Hatası	wMAPE

Ortalama Mutlak Hata (MAE), yaygın olarak kullanılan basit bir hata ölçüsüdür. MAE, mutlak hatanın ortalamasıdır.

$$\frac{1}{n} \sum |f_t - a_t| \quad (2.1)$$

$f_t$ :  $t$ . gerçek değeri ifade eder.  $a_t$ :  $t$ . tahmin değerini ifade eder. MAE'nin hesaplanması basit bir yöntemdir ve regresyon ilişkilerini incelemek için oldukça iyidir fakat bu yöntemin sınırlı yanları da mevcuttur. MAE, ölçülen verilerle aynı ölçektir. Bununla birlikte, farklı ölçeklerdeki verileri karşılaştırırken olası bir hata hakkında çok az fikir vermektedir. Büyük hataları / aykırı değerleri ve küçük hataları aynı şekilde ele almaktadır. MAE'ye alternatif bir yöntem gerekirse, RMSE veya özelleştirilmiş amaç fonksiyonları araştırılabilmektedir.

MAE'nin eksikliklerinden olan büyük hataları / aykırı değerleri ve küçük hataları aynı şekilde ele alması, hatayı normalleştirerek çözülebilir. Bu şu anda iki şekilde elde edilmektedir. Bunlar Ortalama Mutlak Yüzde Hatası (MAPE) ve normalleştirilmiş Ortalama Mutlak Hata (nMAE veya % MAE) ifade edilebilir.

$$MAPE = \frac{1}{n} \sum \frac{|f_t - a_t|}{a_t} \quad (2.2)$$

$f_t$ :  $t$ . gerçek değeri ifade eder,  $a_t$ :  $t$ . tahmin değerini ifade eder. MAPE, veriler üzerinde normalize edilen ve hatanın farklı ölçeklerdeki veriler arasında karşılaştırılmasına olanak tanıyan mutlak hatadır. MAPE, gerçek değer üzerinden normalize edilen, her veri noktası için hesaplanan ve ardından ortalaması alınan mutlak hatadır.

nMAE, MAPE'den farklıdır, çünkü ortalama hatanın ortalaması, tüm gerçek değerlerin ortalaması üzerinden normalleştirilir.

$$nMAE = \frac{\frac{1}{n} \sum |f_t - a_t|}{\frac{1}{n} \sum a_t} = \frac{\sum |f_t - a_t|}{\sum a_t} \quad (2.3)$$

$f_t$ :  $t$ . gerçek değeri ifade eder,  $a_t$ :  $t$ . tahmin değerini ifade eder

Hatanın hesaplanma şeklindeki küçük fark, özellikle objektif bir işlev olarak kullanıldığında çok farklı sonuçlar üretebilmektedir. MAPE her veri noktası üzerinden hesaplanmakta ve ortalaması alınmaktadır. Bu nedenle daha fazla hata ve aykırı değer yakalamaktadır. Öte yandan nMAE, ortalamadan önce yapılan hataların bir araya toplanması nedeniyle ayrıntıların bir kısmını kaybedebilmektedir.

MAPE, uygulamasının faydasına kıyasla dezavantajı daha fazladır, bunlar:

1. MAPE'yi hesaplamak için, sıfır hatasına bölünmeyi önlemek adına gerçek değeri sıfır olan veri noktalarının hariç tutulması gerekmektedir.

2. MAPE, yapılmış olan olumsuz hatalara daha büyük bir ceza maliyet değeri

vermektedir. Büyük ceza maliyet değeri vererek bu işlemin yapılmasının önüne geçmektedir. Bunun anlamı, aynı hata için, hatanın  $a^t < f^t$  hatalı olduğunda,  $a^t > f^t$  durumundan daha yüksek olmasıdır.

Mesela; gerçek değer 100 ve tahmini değer 90 için MAPE değeri % 10'dur. Aynı tahmini değer ve 80'in gerçek değeri için MAPE %12,5'tir. Bu nedenle, MAPE'yi objektif bir fonksiyon olarak kullanırken, tahminci daha küçük değerleri tercih eder ve negatif hatalara karşı önyargılı olabilmektedir. Veri kümelerine bağlı olarak, farklı hata önlemleri farklı gereksinimleri hedefleyebilmektedir. Bu yüzden tam hesaplamayı açıklamak, isimlendirmeye güvenmekten daha faydalı olabilmektedir.

### **2.5.1. Gecikme**

Şebeke istikrarı, yalnızca tüm operasyonel eylemler düşük gecikmeyle gerçekleştirilirse sağlanabilmektedir. Gecikme, bir işlemin tamamlanması için geçen toplam süredir. Gerçek zamanlı işleme gereksinimi olan tüm yazılımların amacı, işlemin gecikmesini en aza indirmektir. Gecikmenin ihmal edilebileceğini düşünmek yaygın yapılmakta olan bir hatadır.

Saeli vd. (2011:12)'e göre, üç tür gecikme bulunmaktadır.

- Veri yakalama gecikmesi - gönderilen mesajın gönderilmesi, alınması ve sırasının kaldırılması için geçen süre.
- Analiz gecikmesi - verilerin analiz edildiği süre.
- Eylem gecikmesi - alınan verilere tepki verme süresi.

Kullanıcılar genellikle en kötü durum gecikmesi, ortalama durum gecikmesi ve yüzde 99'luk dilim üzerinde durmaktadır. Yüzdeler dilim, belirli bir gözlem yüzdesinin aşmadığı bir değeri belirtmektedir. Beklenmedik derecede büyük bir gecikmeyle karşı karşıya kalan az sayıda müşteri bile bir şirkete çok paraya mal olabilmektedir. Özellikle kısa vadeli tahminlerde ve gerçek zamanlı uygulamalarda küçük bir gecikme bir zorunluluk haline gelmektedir. Elektrik tedarik hizmetinde, akıllı ölçüm veri analizinin düşük gecikmesi ve analiz üzerine kararlar, hizmetin şebeke operatörleri için uygun maliyetli ve şebeke için güvenli olmasını sağlayabilmektedir. Genellikle gecikme yüzdelik gösterimle hesaplanmaktadır. Bu nedenle, gecikmenin istatistiksel bir dağılımını hesaplamak için yeterli sayıda test veya gözlem dikkate alınmalıdır. Ayrıca, en kötü durum gecikmesi ve en iyi durum gecikmesi verilebilmektedir.

### **2.6. Yük Tahminini Etkileyen Faktörler**

Yük talebinin özellikleri, tüketim alanına, haftanın gün sayısına (bağımsız değişkenler

olarak adlandırılır) ve sosyal, meteorolojik, demografik ve ekonomik faktörlere göre değişir. Düşük hata yüzdesi ile yük tahmini çalışmaları yapabilmek için bu faktörlerin iyi değerlendirilmesi ve çalışmada dikkate alınması gerekmektedir (Esener, 2012: 16).

Yük talep özellikleri, tüketim alanına göre değişir. Sanayi alanlarının yük özellikleri, yerleşim yerlerinininkinden farklıdır. Bir şehrin veya coğrafi bölgenin yük özellikleri de şehrin veya coğrafi bölgenin bulunduğu ülkenin genel yük özelliklerinden farklıdır.

Yük talebi özellikleri de haftanın günlerine (gün tipi) göre değişir. Hafta içi yük özellikleri hafta sonlarına göre çok farklıdır (Esener, 2012: 16).

Hafta sonları gibi, dini bayramlar, ulusal bayramlar ve yeni yıl tatillerinde de yük özellikleri değişecektir. Bu günlerde bile aralarında farklı yük özellikleri vardır. Bu nedenle yerel tatiller ve normal günler için tek bir model oluşturmak zordur. Aksine literatür, yerel tatillere ilişkin verilerin değiştirilmesini veya bu günlerin tahmin çalışmasına dahil edilmemesini önermektedir (Osman vd., 2009).

Yük gereksinimleri demografik koşullara göre değişir. Nüfusun artması, elektrik tüketiminin artması anlamına gelir. Benzer şekilde, nüfusun azalması da elektriğin azalması ihtimaline işaret etmektedir (Esener, 2012: 16).

Meteorolojik koşullar (sıcaklık, yağış, nem, rüzgar vb.) de yük talebini etkileyen faktörlerden biridir. Örneğin hava sıcaklığındaki bir düşüş, ısınma amaçlı elektrik enerjisi tüketimine yol açar. Bu, havalar soğudukça güç tüketiminin artacağını gösterebilir.

KDYT(Kısa Dönem Yük Tahmini) araştırmalarında sıcaklık verileri genellikle bağımsız değişken olarak kullanılır. Bazı çalışmalarda sıcaklık verilerinin yanı sıra rüzgar, nem, yağış gibi meteorolojik veriler de kullanılmaktadır. Ayrıca sadece yük verilerinin kullanıldığı bir çalışma da yapılmıştır. Araştırmalar genellikle bölgesel yük tahminine odaklanmaktadır (Esener, 2012: 17).

Sistem yükünü modellemek için, yükü hangi koşulların veya faktörlerin etkilediğini anlamak gerekir.

### **2.6.1. Meteorolojik koşullar**

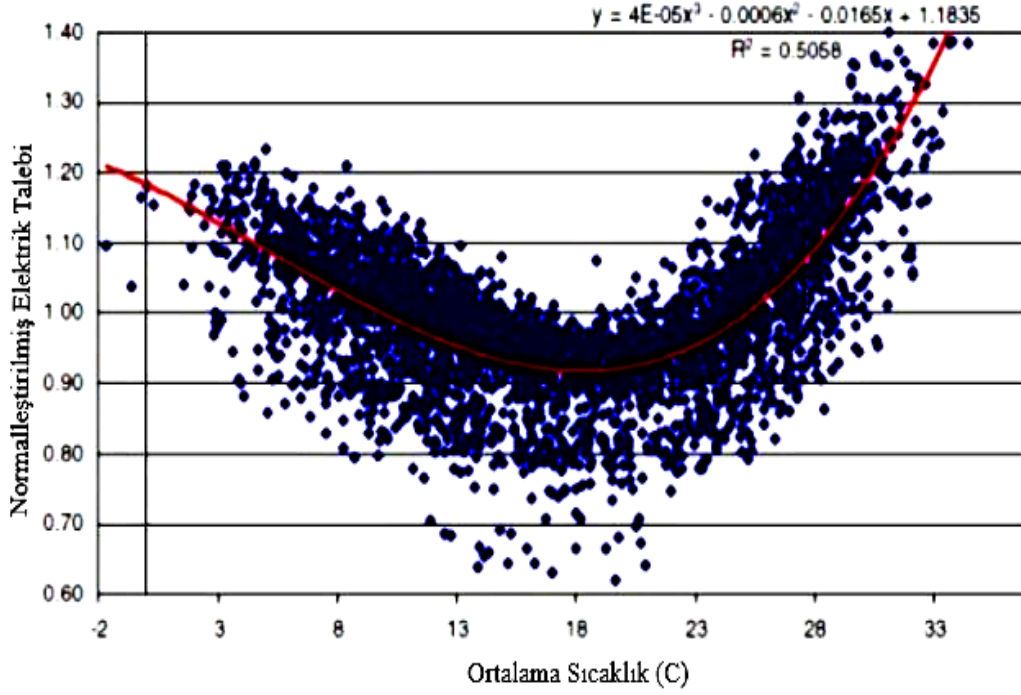
Hava koşullarının navlun talebinin büyümesi üzerinde önemli bir etkisi vardır. Bunun nedeni, ısıtma, havalandırma, iklimlendirme, tarımsal sulama vb. hava koşullarından etkilenen yüklerin sistemin toplam yükünün belirli bir oranında bulunmasıdır [14]. Elektrik sisteminin kayıtları kontrol edildiğinde birçok sistemdeki pik yüklerin anormal hava koşullarına karşılık

geldiği görülmektedir. Dünyanın birçok yerinde kış zirvesi genellikle en yüksek zirvedir. Özellikle sıcak ve nemli bölgelerde nem sadece sistem yükünü etkilemekle kalmaz, aynı zamanda sıcaklığı da etkiler. Sıcaklık ve nemin yanı sıra rüzgar hızı, yağış ve bulut yoğunluğunun da güç tüketimi üzerinde etkisi vardır.

Sıcaklık değişiklikleri, yük eğrisinde büyük değişikliklere neden olacaktır. Sıcaklığın yük üzerindeki etkisi tek tip değildir, mevsimlerin değişmesiyle değişecektir. Yaz ve kış aylarında hava oldukça farklıdır ve yük eğrisi farklıdır. Örneğin, kışın oda sıcaklığı düşer, ısıtma açılır ve güç tüketimi artarken, yazın sıcaklık arttıkça klima devreye girer ve güç tüketimi artar. Genellikle yük eğrisini etkileme açısından gündüz sıcaklığı en önemli hava değişkenidir, bu nedenle birçok kısa vadeli yük tahmini çalışmasında bağımsız değişken olarak seçilir. Önceki birkaç günün sıcaklığı da yük eğrisini etkileyecektir. Örneğin, art arda yüksek sıcaklıklı günlerle ısı birikecek ve güç talebinde yeni zirvelere neden olacaktır. Bazı çalışmalarda, sıcaklığın etkisinin sadece aktivite sıcaklığının değil, sıcaklık değişiminin bir fonksiyonu olduğu düşünülmektedir. Bunun nedeni, genel sıcaklığın ana etkisinin önceden mevsimsel yükten elde edilmesi ve yalnızca sıcaklık değişikliklerinin yükün değişmesine neden olmasıdır. Havaya duyarlı yüklere örnek olarak tarımsal sulama ekipmanları kullanılabilir. (Soliman ve AlKandari, 2010; Mıshra, 2008: 79-82).

Nem de önemli bir faktördür çünkü tüketici konforunu büyük ölçüde etkiler. Nem, özellikle yaz aylarında klimaların ve diğer soğutma ekipmanlarının çalışma verimliliğini etkiler. Sıcaklık çok yüksek olduğunda, yüksek nemin etkisi fark edilebilir. Bir diğer meteorolojik faktör rüzgar hızıdır. Rüzgarın soğutma üzerinde önemli bir etkisi vardır. Buna soğutma rüzgarı etkisi de denir. Rüzgar etkisi, kışın sıcaklığa ve rüzgar hızına bağlı bir etkidir. Aydınlatma yükünü harekete geçirebilecek meteorolojik etkilerin etkisi diğer faktörlere göre daha azdır. Gün içerisinde gün ışığı miktarının azalması sonucunda elektrikli aydınlatma ekipmanları devreye girmekte ve elektrik kullanımı artmaktadır. Bulutlu gökyüzü, toz, sis gibi faktörler gün ışığı seviyelerinde etkilidir (Çevik, 2013: 15).

Elektrik tüketimi ve sıcaklığın arasındaki ilişkiyi tespit etmek için birçok çalışma yapılmıştır. Mirasgedis ve Sarafidis 2007 yılında Yunanistan'daki elektrik talebinin sıcaklık ile ilişkisini analiz etmişlerdir. Normalize edilen yük değerleri ile günlük ortalama sıcaklık değerlerinin grafiği Şekil 2.1'de gösterilmiştir. Yapılan çalışmada hava koşullarının elektrik tüketiminde etkili olduğu görülmüştür. (Evren, 2021: 20).



**Şekil 2.1.** Normalize edilen elektrik yükü ile günlük ortalama sıcaklığı arasındaki ilişki

### 2.6.2. Zaman faktörü

Zaman faktörünün yük eğrisi üzerinde önemli bir etkisi vardır. Bu tür faktörler, mevsimsel, haftalık, günlük, resmi ve dini bayramlar gibi zaman yük eğrilerindeki farklılıklar nedeniyle gösterilmektedir. Mevsimsel değişiklikler, ülkelerin coğrafi konumlarına göre yaz veya kış yük zirvelerini belirlemelerine yardımcı olur. Güneşlenme süresi ve sıcaklık değişiklikleri gibi yük eğrisindeki bazı mevsimsel değişiklikler ani olaylar değil, kademeli olarak meydana gelir. Öte yandan, ani ve önemli yapısal değişiklikleri beraberinde getirebilecek bazı mevsimsel olaylar da vardır. Gün ışığından daha fazla yararlanmak, okul eğitiminde açılış ve kapanış saatleri, tatillerde etkinliklerin azaltılması için bunlar ileri/geri sayılabilir (Çevik, 2013: 14).

Yük tahmini açısından zaman faktörü en önemli faktördür. Mevsimsel etkiler ve dönemsel davranışların (günlük ve haftalık ritimler) yanı sıra resmi ve dini bayramların neden olduğu tatiller de zaman faktörüne dahildir (Biçer, 2018: 16).

### 2.6.3. Demografik faktörler

Uzun vadeli yük tahmininde yük talebini belirleyen en önemli faktörler ekonomik ve demografik faktörlerdir. Bilim ve teknolojinin gelişmesi ve kişi başına düşen gelirin ve diğer faktörlerin artması ile modern elektrikli ekipmanların kullanımı giderek yaygınlaşmakta ve elektrik tüketiminde artışa neden olmaktadır. Yeni ticari ve endüstriyel kuruluşların mal ve

hizmet tüketimi arttıkça, özellikle sanayide üretimde enerjiye olan talep artmaktadır (Biçer, 2018: 16).

Bu çalışmada sadece kısa dönemli yük tahminleri yapılacağı için ekonomik ve demografik faktörler ele alınmayacaktır.

#### **2.6.4. Rastlantısal faktörler**

Günümüz elektrik sistemlerinin çok sayıda kullanıcısı vardır. Her kullanıcının ne kadar güç tüketeceğini bilmek imkansız olsa da, tüm küçük kullanıcıların toplam yükü istatistiksel rehberlik sağlayabilmektedir. Bu, yük tahmini işinin temelini oluşturur. Ancak, çelik fabrikaları ve parçacık hızlandırıcı rüzgar tünelleri gibi büyük yüklerin başlangıcında ve sonunda, yük eğrisi belirgin değişiklikler gösterir. Bu yük dağıtıcının rastgele değişmesidir. Yük kullanıcılarının rastgele zamanıdır. Şebekeden çektikleri güç için zaman kuralı yoktur. Yükü etkileyen bazı rastgele olaylar da vardır. Örneğin Dünya Kupası sırasında TV kullanıcılarının artacağını bilmesine karşın kullanıcı sayısındaki belirsizlikler bu durumu teşkil etmektedir. Ayrıca grevler, toplumsal huzursuzluklar, fırtınalar, afetler, sanayi ve tesis arızaları gibi çeşitli rastgele faktörler hesaplanabilmektedir (Çevik, 2013: 15).

Yükü etkileyen ve yukarıda sayılan faktörlerle açıklanamayan olaylar rastgele faktörler olarak sınıflandırılır. Öte yandan endüstriyel tesislerin arızalanması, çarpması gibi etkenler yükte büyük belirsizliğe neden olacaktır (Biçer, 2018: 17).

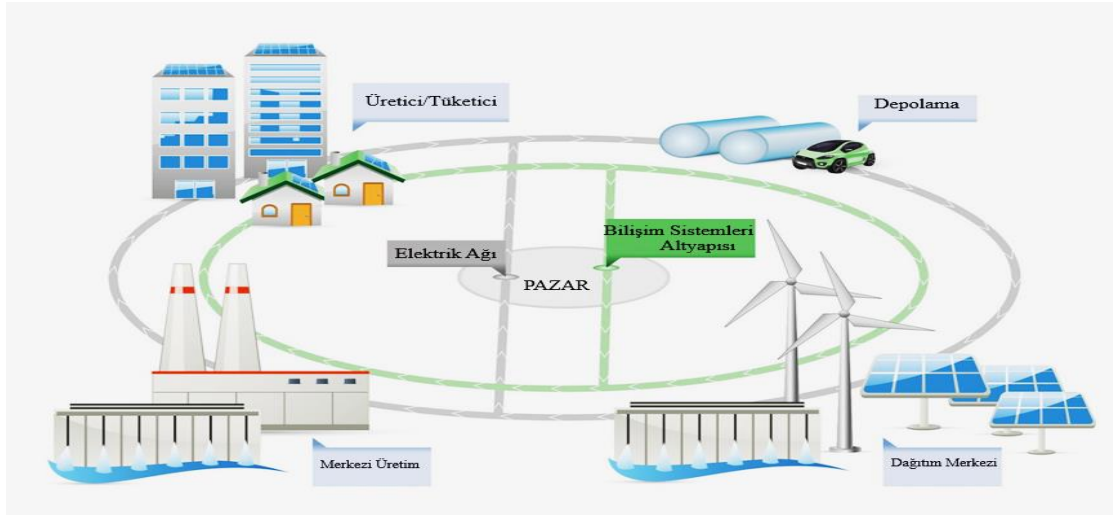
#### **2.6.5. Ekonomik faktörler**

Ekonomik faktörler, uzun vadeli yük tahmininde en önemli faktördür. Teknolojinin gelişmesi, sanayileşmenin hızı, kişi başına düşen gelirin artması, elektrikli ekipmanların yaygınlaşması ve ekonomik büyüme rakamları etkili ekonomik faktörlerdir. Nüfus arttıkça nakliye talebi de artacaktır. Yeni ticari ve sanayi kuruluşlarının mal ve hizmet tüketimi arttıkça ve nüfus arttıkça bu durum özellikle sanayi sektöründe enerji talebinin artmasına neden olmaktadır (Ceylan, 2004). Ayrıca endüstriyel faaliyetlerin hızı, tarım sektöründeki değişiklikler ve kullanılan elektrikli ekipmanın doğası gibi değişkenler de sistem yükünün artması veya azalması eğiliminde önemli bir rol oynamaktadır (Tan, 1997). Ayrıca bazı yıllarda özellikle büyük ülkelerde yaşanabilecek ekonomik kriz tüm dünyada hissedilmekte ve güç tüketimi etkilenmektedir.

### 3. YÜK TAHMİNİNDE KULLANILAN YÖNTEMLER

Tarihsel olarak, elektrik şebekesi, birkaç merkezi güç üreticisinin bir bölge veya tüm bir ülke için tüm elektriği sağladığı dağıtım olmuştur. Elektrik daha sonra geniş bir iletim hatları ve transformatör ağı üzerinden kullanıcıya sunulmaktadır. Bu eski sistem, yaklaşık bir asırdır iyi hizmet vermiş olsa da, yeni çevresel ve toplumsal zorlukların yanı sıra yaşlanan altyapı açısından da bir güncellemeye ihtiyaç duyulmaktadır (Fan, vd. 2013:33). Enerjinin telekomünikasyon, ulaşım, internet ve elektronik ticaretle birleşmesinden ortaya çıkan Akıllı Şebeke, elektrik arz ve talebi için yeni bir altyapı olduğu görülmektedir (Amin ve Wollenberg, 2005:36). Bu enerji ağları, enerji akışlarını otomatik olarak izleyebilmekte, arz ve talepteki değişikliklere uyum sağlayabilmektedir (E. Commission, 2017). Elektrik Şebeke Mimarisi, (Austria, 2016)'dan Şekil 3.1, elektrik şebekesini ve paydaşlarını görselleştirmektedir.

Şekil 3.1'de gösterilen, Elektrik şebekesini (gri çizgi) ve elektrik şebekesini etkinleştiren Bilişim Teknolojisi altyapısını (yeşil hat) göstermektedir. Merkezden gelen ve merkeze doğru uzanan küçük beyaz oklar, iki yönlü güç ve iletişim akışını görselleştirmektedir. Bu, sol üstte tasvir edilen ofis binaları ve evleri gibi tüketicilerin aynı zamanda üretici olarak hareket etmesini ve yenilenebilir enerji kaynaklarından üretilen fazla enerjiyi şebekeye geri vermesini sağlamaktadır. Sağ üstte depolamalı santraller gibi farklı enerji depolama çözümleri görselleştirilmiştir. Kömür santralleri gibi konvansiyonel enerji üretim tekniklerinin yanı sıra PV sistemleri gibi yenilenebilir enerji kaynakları sırasıyla sol altta ve sağda görselleştirilmiştir.



Şekil 3.1. Elektrik şebekesi ve paydaşları.

**Kaynak:** (E. Commission, 2017)

Elektrik talebini doğru bir şekilde tahmin etmeye çalışmaya odaklanma amaç olmalıdır. Bu nedenle, sonraki elektrik şebekelerinde talep tahmini hakkında yeterli bilginin elde edilmesi gerekir.



Şekil 3.2. Talep Tahmin Yöntemleri.

Kaynak: (Biçer, 2018: 15)

### 3.1. Analitik Yöntemler

Yük tahmini araştırmalarında kullanılan ana analiz yöntemleri benzer gün yöntemi, en küçük kareler yöntemi, regresyon analizi, zaman serisi analizi ve dalgacık dönüşümüdür.

#### 3.1.1. Benzer gün yaklaşımı

Bu yöntem doğrudan bir tahmin yöntemi olmamakla birlikte tahmin çalışmasında kullanılan veri setini belirlemek için kullanılmaktadır. Bu yöntemin temeli, veri setinden tahmin edilen günlere benzer özelliklere sahip günleri bulmaktır (Mandal vd., 2006). Gün sayısının benzer özellikleri, meteorolojik koşulların (hava koşulları), ekonomik koşulların, demografik koşulların, sosyal koşulların (normal günler, yerel tatiller) ve gün türlerinin (Pazartesi, Salı, Çarşamba, Perşembe, Cuma, Cumartesi, Pazar) olduğu anlamına gelir (Esener, 2012: 18).

#### 3.1.2. En küçük kareler yöntemi

EKKY, E.2.1'de verilen soruda gerçek değer ile tahmin edilen değer arasındaki farkın karelerinin toplamını minimize ederek bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi belirler (Soliman ve Al-Kandari, 2010).

Denklemden,  $Z$ ,  $\theta$ ,  $H$  ve  $v$  terimleri  $m \times 1$  boyutunun bağımlı değişken vektörünü,  $n \times 1$  boyutunun ilişkisel parametre vektörünü,  $m \times n$  boyutunun bağımsız değişken vektörünü ve hata vektörünü temsil eder (Esener, 2012: 19).

En küçük kareler yöntemi, önce maliyet fonksiyonunun doğrusallaştırılması şartıyla, doğrusal olmayan problemlerin çözümü için de uygundur.

### **3.1.3. Regresyon analizi**

Regresyon analizi, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi belirlemek için kullanılan analitik bir yöntemdir. Bağımlı değişken ile bağımsız değişken arasında bir dağılım grafiği çizerek, iki değişken arasında bir bağlantı kurulup kurulamayacağını ve varsa ne tür bir fonksiyonun işleneceğini belirleyin (Oğurlu, 2011). Regresyon analizi; basit regresyon, çoklu regresyon, doğrusal olmayan regresyon olarak üç alt başlık altında incelenebilir. (Palit ve Popovic, 2005).

### **3.1.4. Dalgacık dönüşümü**

Dalgacık dönüşümü, Fourier dönüşümüne dayalı bir sinyal analiz yöntemidir. Fourier ve kısa süreli Fourier dönüşümüne alternatif olarak sürekli dalgacık dönüşümü (SDD), sinyalin frekans bileşenlerini farklı büyüklükteki alanlarda gerekli zaman aralığında belirlemek için geliştirilmiştir. Ayrık Dalgacık Dönüşümü'nde (ADD), sinyal istenilen düzeyde düşük frekans ve yüksek frekans bileşenlerine ayrılır (Esener, 2012: 22).

## **3.2. Yapay Zeka Yöntemleri**

Bu bölümde yapay zeka yöntemleri ifade edilecektir. Bunlar bulanık mantık, destek vektör makineleri, yapay sinir ağları olarak ifade edilebilir.

### **3.2.1. Bulanık mantık**

Bulanık Mantık kavramı 1965 yılında Loft A. Zadeh tarafından önerilmiştir. Bulanık mantık ile klasik mantık arasındaki temel fark, klasik mantığın önerme olarak yalnızca "0 veya 1" veya "doğru veya yanlış" değerlerini kullanmasıdır. Verilerin eksiksiz ve net olması gerektiğinden, karmaşık sistemleri klasik mantık yöntemleriyle modellemek ve kontrol etmek zordur. Öte yandan, bulanık mantık yöntemleri, karmaşık problemlerin çözümüne yardımcı olan "0-1" aralığındaki her değeri kullanabilir.

Bulanık teorinin temel kavramı bulanık kümedir. Bulanık kümeler, net sınırları olmayan ve kişiden kişiye değişen, yani matematikte kolayca ifade edilemeyen veri kümeleridir. Bulanık küme, üyelik fonksiyonu ile temsil edilir. Üyelik fonksiyonu 0 ile 1 arasında herhangi bir değer alabilir. Böyle bir üyelik fonksiyonunu kullanarak, fonksiyona ait verilerle ilgili olarak "kesinlikle ait" veya "kesinlikle ait değil" arasında ince ayar yapmak mümkündür.

Bulanık mantıkta bir diğer önemli kavram ise dilsel değişkenler kavramıdır. Dil

değişkenleri, kelimeler ve ifadeler ile tanımlanabilen değişkenlerdir. Dil değişkenlerinin değeri, bulanık kümelerle de temsil edilebilir.

Bulanık mantığın sağladığı en büyük fayda, "insan deneyiminden öğrenme" olgusunu kolaylıkla modelleyebilmesi ve bulanık kavramları matematiksel olarak ifade edebilmesidir. Bu nedenle, doğrusal olmayan sistemlerin yaklaştırılması için özellikle uygundur. Bu amaçla bir kural tabanı oluşturulmuştur. Kural tabanı, insanların şimdiye kadar elde ettiği tüm gözlemleri, deneyimleri ve matematiksel ilişkileri, yani araştırılan nesne hakkındaki tüm bilgileri içermelidir. Kural tabanı ne kadar iyi hazırlanır ve kapsam ne kadar geniş olursa, elde edilen sonuçlar o kadar doğru olur (Esener, 2012: 24).

Bulanık sistem yöntemleri, yük değişim faktörlerini (yük tahmininde sıcaklık ve tarih türleri gibi) tahmin ederken iyi sonuçlar verebilir (Oğurlu, 2011).

### **3.2.2. Destek vektör makineleri (Support Vector Machines – SVM)**

Temel olarak destek vektör makinesi, Vapnik Chervonenkis tarafından tanımlanan istatistiksel öğrenme algoritmalarından biridir ve birçok pratik problemde başarılı sonuçlar vermiştir. İlk başarılı uygulama 1990'lı yıllarda gerçekleştirilmiş, bu uygulamalardan sonra matematikçilerin ve yapay zeka bilim adamlarının ilgi odağı haline gelmiştir (Karagülle, 2008). Destek vektör makinelerinin makine öğrenmesi alanında başarılı bir şekilde uygulanmasının ardından son yıllarda uzaktan algılama alanında da başarıyla uygulanan bir sınıflandırma yöntemidir.

Bu sınıflandırma yöntemi, verilerin daha yüksek boyutlara dönüştürülmesiyle oluşturulan bir hiperdüzlem ile iki sınıfın birbirinden ayrılması ilkesine dayanmaktadır. Daha yüksek boyutlara dönüşüm için farklı niteliklere sahip fonksiyonlar kullanılır. Bu fonksiyonlara kernel fonksiyonları denir (Kavzoğlu ve Çölkesen, 2010). Kernel fonksiyonlarının kullanılabilmesi için bu fonksiyonların matematiksel ifadelerindeki bazı parametrelerin kullanıcı tarafından belirlenmesi gerekmektedir (Kavzoğlu ve Çölkesen, 2010). DVM son zamanlarda yüz tanıma, biyoloji, örüntü tanıma ve veri madenciliği gibi alanlarda kullanılmaktadır.

### **3.3. Yük Tahmini Çeşitleri**

Elektrik enerjisi planlaması, ekonomik ve sosyal hedeflere dayalı, yerinde, zamanında, istenilen kalite seviyesi, güvenilirlik ve en düşük maliyetle ve ihtiyaçları göz önünde bulundurularak yapılır. Yük tahmini, plana göre farklı zaman periyotları için gerçekleştirilen güç sistemi planlamasının ilk adımıdır. Yük tahmini, enerji sisteminin planlamasına göre kısa

vadeli, orta vadeli ve uzun vadeli tahmin alt periyotlarına bölünerek gerçekleştirilir (Ceylan, 2004: 6):

- Uzun dönem yük tahmini
- Orta dönem yük tahmini
- Kısa dönem yük tahmini
- Çok kısa dönem yük tahmini

Etkili güç sistemlerinin planlanması ve verimli bir şekilde işletilmesi için gerekli olan puant yük ve enerji talebinin tahmin edilmesinin temelini oluşturan yük tahmini kavramı ise; geçmişteki koşulların ve verilerin incelenerek gelecekteki durumun tahmin edilmesine dayanır.

### **3.3.1. Kısa dönem yük tahmini**

Kısa dönem yük tahmini (KDYT), enerji planlama sektörünün ayrılmaz bir parçasıdır. Bir dönem sonraki enerji piyasası tasarlamak, yeni üretim, iletim ve dağıtım için talep planlamasını yapmak gerekmektedir. KDYT, güç sistemi operatörlerine güç sistemindeki tedarik planlaması, üretim rezervi, sistem güvenliği, dağıtım planlaması, talep tarafı yönetimi, finansal planlama vb. dahil olmak üzere çeşitli kararlar alma konusunda yardımcı olmaktadır. KDYT, sonraki dönem elektrik piyasası operasyonu için özellikle gereklidir. Fakat hatalı yapılan talep tahmini, şirkete muazzam bir mali yüke sebep olacaktır (Fallah vd., 2019:393).

Geleneksel olarak, mühendislik yaklaşımları gelecek dönemlerdeki talebi çizelgeler ve tablolar yardımıyla elle tahmin etmektedir. Bu geleneksel yöntemler esas olarak hava etkilerinin yanı sıra takvim etkilerini de dikkate almaktadır. Günümüzde bu özellikler, yeni yöntemlerle yük modelleri geliştirmek için hala kullanılmaktadır (Hong ve Fan, 2016:920).

### **3.3.2. Orta dönem yük tahmini**

Orta dönem yük tahmini (1-12 aylık) bir zaman aralığını kapsar (Abu-Shikhah vd., 2011:2). Bu tür bir tahmin, temelde büyüme faktörlerine, yani ana olaylar, yeni yüklerin eklenmesi, mevsimsel değişiklikler, büyük tesislerin talep modelleri ve büyük tüketicilerin bakım gereksinimleri gibi talebi etkileyen faktörlere bağlıdır. Dahası, bu tür bir tahmin, günlerin en yüksek yükünün veya önümüzdeki haftaların tahmini için saatlik yükleri kullanmaktadır. Bu bilgilerle, belirli bir süre içinde belirli tesislerin bakıma alınıp alınmayacağına karar verilebilir. Bu aynı zamanda büyük testlerin ve devreye alma olaylarının planlanmasına ve tesislerin, büyük ekipman parçalarının kesinti sürelerinin belirlenmesine yardımcı olacaktır. Bu tür bir tahmin için kullanılan analiz yöntemleri, kısa dönem tahmine benzemektedir. Bununla birlikte, orta dönem tahminin güç sistemi operasyonları üzerindeki

duyarlılığının, kısa dönem tahminden daha az olduğu belirtilmelidir (Abu-Shikhah vd., 2011:2).

Elektrik yükü zaman içinde sürekli değiştiği için bir zaman serisi olarak kabul edilir. Bu, yüklerin mevcut geçmiş verilerine dayalı olarak gelecekteki yükleri tahmin etmek için farklı zaman serisi teknikleri ve metodolojileri kullanılır.

### **3.3.3. Uzun dönem yük tahmini**

Uzun dönem yük tahmini 1 yıldan daha fazla bir zaman aralığını kapsar. Uzun dönem elektrik yükü tahmini, elektrik güç sistemlerinin dönüşümünün önemli bir parçasıdır ve hem akademisyenlerden hem de endüstri temsilcilerinden giderek daha fazla ilgi görmektedir (Zakarya vd., 2017:1530).

Prensip olarak, bir yük tahmin modeli, yük ve etkili parametreler arasındaki ilişkinin matematiksel bir gösterimini amaçlamaktadır. Böyle bir model, gelecekteki yük değerlerini tahmin etmek için kullanılmaktadır. Sonuç olarak, modelin doğruluğu hem seçilen modele hem de tahmin edilen parametrelerin doğruluğuna bağlıdır. Literatür çalışmasında görüldüğü üzere, uzun dönem yük tahmininin kısa dönem yük tahminine göre daha az ilgi gördüğünü ortaya koymaktadır. Bunun nedeni, doğru bir tahminin gerçekleştirilmesindeki karmaşıklığıdır. Uzun dönem yük tahmini, finans, istatistik, olasılık ve uygulamalı matematik bilgilerinin entegre edilmesine dayanmaktadır. Yük artışı/düşüşü ve teknoloji evrimi hakkında çıkarımlarda bulunmaktadır. Khuntia vd. (2016:3975), uzun dönem yük tahmini kavramını rasyonel bir şekilde göstermiş ve ayrıca elektrik enerjisi endüstrisindeki son gelişmeleri sunmuştur. Feinberg ve Genethliou (2005:6), zaman serisi yaklaşımı, ekonometrik yaklaşım ve son kullanım yaklaşımı olarak uzun dönem tahmin için üç yöntem önermiştir.

Uzun dönem tahmin için, tüm yaklaşımlar geçmiş dönem verilere ihtiyaç duymakta ve genel olarak geleneksel (istatistiksel) ve geleneksel olmayan (yapay zeka) tabanlı metodolojiler olarak kategorize edilmektedir. Son zamanlarda, uzun dönem tahminlerde olasılıklı yöntemlerin kullanımı da görülmektedir (Hong vd., 2014:459; Hong ve Fan, 2016:925).

### **3.3.4. Çok kısa dönem yük tahmini**

Bir saatten daha kısa süreli tahminlere aşırı kısa vadeli yük tahminleri denir. Ultra kısa vadeli yük tahmininin amacı, iş kontrol merkezi operatörlerine talep sorunlarına neden olacak bir yük artış trendi olup olmayacağını bildirmektir. Bu durumda üretim yük dengelemesine müdahale etmemek için acil kararlar ve aksiyonlar alınmalıdır. Bu, sistem genellikle bir tepe noktası olarak tanımlanan 17:00 ile 22:00 arasında aşırı yüklendiğinde meydana gelir (Neto, et al. 2011).

Jeneratör hız regülatörünün ani yük değişikliklerine verdiği ana tepkiye, bir dakika içinde yük bozulmaları eşlik eder. Bu yanıt, otomatik üretim kontrol sisteminin temel amacını karşılar, ancak regülatör ayar faktörleri nedeniyle sistem frekansı ve net alan güç değişiklikleri "yarı sürekli durum" tipi hatalardan etkilenecektir. Bu nedenle enerji yönetim sistemindeki yük frekans kontrol fonksiyonu, belirlenen frekans ve net alan güç değişim değerini birkaç dakika içerisinde tamamlayarak ikinci amacına ulaşır. Üçüncü amaca ise ekonomik dağıtım fonksiyonu ile ulaşılır (Ceylan, 2004: 11).

Yük frekansı kontrolü ve ekonomik dağıtım, yalnızca yük bozulmalarına veya belirtilen frekans ve net alan gücü ofset değerinden önemli sapmalara yanıt verir. Bu nedenle, daha yüksek derecede ayarlama yöntemleri gerektirirler. Yük frekansı kontrol sistemi, yük talebinin anlık tahminine dayalı olarak geliştirilmiştir. Ancak, yük talebinin dalgalanma oranı, üretim arzının dalgalanma oranından daha yüksek olup, gerçek zamanlı yük tahminini yetersiz kılmaktadır. Yük frekansını tam olarak kontrol etmek için ileriye dönük bir bakış açısı gereklidir. Yük frekans kontrol stratejilerini daha iyi tasarlamak için çok kısa süreli yük tahmini sonucunda elde edilen 15-30 dakikalık yük trendi bilgisi faydalı olacaktır (Charytoniuk et al. 2000: 263-268).

### **3.5. Talep Tahmin Tekniklerinin Sınıflandırılması**

Günümüzde talep tahmin teknikleri ile ilgili birçok çalışma yapılmıştır. Literatürde, tahmin ve tahmin yöntemlerinin süresine dayalı çeşitli sınıflandırma türleri önerilmiştir.

Talep tahmin yöntemleri, tahmin modelinde kullanılan matematiksel analiz derecelerine göre de sınıflandırılabilir. Bunlar nicel ve nitel yöntemler olmak üzere iki temel çeşittir. Çoğu durumda, geçmiş veriler yetersizdir veya mevcut değildir. Nitel tahmin yöntemleri genellikle planlamacılar tarafından doğru tahmin yapmak için kullanılır. Bu yöntemler Delfi yöntemi, Eğri uydurma (Curve fitting) ve diğer yöntemlerdir. Ayırıştırma yöntemleri, regresyon analizi, üstel yumuşatma ve BoxJenkins yaklaşımı gibi diğer tahmin teknikleri nicel yöntemlerdir. Literatürdeki makalelerde sunulan çeşitli çalışma türlerine dayanarak, yük tahmin teknikleri geniş olarak üç ana grupta gruplandırılabilir. Bunlar; geleneksel tahmin tekniği, değiştirilmiş geleneksel teknikler ve esnek hesaplama (soft computing) tekniğidir (Singh vd., 2012:5).

#### **3.5.1. Geleneksel tahmin teknikleri**

Günümüzde en önemli konulardan biri, kalkınma eğilimlerini ve ülkenin genel kalkınma endeksini planlamak için gelecekteki yük taleplerini tahmin etmektir. İlk günlerde, bu tahminler matematiksel model temelli geleneksel yöntemlerle gerçekleştirilmiştir. Gelişmiş araçların

ortaya çıkması ile bu teknikler, çeşitli çalışma alanlarında daha etkili tahmin için araştırma bulguları ile zenginleştirilmiştir. Geleneksel tahmin teknikleri şunlardır: regresyon, çoklu regresyon, üstel düzeltme ve yinelemeli yeniden ağırlıklandırılmış en küçük kareler tekniğidir (Singh vd., 2012:7).

**Regresyon Yöntemi:** En yaygın kullanılan istatistiksel tekniklerden biridir ve uygulanması genellikle kolaydır. Regresyon yöntemleri genellikle yük tüketimi ve hava koşulları, gün türleri ve müşteri sınıfları gibi diğer faktörler arasındaki ilişkiyi modellemek için kullanılır. Bu yöntem, yükün standart bir yük eğilimine ve yükü etkileyen bazı faktörlere doğrusal olarak bir eğilime bölünebileceğini varsaymaktadır (Ding, 2006:1542).

**Çoklu regresyon:** En popüler yöntemdir ve genellikle meteorolojik etkilerden, sermaye başına büyüme, elektrik fiyatları, ekonomik büyüme gibi çeşitli faktörlerden etkilenen yükü tahmin etmek için kullanılır. Yük tahmini için Çoklu Regresyon analizi, en küçük kare tahmini tekniğini kullanır (Mbamalu ve El-Hawary, 1992:345).

**Üstel düzeltme:** Yük tahmini için kullanılan yaklaşımlardan biridir. Bu yöntemde, önce yük önceki verilere dayalı modeldir, ardından bu modeli gelecekteki yükü tahmin etmek için kullanır (Infield ve Hill, 1998:1118).

**Yinelemeli Yeniden Ağırlıklı En Küçük Kareler:** Model sırasını ve parametrelerini tanımlamak için yinelemeli olarak yeniden ağırlıklandırılmış en küçük kareler prosedürü kullanılmaktadır. Yöntem, her seferinde bir değişkeni kontrol eden ve optimum başlangıç noktasını belirleyen bir operatör kullanır. Optimal bir modelin ve sonraki parametre tahminlerinin belirlenmesinde ağırlıklandırma fonksiyonu, ayar sabitleri ve kare kalıntılarının ağırlıklı toplamı tarafından üç yönlü bir karar değişkeni oluşturulur (Mbamalu ve El-Hawary, 1992:347).

### **3.5.2. Değiştirilmiş geleneksel teknikler**

Geleneksel tahmin teknikleri, değişen çevre koşulları altında tahmin modelinin parametrelerini otomatik olarak düzeltebilecekleri şekilde değiştirilmektedir. Bu geleneksel tekniklerin değiştirilmiş versiyonu olan tekniklerden bazıları uyarlamalı yük tahmini, stokastik zaman serileri ve destek vektör makine tabanlı tekniklerdir (Jacob vd., 2020:27).

### **3.5.3. Esnek hesaplama teknikleri**

Her sistemin kesin olarak modellenmesinin zor olduğu bir gerçektir. Bu tür modelleri etkili ve en verimli şekilde ele almak için Esnek Hesaplama tekniği adı verilen bir yaklaşım

ortaya çıkmıştır. Son yıllarda çok yaygın olarak kullanılmaktadır. Esnek hesaplama, insan zihninin belirsizlik ortamında akıl yürütme ve öğrenme konusundaki olağanüstü yeteneğine paralel olarak ortaya çıkan bir yaklaşımdır. Bilgisayar tabanlı zeki sistemlerin, insan zihninin kesin olmaktan uzak akıl yürütme yeteneğini taklit eden bir araç olarak ortaya çıkmaktadır. Esnek hesaplamanın temel teması, kesinliğin bir maliyet taşıdığı ve zeki sistemlerin, mümkün olan her yerde, belirsizlik toleransından yararlandığı gerçeğidir. Esnek hesaplama, bulanık mantık (Fuzzy Logic), sinir ağları (Neural Network), genetik algoritmalar (Genetic Algorithm) gibi evrimsel algoritmalar (evolutional algorithm) vb., yöntemleri içermektedir (Bouktif vd., 2018:12).

### **3.6. Makine Öğrenmesi**

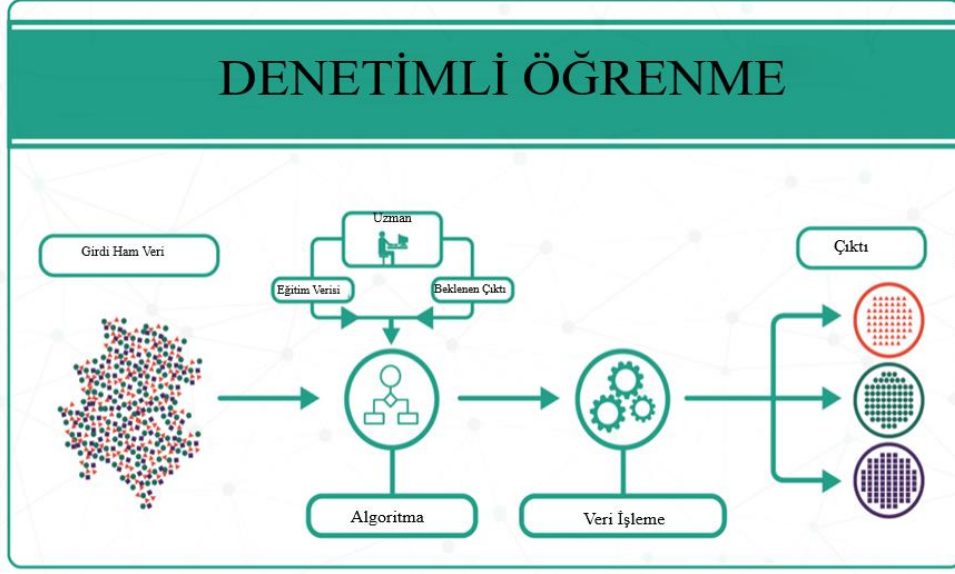
Yapay Zeka (AI) ve Makine Öğreniminin arkasındaki kavramlar araştırıldığında, bu çalışma alanıyla ilgili çok sayıda tanımla karşılaşılmaktadır. Bu tanımları anlamak ve makine öğrenimi ile ilgili çalışmayı nasıl etkileyebileceğini anlamak, yapay zekayı şu anki durumuna getirmek için araştırmacılar ve veri bilimciler tarafından yürütülen çalışmayı anlamada uzun bir yol kat edilmektedir.

Denetimli, denetimsiz ve pekiştirilmiş Makine Öğrenimi, temel olarak, makinelerin veya algoritmaların bir veri kümesinde gevşemesine izin verilebilen yolların bir açıklamasıdır. Makinelere ayrıca süreçten faydalı bir şeyler öğrenmeleri beklenmektedir. Denetimli, denetimsiz ve pekiştirmeli öğrenme, parlak olması beklenen ve zamanla insanlara günlük işleri yapmada yardımcı olacak makinelerin geleceğine giden yolu açmaktadır.

#### **3.6.1. Denetimli öğrenme**

Denetimli öğrenmeyle ilgili teknik ayrıntılara girmeden önce, bu büyüyen alandaki deneyimlerinden bağımsız olarak tüm okuyucular tarafından anlaşılabilir kısa ve basit bir genel bakış vermek zorunludur.

Denetimli öğrenme ile, algoritmaların çıktısı sistemde beslenmektedir. Bu denetimli öğrenmede, makinenin üzerinde çalışmaya veya öğrenmeye başlamadan önce algoritmanın çıktısını zaten bildiği anlamına gelmektedir. Bu kavramın temel bir örneği, bir öğretmenden ders alan bir öğrenci olabilmektedir. Öğrenci dersten ne öğrendiğinin farkındadır.(Bouktif vd., 2018:15).



**Şekil 3.3.** Denetimli öğrenme.

**Kaynak:** (Alpaydın, 2010:18).

Algoritmanın çıktısı bilindiğinde, bir sistemin yapması gereken tek şey, girdiden çıktıya ulaşmak için gereken adımları veya süreci çalıştırmaktır. Algoritma, makineyi yönlendiren bir eğitim veri seti aracılığıyla öğretilmektedir. Süreç karışır ve algoritmalar beklenenden tamamen farklı sonuçlar veririrse, eğitim verileri algoritmayı doğru yola geri yönlendirmek için rolünü yerine getirmektedir.

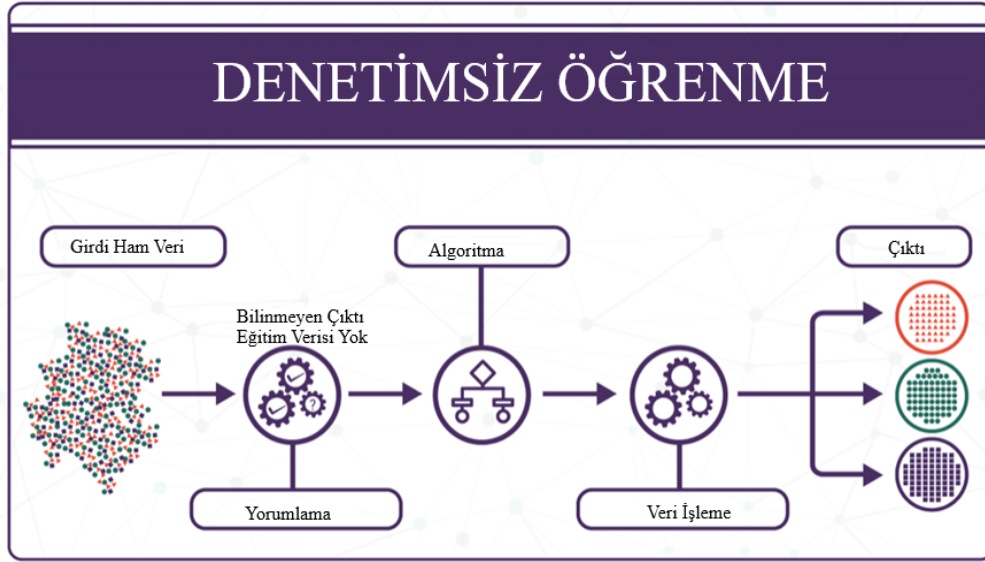
Denetimli Makine Öğrenimi, günümüzde dünya çapında sistemler tarafından kullanılan makine öğreniminin çoğunu oluşturmaktadır. Giriş değişkeni ( $x$ ), bir algoritma kullanarak çıktı değişkenine ( $y$ ) bağlanmak için kullanılmaktadır. Tüm girdi, çıktı, algoritma ve senaryo insanlar tarafından sağlanmaktadır. Denetimli öğrenme iki tür problem üzerinden bakarak daha iyi bir şekilde anlaşılabilir.

**Sınıflandırma:** Sınıflandırma problemleri, çıktıyı oluşturan tüm değişkenleri kategorilere ayırmaktadır. Sınıflandırma yoluyla oluşturulan bu kategorilerin örnekleri, medeni durum, cinsiyet veya yaş gibi demografik verileri içermektedir. Bu tür hizmet durumu için kullanılan en yaygın model, destek vektör makinesidir. Destek vektör makineleri, doğrusal karar sınırlarını tanımlamak için ortaya konmuştur (Hong vd., 2014:461).

**Regresyon:** Regresyon problemleri olarak sınıflandırılabilir problemler, çıktı değişkenlerinin gerçek sayı olarak ayarlandığı türleri içermektedir. Bu sorunun biçimi genellikle doğrusal bir biçim izlemektedir.

### 3.6.2. Denetimsiz öğrenme

Denetimsiz öğrenme kavramı, denetimli öğrenme kadar yaygın değildir ancak çok sık kullanılmaktadır. Denetimsiz öğrenmenin henüz daha geniş bir ölçekte uygulanmamış olmasına rağmen, bu metodoloji Makine Öğreniminin ve olanaklarının arkasındaki geleceği oluşturmaktadır. Gelecek yıllarda sınırsız fırsatlar ortaya koyması ve çıkarması beklenen makine öğrenmesinden sıklıkla bahsedilmektedir.(Hong ve Fan, 2016:936)



Şekil 3.4. Denetimsiz öğrenme

**Kaynak:** (Learned-miller, 2014:3)

Denetimsiz öğrenme sürecinde, sistem somut veri setlerine sahip değildir ve çoğu sorunun sonuçları büyük ölçüde bilinmemektedir. Basit bir terminolojide, AI sistemi ve makine öğrenimi hedefi, operasyona girdiğinde kördür. Sistem, yol boyunca ona rehberlik edecek hatasız ve muazzam mantıksal işlemlere sahiptir, ancak uygun giriş ve çıkış algoritmalarının olmaması, süreci daha da zorlaştırmaktadır. Tüm süreç, denetimsiz öğrenme, tüm bilgisayar sistemlerinde bulunan giriş verileri ve ikili mantık mekanizması aracılığıyla sınırsız miktarda veriyi yorumlama ve bunlara çözüm bulma yeteneğine sahiptir. Sistemin hiç referans verisi yoktur.

Üzerinde çeşitli renkli geometrik şekiller bulunan dijital bir görüntü olduğu düşünüldüğünde, bu geometrik şekillerin renk ve diğer sınıflandırma özelliklerine göre gruplar halinde eşleştirilmesi gerekmektedir. Denetimli öğrenmeyi takip eden bir sistem için tüm bu süreç biraz fazla basittir (Hong ve Fan, 2016:926).

Prosedür son derece basittir, çünkü bilgisayara rakamlarla ilgili tüm ayrıntıları öğretmek yeterlidir. Sisteme, dört kenarlı tüm şekillerin kareler olarak bilindiğini ve sekiz kenarlı

diğerlerinin sekizgenler olarak bilindiđini bildirilmelidir. Ayrıca sisteme renkleri yorumlamayı ve verilen ışığın nasıl sınıflandırıldığını görmeyi öğretebilmektedir. Bununla birlikte, denetimsiz öğrenmede, tüm süreç biraz daha karmaşık hale gelmektedir. Denetimsiz bir öğrenme sistemi için algoritma, denetlenen muadili için olanla aynı girdi verilerine sahiptir (Ding, 2006:1541).

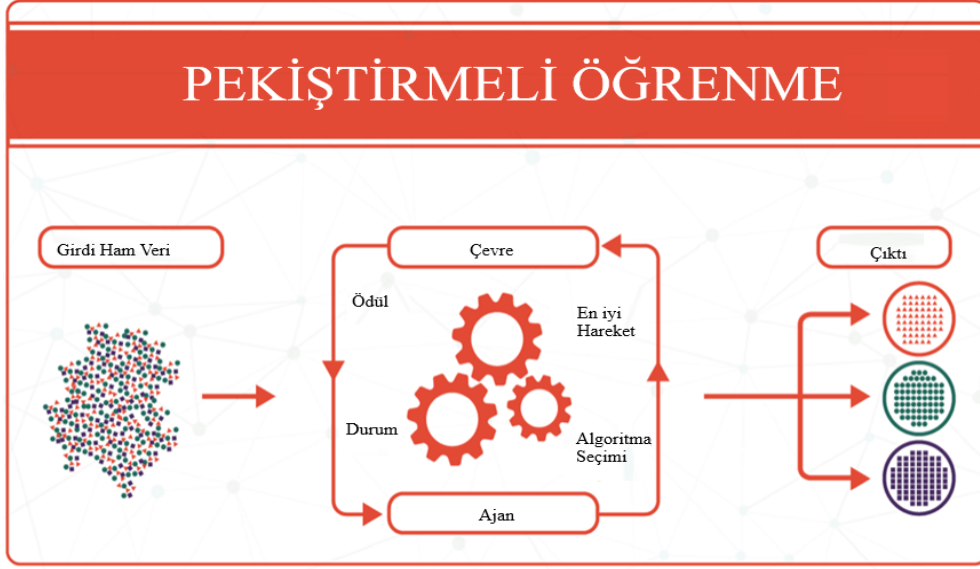
Girdi verilerini aldıktan sonra, sistem elindeki bilgilerden öğrenebildiđi her şeyi öğrenmektedir. Aslında, sistem sınıflandırma problemini ve ayrıca şekil ve renklerdeki farklılığı tanımak için kendi kendine çalışmaktadır. Eldeki sorunla ilgili bilgilerle, denetimsiz öğrenme sistemi daha sonra tüm benzer nesnelere tanıyacak ve bunları bir arada gruplandıracaktır. Bu nesnelere vereceđi etiketler makinenin kendisi tarafından tasarlanacaktır. Teknik olarak, belli bir olasılık derecesi olduđu için yanlış cevaplar olması kaçınılmazdır. Bununla birlikte, tıpkı biz insanların nasıl çalıştığı gibi, makine öğreniminin gücü de hataları tanıma, onlardan öğrenme ve bir dahaki sefere daha iyi tahminler yapma becerisinde yatmaktadır.

### **3.6.3. Pekiştirmeli öğrenme**

Pekiştirmeli Öğrenme, makine öğreniminin, makinenin ilerlemesinden öğrenmesine nasıl yardımcı olduđu konusunda çok fazla prestij kazanan bir başka parçasıdır. Pekiştirmeli Öğrenme, denetimsiz öğrenme konseptinden yola çıkmakta ve bir bağlam içindeki ideal davranışın ne olabileceđini belirlemek için yazılım araçlarına ve makinelere yüksek bir kontrol alanı sağlamaktadır. Bu bağlantı, makinenin performansını, büyümesine yardımcı olacak şekilde en üst düzeye çıkarmak için oluşturulmuştur. Makinenin davranışını öğrenmesine yardımcı olmak için burada makineyi ilerlemesi hakkında bilgilendiren basit geri bildirim gereklidir (Fallah vd., 2019:393).

Pekiştirmeli öğrenme basit değildir ve çok sayıda farklı algoritma tarafından ele alınmaktadır. Nitekim, pekiştirmeli öğrenmede bir temsilci, sonuçların mevcut durumuna bağlı olarak en iyi eyleme karar vermektedir.

Pekiştirmeli öğrenmedeki büyüme, makinelerin yaptıklarının sonucunu öğrenmesine yardımcı olan çok çeşitli algoritmaların üretilmesine yol açmıştır. Şimdiye kadar pekiştirmeli öğrenme hakkında temel bir anlayışa sahip olduđu için, pekiştirmeli öğrenme ile daha önce detaylı olarak bahsedildiđi için denetimli ve denetimsiz öğrenme kavramları arasında karşılaştırmalı bir analiz oluşturarak daha iyi kavranılmaktadır (Hong ve Fan, 2016:929).



**Şekil 3.5.** Pekiştirmeli öğrenme.

**Kaynak:** (Alpaydın, 2010:22)

Denetimli ve Pekiştirmeli Öğrenme: Denetimli Öğrenmede, çevre hakkında yeterli bilgiye sahip olan ve aynı zamanda daha iyi bir anlayış oluşturmak ve görevi tamamlamak için öğrenmeyi bir süpervizörle paylaşan bir dış süpervizör bulunmaktadır. Ancak temsilcinin bu kadar çok farklı türde alt görevi yerine getirebileceği sorunlar olduğu için genel hedefe ulaşmak adına bir denetçinin varlığı gereksizdir ve pratik değildir. Oyuncunun nihai hedefe ulaşmak için on binlerce hamle oynayabileceği bir satranç oyunu örneğini konuyu anlatmak ve anlamak için faydalı olacaktır. Bu amaç için bir bilgi tabanı oluşturmak gerçekten karmaşık bir görev olabilmektedir.

Bu nedenle, bu tür görevlerde bilgisayarın işleri kendi başına nasıl yöneteceğini öğrenmesi zorunludur. Dolayısıyla makinenin kendi deneyimlerinden öğrenmesi daha uygun ve yerinde olmaktadır. Makine kendi deneyimlerinden öğrenmeye başladığında, daha sonra gelecekteki hamlelerde uygulamak üzere bu deneyimlerden bilgi edinebilmektedir. Bu muhtemelen pekiştirme ve denetimli öğrenme kavramları arasındaki en büyük ve en zorunlu farktır. Her iki öğrenme türünde de, çıktı ve girdi arasında belirli bir tür eşleştirme vardır. Ancak Pekiştirmeli Öğrenim kavramında, Denetimli Öğrenmenin aksine, sistemin doğru yolda ilerleyişini bilmesini sağlayan örnek bir ödül işlevi vardır (Jacob vd., 2020:22).

Pekiştirmeli ve Denetimsiz Öğrenme: Pekiştirmeli Öğrenme temelde makineyi girdiden çıktıya yönlendiren bir eşleştirme yapısına sahiptir. Ancak, Denetimsiz Öğrenimin içinde böyle bir özellik yoktur. Denetimsiz Öğrenmede, makine, nihai hedefe doğru ilerlemek için

haritalama yerine modellerin yerini belirleme görevine odaklanmaktadır. Örneğin, makinenin görevi bir kullanıcıya iyi bir haber güncellemesi önermekse, Takviye Öğrenme algoritması söz konusu kullanıcıdan düzenli geri bildirim almaya çalışacak ve ardından geri bildirim yoluyla tüm haberlerin saygın bir bilgi grafiğini oluşturacaktır. Aksine, bir Denetimsiz Öğrenme algoritması, buna benzer şekilde kişinin okuduğu diğer birçok makaleye bakmayı deneyecek ve kullanıcının tercihlerine uyan bir şey önerecektir (Ding, 2006:1543).

#### **3.6.4. Terminoloji**

Sınıflandırma, veri girişlerinin kolayca kategorilere ayrılabilirdiği denetimli öğrenmenin (etiketli verilerle öğrenme) bir parçasıdır. En popüler sınıflandırma algoritmalarından biri, kesin sınıflandırmalara yol açan tekrarlanan soruların zaman içinde olasılıklar havuzunu daraltmak için bir “eğer-öyleyse” çerçevesi oluşturabildiği bir karar ağacıdır (Alpaydın, 2010:33). Kümeleme, veri noktalarının özelliklere ve özniteliklere göre gruplandırılmasını içeren bir denetimsiz öğrenme biçimidir. Kümeleme, müşteri demografisini ve satın alma davranışını hedefleme ve ürün konumlandırma için belirli segmentler halinde düzenlemek için kullanılabilir. Ayrıca, gayrimenkul değerlemeleri oluşturmak ve yeni şehir gelişmelerinin yerleşimini planlamak için konut kalitesini ve coğrafi konumları analiz edebilmektedir. Bilgileri kitaplıklar veya web sayfaları içindeki konulara göre sınıflandırabilmekte ve kullanıcılar için kolay erişilebilir bir dizin derleyebilmektedir.

En yaygın kümeleme türü, her kümenin bir "k" değişkeni ile temsil edilmesini ve ardından bu kümelerin merkezlerinin tanımlanmasını içeren K-ortalımalı kümelemedir. Tüm veri noktaları daha sonra belirli bir kümeye atanır ve bu işlem aracılığıyla yeni kümelerin merkezi belirlenmektedir (Ding, 2006:1542).

Regresyonlar, farklı veri türleri arasında ilişkiler ve korelasyonlar oluşturmaktadır. Örneğin, her profil resminin bir kişiye ait piksellere sahip bir resmi vardır. Statik tahmin yöntemi ile makine öğrenimi belli bir piksel düzenlemesi yaparak belirli bir isme karşılık gelmektedir (Learned-miller, 2014:4).

Regresyonlar, mevcut verilere dayalı olarak sonuçları tahmin ederken de yararlı olabilmektedir. Uzun bir süredir, bir felçten sonra bilişsel işlevlerin iyileşmesini tahmin etmek veya telekomünikasyon endüstrisindeki müşteri kaybını tahmin etmek gibi sorunları çözmek için istatistiksel regresyon kullanılmıştır. Tek fark, artık bu regresyon analizlerinin birçoğunun makineler tarafından daha verimli ve hızlı bir şekilde yapılabilmesidir.

Regresyon, girdileri ve çıktıları etiketlenebilen bir tür yapılandırılmış makine öğrenme

algoritmasıdır. Doğrusal regresyon, fiyatlandırma verileri gibi sürekli değişkenlere (bir aralıktaki herhangi bir değer) sahip çıktılar sağlamaktadır. Lojistik regresyon, değişkenlerin kategorik olarak bağımlı olduğu ve etiketli değişkenlerin tam olarak tanımlandığı zamandır. Örneğin, bir mağazanın açık olup olmadığını (1) veya (0) olarak sınıflandırabilmektedir ancak bunun için yalnızca iki olasılık vardır.

Burada bulunan diğer regresyon türleri polinom regresyonu, destek vektör regresyonu, karar ağacı regresyonu ve rastgele orman regresyonudur (Singh vd., 2012:9).

Derin Öğrenme, makine öğrenimine benzer - aslında, insan beyninin işleyişini taklit eden bir makine öğrenimi uygulamasıdır. Derin öğrenme ağları, büyük verileri (tek bir bilgisayara sığamayacak kadar büyük olan veriler) hem yapılandırılmamış hem de yapılandırılmış yorumlar ve kalıpları tanımaktadır. Ne kadar çok veriden "öğrenebilirler", kararları o kadar bilgili ve doğru olacaktır. İşte pratikte derin öğrenmeye ilişkin bazı örnekler aşağıda verilmiştir.

Sohbet robotları ve sanal asistanlar: Alexa ve Siri gibi sanal asistanlar veya farklı web sayfalarındaki müşteri hizmetleri sohbet robotları insan isteklerini alabilmektedir, dili deşifre edebilmekte ve gerçeğe yakın yanıtlar sunabilmektedir (Jacob vd., 2020:30).

Gerçek zamanlı teklif verme ve programatik reklamcılık: Reklamcılık artık, rekabetçi bir teklif verme süreci aracılığıyla reklam alanı satın alan yazılımlara bağlıdır. Cognitiv AI , belirli bir hedef pazar için özel satın alma algoritmaları oluşturmak için müşteri demografisi, hava durumu, kullanılabilir envanter, günün saati ve diğer değişkenlerle ilgili verileri sentezleyen bir derin öğrenme platformunun bir örneğidir.

Öneri motorları, booking.com ve Expedia gibi seyahat sitelerinden Netflix ve Spotify gibi yayın platformlarına kadar öneri motorları, pazarlamayı özelleştirmek için geçmiş satın alma veya kullanım davranışlarından öğrenmektedir. İki öneri motoru biçimi vardır. Bunlar; kullanıcı tercihi verilerinin ölçekte toplandığı ve kullanıcıların benzer kullanıcı kişilikleriyle karşılaştırıldığı işbirlikçi ve belirli öğelerin özelliklerinin analiz edildiği ve gelecekteki öğelerin belirlemek için geçmiş öğelerle karşılaştırıldığı içeriğe dayalı filtreleme en yakın eşleşmelerdir (Hong vd., 2014:458).

Nöral ağlar, derin öğrenme ile yakından ilişkilidir. Doğru bir analiz sağlamak için bir makineden toplanan verilerin anlaşılmasını derinleştiren sıralı nöron katmanları oluşturmaktadırlar.

Bir sinir ağı, "tetikleyici" verilerden uyarı alan düğüm katmanlarından oluşmaktadır.

Bazı veri girişleri diğerlerinden daha önemli olabileceğinden, bu verilere daha sonra katsayılar aracılığıyla bir ağırlık atanmaktadır.


Nöronlar normalde üç farklı katman halinde gelmektedir. Bunlar; bir veri giriş katmanı, matematiksel hesaplamalara sahip gizli bir katman ve bir çıktı katmanıdır. Uçak bileti fiyatlarını tahmin etmek istenilen bir örnekte, girdi katmanı başlangıç havalimanını, varış havalimanını, kalkış tarihini ve havayolunu toplayacaktır. Bunların her biri bir ağırlık alacak ve ardından çıktı bir fiyat tahmini sunacaktır (Bishop, 1995:35).

### 3.6.5.Fazla uyum (overfitting) ve yetersiz uyum (underfitting)

Fazla uyum, eğitim verilerini çok iyi modelleyen bir modeli ifade etmektedir. Fazla uyum, bir model eğitim verilerindeki ayrıntı ve gürültüyü, modelin performansını yeni veriler üzerinde olumsuz olarak etkilediği ölçüde öğrendiğinde gerçekleşmektedir. Bu, eğitim verilerindeki gürültü veya rastgele dalgalanmaların model tarafından kavramlar olarak alındığı ve öğrenildiği anlamına gelir. Sorun, bu kavramların yeni veriler için geçerli olmaması ve modellerin genelleme yeteneğini olumsuz yönde etkilemesidir (Brownlee, 2017).

Bir hedef işlevi öğrenirken daha fazla esnekliğe sahip olan parametrik olmayan ve doğrusal olmayan modellerde fazla uyum olasılığı daha yüksektir. Bu nedenle, birçok parametrik olmayan makine öğrenme algoritması, modelin ne kadar ayrıntı öğrendiğini sınırlamak ve sınırlamak için parametreler veya teknikler de içermektedir.

Örneğin, karar ağaçları, çok esnek olan ve aşırı uygun eğitim verilerine tabi olan parametrik olmayan bir makine öğrenme algoritmasıdır. Bu sorun, bir ağaç öğrendikten sonra, aldığı ayrıntıların bir kısmını ortadan kaldırmak için budanarak çözülebilmektedir.



Şekil 3.6. Fazla uyumun, optimal noktanın ve yetersiz uyumun görselleştirilmesi.

Kaynak:(Sharma, 2017)

Makine öğreniminde yetersiz uyum ise eğitim verilerini modelleyemeyen veya yeni verilere genelleştiremeyen bir modeli ifade etmektedir. Yetersiz bir makine öğrenimi modeli uygun bir model değildir ve eğitim verilerinde zayıf performans göstereceği için açık olacaktır. İyi bir performans ölçütü verildiğinde tespit edilmesi kolay olduğu için yetersiz uyum genellikle tartışılmamaktadır. Çözüm, devam etmek ve alternatif makine öğrenimi algoritmalarını denemektir. Yine de, fazla uyum sorunuyla iyi bir tezat oluşturmaktadır (Joechtl, 2012:11).

İdeal olarak, yetersiz ve fazla uyum arasındaki optimal noktada bir model seçmek istenmektedir. Bu amacın pratikte gerçekleştirilmesi çok zordur. Bu hedefi anlamak için, bir eğitim verilerini öğrenirken bir makine öğrenimi algoritmasının zaman içindeki performansına bakılmaktadır. Hem eğitim verilerindeki beceriyi hem de beceriyi eğitim sürecinden uzak tuttuğumuz bir test veri kümesindeki beceriyi çizilebilmektedir.

Zamanla, algoritma öğrendikçe, eğitim verilerindeki model hatası ve test veri kümesindeki hata da azalmaktadır. Çok uzun süre eğitim yapılırsa, model fazla uyumlu olduğundan ve eğitim veri setindeki alakasız ayrıntı ve gürültüyü öğrendiğinden eğitim veri setindeki performans düşmeye devam edebilmektedir. Aynı zamanda, modelin genelleme yeteneği azaldıkça test seti hatası yeniden yükselmeye başlamaktadır.

Optimal nokta, modelin hem eğitim veri kümesinde hem de görünmeyen test veri kümesinde iyi beceriyeye sahip olduğu test veri kümesindeki hatanın artmaya başlamasından hemen önceki noktadır (Sharma, 2017).

Bu deney, makine öğrenme algoritmalarıyla gerçekleştirilmesi uygun olacaktır. Bu, pratikte genellikle yararlı bir teknik değildir, çünkü test veri setindeki beceriyi kullanarak eğitim için durma noktasını seçmek, test setinin artık "görünmez" veya bağımsız bir objektif ölçü olmadığı anlamına gelmektedir.

Pratikte optimal noktayı bulmaya yardımcı olmak için kullanabilecek iki ek teknik vardır. Bunlar; yeniden örnekleme yöntemleri ve bir doğrulama veri kümesidir.

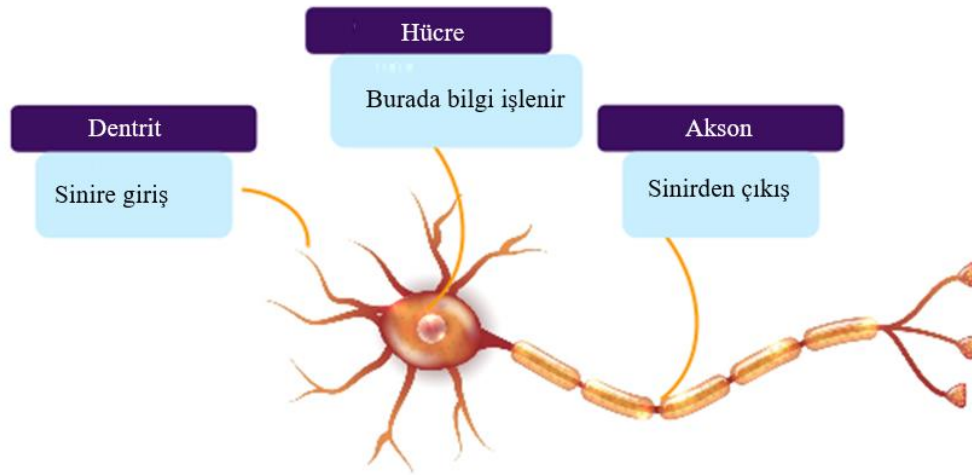
### **3.7. Yapay Sinir Ağları**

İnsan beyni, insan vücudundaki en karmaşık organdır. Düşünmeye, anlamaya ve karar vermeye yardımcı olur. Gücünün arkasındaki sır bir nörondur. 1950'lerden beri bilim adamları bir nöronun işleyişini taklit etmeye ve onu daha akıllı ve daha iyi robotlar yapmak için kullanmaya çalışmaktadır. Pek çok deneme yanılma sürecinden sonra insanlar sonunda insan konuşmasını tanıyabilen bir bilgisayar oluşturmuştur. Ancak 2000 yılından sonra insanlar, çeşitli görüntüleri ve videoları görebilen ve ayırt edebilen derin öğrenmede (bir AI alt kümesi)

uzmanlaşmışlardır (Chollet, 2017:42).

Derin öğrenme, bilgisayarlardan insanlara doğal olarak gelen şeyi yapmalarını isteyen bir makine öğrenimi alt kümesidir. Bilim adamları, herhangi bir derin öğrenme tabanlı makineye güç veren yapay bir nöron (biyolojik) formu oluşturmayı başarmışlardır. Makine örnek olarak resimlerle eğitilerek, donanımsal öğrenmeden farklı olarak bilgisayar programı destekli tanıma ve öğrenme uygulamalarını kapsar. Bilgisayar, daha önce beslenen görüntülere dayanarak nesneyi tanımlar.

Yapay bir nöronun çalışmasının anlaşılması için, biyolojik nöronun nasıl çalıştığını bilmek faydalı olacaktır. Şekil 3.7’de biyolojik bir nöronun çalışması gösterilmektedir. (Oliver vd., 2018:3230).



**Şekil 3.7.** Biyolojik bir nöronun çalışması.

**Kaynak:**( Oliver vd., 2018:3230)

Dendritler, kendisine bağlanan diğer nöronlardan bilgi veya sinyaller olarak sinir hücrelerine aktarım gerçekleştirirler. Vücut hücresi, bilgi işleminin gerçekleştiği hücre gövdesidir. Bunlar, farklı dendritlerden gelen tüm bilgileri almakta ve bu bilgileri işlemektedir.

Akson: Çıkış sinyalini bilgi akışı için başka bir nörona göndermektedir Burada, iletimi sağlayan kanalların her biri bir sonrakindeki dendrite veya kılcallara bağlanmaktadır. (Anderson ve Mcneill, 1992:22). Şekil 3.8’de YSA gösterilmektedir.

Ağ, verileri alan bir giriş katmanıyla başlamaktadır. Gizli katmanlara bağlanan çizgilere ağırlık denir ve bunlar gizli katmanlara eklenmektedir. Gizli katmandaki her nokta girdileri işlemekte ve bir sonraki gizli katmana ve son olarak çıktı katmanına bir çıktı sağlamaktadır (Bishop, 1995:45).



**Şekil 3.8.** Yapay sinir ağı yapısı.

**Kaynak:** (Anderson ve Mcneill, 1992:22).

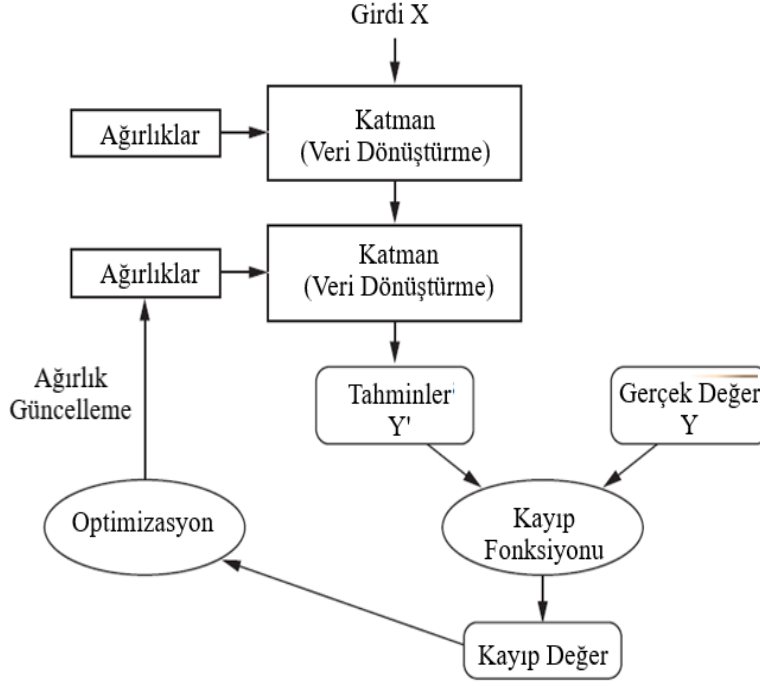
Yukarıdaki iki şekle bakarak, bir YSA'nın biyolojik bir nöronu nasıl kopyaladığını görmek mümkündür.

- Bir nörona girdi: girdi katmanı
- Nöron: gizli katman
- Sonraki nörona çıkış: çıktı katmanı

Sinir ağı, insan beynindeki nöronların işleyişinden sonra tasarlanmış bir donanım veya yazılım sistemidir. Yapay sinir ağları olarak da adlandırılan sinir ağları, derin öğrenmeye ulaşmanın yollarıdır.

### 3.7.1. Öğrenme süreci

Bir sinir ağının öğrenme sürecindeki temel mantık, hata puanını her bir yinelemedeki ağırlıkların değerini biraz doğru yönde ayarlamak için bir geri bildirim sinyali olarak kullanmaktır, böylece hata puanı küçülmektedir. Bu süreç Şekil 3.8'de görselleştirilmiştir. Ağırlık ayarlaması, sözde geri yayılım algoritmasını uygulayan bir optimize edici tarafından gerçekleştirilmektedir (Chollet, 2017:50). Başlangıçta ağırlıklar rastgele başlatılmaktadır. Daha sonra giriş ağı konmakta ve çıktı belirlenmektedir (Joechtl, 2012:13). Çıktı istenen değer değilse, ağırlıklar yukarıda belirtildiği gibi düzeltilmektedir. Ağırlıkların düzeltilmesi işe yarar çünkü çıktı fonksiyonları türetilmekte, bu da algoritmaya ağırlığın düzeltilmesi gereken yönü verir ki bu da gradyan inişi olarak adlandırılmaktadır (Sharma, 2017). Bütün bir ağda, her katmanda farklı ağırlıklar vardır. Genellikle çıktı katmanının ağırlıkları önce ve sonra üstteki gizli katmanın ağırlıkları düzeltilmektedir (Joechtl, 2012:18).



**Şekil 3.9.** Sinir ağı öğrenme süreci .

**Kaynak:** (Chollet, 2017:52).

Ağırlıkları düzeltme sürecine optimizasyon denir. Amaç, eğitim verilerinde mümkün olan en iyi performansı elde etmek için ağırlıkları ayarlamaktır. Amaç, verileri ezberlemeden yeni görünmeyen veriler üzerinde iyi performans gösteren bir modele sahip olmaktır, bu da modelin iyi genelleştirebileceği anlamına gelmektedir (Chollet, 2017:47). Ağırlıkları düzeltmek için farklı optimize ediciler kullanılabilir. Bir makine öğrenimi modeli için bir optimizasyon algoritmasının seçilmesi, dakikalar, saatler veya günler cinsinden iyi sonuçlar arasında bir fark anlamına gelebilir (Brownlee, 2017). Tipik olarak, bu amaç için stokastik gradyan iniş algoritmaları kullanılmaktadır (Le vd., 2011:267). Stokastik gradyan inişi, bilgisayarla görme ve doğal dil işlemede derin öğrenme uygulamaları için geniş bir şekilde benimsenmiştir (Brownlee, 2017). Gradyan iniş yaklaşımında ağırlıklar rastgele olarak başlatılmaktadır (Curtis ve Scheinberg, 2017:95).

Hesaplama açısından, gradyan iniş algoritması, tüm veri seti üzerinden bir geçiş gerektirmesinden dolayı pahalı olabilmektedir. Bu, özellikle veri seti büyük olduğunda karşılaşılan durumdur. Adım boyutu, öğrenme hızı olarak da bilinir ve sabittir ve de yeterince küçüktür. Stokastik gradyan yöntemi, tekrarlama başına maliyetin gradyan inişinden daha az olması avantajıyla stokastik denklem sistemlerini çözmek için bir varyasyondur. Bunun nedeni, stokastik gradyan yönteminin her yinelemesinde gerçek gradyanın tarafsız bir tahmin edicisinin

hesaplanmış olmasıdır. Bu tahminci, düşük bir maliyetle hesaplanabilir (Curtis ve Scheinberg, 2017:98). Stokastik gradyan tabanlı optimizasyon algoritması bilim ve mühendislikte büyük önem taşımaktadır (Kingma ve Ba, 2014).

Pek çok problem, parametrelerine göre maksimizasyon veya minimizasyon gerektiren bazı skaler parametrize optimizasyon fonksiyonunun optimizasyonu olarak görülebilmektedir (Kingma ve Ba, 2014). Adam optimizer, stokastik gradyan inişinin bir uzantısıdır (Brownlee, 2017). Bu, yalnızca çok az bellek gereksinimi olan birinci dereceden gradyanlara ihtiyaç duyan etkili stokastik optimizasyon yöntemidir (Kingma ve Ba, 2014). Adam'ın geliştiricileri, bunu diğer iki stokastik gradyan inişi uzantısı arasındaki bir kombinasyon olarak tanımlamaktadır. Bunlar; uyarlanabilir gradyan algoritması ve ortalama karekök ortalamasıdır (Brownlee, 2017).

YSA'nın çıktıları tamamen, başlangıçta uzman bir sistem tarafından kendilerine verilen girdiler ve sonuçlarla sınırlı değildir. Bu yetenek, robotik ve örüntü tanıma sistemleri için kullanışlıdır. Bu ağ, yüksek hata toleransı potansiyeline sahiptir ve kendi başına bir ağda hata ayıklama veya tanımlama yapabilmektedir. (Oliver vd., 2018:3241).

### **3.7.2. Sinir ağlarının geleceği**

Yapay zeka ve makine öğreniminin günümüzde şirketler tarafından benimsenme şekliyle, sinir ağlarının uygulamalarında daha fazla ilerleme görülmektedir. Tüm dünyadaki kullanıcılar için kişiselleştirilmiş seçenekler olacaktır. Tüm mobil ve web uygulamaları, arama geçmişine dayalı olarak gelişmiş ve özelleştirilmiş bir deneyim sunmaya çalışmaktadır.

Öğrenme yöntemlerini desteklemek için algoritmalar üzerinde birkaç ilgi çekici keşif beklenmektedir. Yapay zeka ve sinir ağları gerçek dünyaya uygulama aşamasındadır. Yapay sinir ağları gelecekte çok daha hızlı olacak ve sinir ağı araçları her tasarım yüzeyine yerleştirilebilecektir. Pahalı olmayan bir işlem panosuna veya hatta dizüstü bilgisayara takılan küçük bir sinir ağı zaten mevcuttur. Yazılım yerine donanıma odaklanmak, cihazları daha da hızlı hale getirecektir.

Sinir ağları tıp, tarım, fizik, keşifler ve hayal edebilecek diğer her alanda kullanım imkanı bulmakta ve bundan sonraki dönemlerde de bir çok alanda kullanımı öngörülmektedir.

### **3.8. Uzun Kısa Süreli Bellek (LSTM)**

Tekrarlayan veya çok derin sinir ağlarının eğitilmesi zordur, çünkü sıklıkla kaybolan gradyan probleminden muzdariptirler. Uzun vadeli bağımlılıkları öğrenirken bu eksikliğin üstesinden gelmek için, LSTM mimarisi tanıtılmıştır (Hochreiter ve Schmidhuber 1997:1750).

LSTM'nin öğrenme yeteneği, hem pratik hem de teorik açıdan birçok alanı etkilemiştir. Bu yöntem Google tarafından konuşma tanıma için (Sak vd., 2015) ve Google Çeviri'de (Metz 2016) makine çevirilerini iyileştirmek için kullanılmıştır. Amazon, modeli Alexa'nın işlevlerini iyileştirmek için kullanmış (Vogels, 2016) ve Facebook bunu 2017 itibariyle günde 4 milyardan fazla LSTM tabanlı çeviri için kullanmıştır (Pino vd., 2017).

Yüksek uygulanabilirliği ve popülaritesi nedeniyle, bu sinir mimarisi oyun dünyasına da girmiştir. Örneğin, Google'ın Deepmind'ı, Starcraft II'yi oynamak için tasarlanmış bir yapay zeka olan AlphaStar'ı geliştirmiştir. AlphaStar'ın gelişimi boyunca, oyunda ustalaşmaya başlamış ve daha önce görülmemiş olan küresel sıralamada yükselmiştir (The AlphaStar Team 2019). Araştırma ilgisi, karmaşıklığı nedeniyle tüm RTS oyun türünü kapsadığından, bu alandaki araştırmalar elbette Starcraft II ile sınırlı değildir (Zhang vd., 2019:1240). Diğer ortamlarda pekiştirmeli öğrenme konusunu genelleştirmek için OpenAI, nesnelere insan benzeri bir şekilde nasıl manipüle edeceğini kendisine öğreten Dactyl adlı bir robot eli oluşturmayı başarmıştır (Sabina Aouf, 2019).

Elbette, güçlü bir teorik temel olmadan bir sinir mimarisi uygulamaya o kadar iyi adapte edilememektedir. Greff vd. (2017:2230) tarafından birkaç LSTM varyantı ve sözde vanilya modeline göre performansları ile ilgili kapsamlı bir inceleme yapılmıştır. Vanilya LSTM, gizli kapı ve gözetleme deliği bağlantılarının eklenmesiyle orijinal LSTM bloğu olarak yorumlanmaktadır. Toplamda, deney için sekiz varyant belirlenmiştir. Özetle, vanilya mimarisi bir dizi görevde iyi bir performans sergilemekte ve araştırılan sekiz varyantın hiçbiri diğerlerinden önemli ölçüde daha iyi performans göstermemektedir. Bu, literatürde bulunan çoğu uygulamanın vanilya LSTM'yi kullanmasını haklı çıkarmıştır.

Yu ve ark. (2019:1240), LSTM hücrelerine, işlevlerine ve farklı mimarilerine genel bir bakış sunmaktadır. LSTM'nin hakim olduğu sinir ağları ile entegre LSTM ağları arasında bir ayırım yapılmaktadır. Bunlardan ikincisi, özelliklerinden yararlanmak için LSTM'den başka bileşenler eklemektedir ve bu nedenle potansiyel olarak sinir ağlarını melezleştirmektedir.

LSTM modeli, minimum zaman gecikmeleri çok uzun olduğunda bile, uzun vadeli bağımlılıkları öğrenirken tipik olarak ortaya çıkan kaybolan gradyan problemlerinin üstesinden gelmek için özel olarak tasarlanmış güçlü bir tekrarlayan sinir sistemidir (Hochreiter ve Schmidhuber 1997:1749).

Kısacası, LSTM mimarisi, bellek blokları olarak bilinen, tekrarlayan bir şekilde bağlanan bir dizi alt ağdan oluşmaktadır. Bellek bloğunun temel çıkış noktası, durumunu zaman

içinde korumak ve doğrusal olmayan geçitleme birimleri olarak düşünülen bilgi akışını düzenlemektir (Gers ve Schmidhuber 2000:3189). Bloğun çıkışı tekrar tekrar blok girişine ve tüm geçitlere bağlanmaktadır.

LSTM modelinin nasıl çalıştığını netleştirmeyi amaçlayarak, N işlem bloğu ve M girişinden oluşan bir ağ varsayılmaktadır. Bu tekrarlayan sinir sistemindeki adımlar aşağıda açıklanmıştır;

**Blok girişi:** Bu adım, son yinelemede mevcut giriş  $x^{(t)}$  ve bu LSTM biriminin  $y^{(t-1)}$  çıkışını birleştiren blok giriş bileşeninin güncellenmesine ayrılmıştır.

**Giriş kapısı:** Bu adımda, son yinelemede mevcut giriş  $x^{(t)}$ , bu LSTM biriminin  $y^{(t-1)}$  ve hücre değeri  $c^{(t-1)}$  değerini birleştiren giriş kapısı güncellenmektedir.

Önceki adımlarda, LSTM katmanı, ağın hücre durumları  $c^{(t)}$ 'de hangi bilgilerin tutulması gerektiğini belirlemektedir. Bu, potansiyel olarak hücre durumlarına eklenebilecek  $z^{(t)}$  aday değerlerinin ve giriş kapılarının aktivasyon değerlerinin  $i^{(t)}$  seçimini içermektedir.

**Saklı Kapı:** Bu adımda, LSTM birimi hangi bilgilerin önceki hücre durumlarından  $c^{(t-1)}$  çıkarılması gerektiğini belirlemektedir. Bu nedenle, t zaman adımındaki saklı kapıların  $f^{(t)}$  aktivasyon değerleri, bellek hücrelerinin mevcut girdisi  $x^{(t)}$  hesaplanmaktadır. Bu hesaplamada önceki (t-1) zaman adımının gözetleme deliği bağlantıları ve saklı kapıların sapma terimleri  $b_f$  yardımıyla  $y^{(t-1)}$  çıktıları ve  $c^{(t-1)}$  hafıza durumu esas alınmaktadır.

**Hücre:** Bu adım, blok girişi  $z^{(t)}$ , giriş kapısı  $i^{(t)}$  ve saklı kapı  $f^{(t)}$  değerlerini önceki hücre değeri ile birleştiren hücre değerini hesaplamaktadır.

**Çıkış kapısı:** Bu adım, son yinelemede mevcut giriş  $x^{(t)}$ , LSTM birimi  $y^{(t-1)}$  ve hücre değeri  $c^{(t-1)}$ 'i birleştiren çıkış kapısını hesaplamaktadır.


**Blok çıkışı:** Son olarak, mevcut hücre değeri  $c^{(t)}$  ile mevcut çıkış kapısı değerini birleştiren blok çıktısını hesaplamaktadır.

### **3.8.1 LSTM modeli**

Burada LSTM ağlarını kullanarak sınıflandırma ve regresyon görevleri için sıra ve zaman serisi verileriyle nasıl çalışılacağını açıklamaktadır. Bir LSTM ağı kullanılarak sıra verilerinin nasıl sınıflandırılacağını gösteren örnekler görülebilir. Bir LSTM ağı, sıra verilerinin zaman adımları arasındaki uzun vadeli bağımlılıkları öğrenebilen bir tür tekrarlayan sinir ağıdır (RNN) (Yu vd., 2019: 1236).

## LSTM Ağ Mimarisi


Bir LSTM ağının temel bileşenleri, bir dizi giriş katmanı ve bir LSTM katmanıdır. Bir dizi giriş katmanı ağ girdiler sekansı ya da zaman serisi verileridir. Bir LSTM katmanı, sıra verilerinin zaman adımları arasındaki uzun vadeli bağımlılıkları öğrenmektedir.



**Şekil 3.10.** Basit LSTM ağ mimarisi.

**Kaynak:** (Yu vd., 2019:1238)

Şekil 3.10, sınıflandırma için basit bir LSTM ağının mimarisini göstermektedir. Ağ, bir dizi giriş katmanı ile başlar ve bunu bir LSTM katmanı izlemektedir. Sınıf etiketlerini tahmin etmek için ağ, tamamen bağlantılı bir katman, bir softmax katmanı ve bir sınıflandırma çıktı katmanı ile sona ermektedir (Yu vd., 2019:1238). Şekil 3.10'da regresyon için basit bir LSTM ağının mimarisi gösterilmektedir.



**Şekil 3.11.** Regresyon için basit bir LSTM ağının mimarisi

**Kaynak :** (Yu vd., 2019:1238).

Ağ, bir dizi giriş katmanı ve ardından bir LSTM katmanı ile başlamaktadır. Ağ, tamamen bağlantılı bir katman ve bir regresyon çıktı katmanı ile sona ermektedir.

LSTM Ağlarında Sınıflandırma: Sıradan etikete sınıflandırmanın yapılması için bir LSTM ağı oluşturulması gerekmektedir. LSTM ağı oluşturmak için, bir dizi giriş katmanı, bir LSTM katmanı, tam olarak bağlı bir katman, bir softmax katmanı ve bir sınıflandırma çıktı katmanı içeren bir katman dizisi oluşturulmaktadır (Yu vd., 2019:1240).

Sıralı giriş katmanının boyutunu, giriş verilerinin özelliklerinin sayısına ayarlanması zorunludur. Tamamen bağlı katmanın boyutunu sınıf sayısına ayarlamak gereklidir. Sıra uzunluğunu belirlemeye gerek bulunmamaktadır.

Regresyon LSTM Ağları: Regresyon gerçekleştirmek adına bir LSTM ağı oluşturmak için, bir dizi giriş katmanı, bir LSTM katmanı, tamamen bağlı bir katman ve bir regresyon çıktı katmanı içeren bir katman dizisi oluşturulmalıdır.

Sıralı giriş katmanının boyutunu, giriş verilerinin özelliklerinin sayısına ayarlamak

büyük önem arz etmektedir. Tamamen bağlı katmanın boyutunu yanıt sayısına ayarlamak gerekmektedir. Sıra uzunluğunu belirlemeye gerek bulunmamaktadır. Sıradan sıraya regresyon için bir LSTM ağı oluşturmak amacıyla, sıradan bir regresyon ile aynı mimariyi kullanmak, ancak LSTM katmanının çıktı modunu ayarlamak gereklidir. Tablo 3.1’de LSTM mimarisinde yer alan katmanların tümü hem simgeleri, hem de açıklamaları ile yer almaktadır.

**LSTM Katman Mimarisi:** Bu diyagram, bir LSTM katmanı boyunca  $S$  uzunluğunda  $C$  özelliklerine (kanallar) sahip bir  $X$  zaman serisinin akışını gösterir. Diyagramda,  $\mathbf{h}_t$  ve  $\mathbf{c}_t$  sırasıyla adım  $t$  zamanındaki çıktı (gizli durum olarak da bilinir) ve hücre durumunu belirtir .


İlk LSTM bloğu, ilk çıktıyı ve güncellenmiş hücre durumunu hesaplamak için ağı başlangıç durumunu ve dizinin ilk zaman adımını kullanır.  $T$  zaman adımında, blok ağı mevcut durumunu kullanır ( $\mathbf{c}_{t-1}, \mathbf{h}_{t-1}$ ). Çıktıyı ve güncellenmiş hücre durumunu hesaplamak için dizinin bir sonraki adımını  $c_t$  kullanır.

Katmanın durumu, gizli durumdan ve hücre durumundan oluşur.  $T$  zaman adımındaki kayıp kapı, bu zaman adımı için LSTM katmanının çıktısını içermektedir. Hücre durumu, önceki zaman adımlarından öğrenilen bilgileri barındırmaktadır. Her adımda katman, hücre durumuna bilgi ekler veya bilgileri hücre durumundan çıkarmaktadır. Katman, bu güncellemeleri geçitleri kullanarak kontrol etmektedir. Tablo 3.1.’de yer alan bileşenler, katmanın hücre durumunu ve gizli durumunu kontrol eder.

**Tablo 3.1.** Katman bileşenleri

Bileşen	Amaç
Giriş kapısı ( $i$ )	Hücre durumu güncellemesinin kontrol seviyesi
Kayıp kapı ( $f$ )	Hücre durumu sıfırlamanın kontrol seviyesi (kayıp)
Hücre aday ( $g$ )	Hücre durumuna bilgi eklemek
Çıkış kapısı ( $o$ )	Gizli duruma eklenen hücre durumunun kontrol seviyesi

Şekil 3.11,  $t$  zaman adımındaki veri akışını göstermektedir. Şema, kapıların hücreyi ve gizli durumları nasıl unuttuğunu, güncellediğini ve çıktı verdiğini vurgular.



Şekil 3.12. t zaman adımındaki veri akışı.

**Kaynak:** (Yu vd., 2019:1241)

Bir LSTM katmanının öğrenilebilir ağırlıkları, girdi ağırlıkları  $W$  (Input Weights), tekrarlayan ağırlıklar  $R$  (RecurrentWeights) ve tarafl  $b$  (Bias) 'dir.  $W$ ,  $R$  ve  $b$  matrisleri, sırasıyla girdi ağırlıklarının, yinelenen ağırlıkların ve her bir bileşenin önyargısının birleşimidir.

Bu hesaplamalarda,  $\sigma_g$  geçit aktivasyon fonksiyonunu gösterir. Lstm Layer Fonksiyon varsayılan olarak verdiği sigmoid fonksiyonunu kullanır.  $\sigma(x) = (1 + e^{-x})^{-1}$  kapı aktivasyon fonksiyonunu hesaplamak için kullanılmaktadır (Yu vd., 2019:1241).

### 3.8.2. İlgili uygulamalar

LSTM ağı, hem bireysel olarak hem de diğer derin öğrenme mimarileriyle birlikte çok çeşitli problem alanlarında uygulanmaktadır. Daha önce tartışıldığı gibi, LSTM, zamansal dizileri işlemek için en gelişmiş ağlardan biridir. Bu nedenle, vanilya LSTM, hibrit modeller oluşturmak için diğer ağlarla birleştirmek mümkün olsa da, hala en popüler ağ seçeneklerinden biridir. LSTM, zaman serisi tahminlerini ve aynı zamanda geçici bellek gerektiren diğer problemleri ele almak için çok uygundur.

### 3.8.3. Zaman serisi tahmini

Verilerdeki zamansal diziler söz konusu olduğunda, zaman serisi verileri hemen akla gelir. Zaman serisi tahminlerinde, LSTM modeli, örneğin Fischer ve Krauss (2018:660) ve Yan ve Ouyang (2017:5)'de finansal piyasa tahminlerine uygulanmıştır. Doğrusal olmama, durağan olmama ve sıra korelasyonu gibi karmaşık özellikler nedeniyle, finansal veriler büyük bir tahmin zorluğu oluşturmuştur. Bununla birlikte, Fischer ve Krauss tarafından, LSTM ağının daha geleneksel kıyaslamalardan daha iyi performans gösterdiği ifade edilmiştir.

Sagheer ve Kotb (2019:208), LSTM'nin petrol üretimini tahmin ederken standart yaklaşımlardan daha iyi performans gösterdiğini doğrulamıştır. Araştırmalarında, LSTM bloklarının birden çok katmanını hiyerarşik bir şekilde birbirinin üzerine inşa etmiştir. Bu,

modelin zamansal görevleri işleme yeteneğini artırmış ve veri dizilerinin yapısını daha iyi yakalamasını sağlamıştır. Petrol piyasası fiyatını tahmin etmeye çalışan Cen ve Wang (2019:165)'da aynı sonuçlara ulaşılmıştır. Vanilya LSTM mimarisinden oluşan tahmin modelinin üstün olduğu kanıtlanmıştır. Liu (2019:103), LSTM'yi destek vektör makineleri gibi diğer modellerle karşılaştırmıştır. Finansal hisse değişimini tahmin etmeye yönelik bu araştırma, yalnızca LSTM'yi kalibre etmenin nispeten kolay olduğunu göstermekle kalmamış, aynı zamanda büyük zaman aralıkları için bile doğru tahminlerle sonuçlandığını göstermiştir.

#### **3.8.4. Doğal dil işleme**

LSTM, hem bağlamdan bağımsız hem de içeriğe duyarlı dil öğrenimi söz konusu olduğunda hesaba katılması gereken bir yöntemdir (Gers vd., 2002:659). Doğal dil işleme, bilgisayarların yararlı şeyler yapmak için doğal dildeki metni veya konuşmayı anlamak, işlemek için nasıl kullanılabileceğini araştıran bir alandır. Örneğin, konuşma araçları olarak da bilinen diyalog sistemleri, insanların konuşma yoluyla bir makineyle etkileşime girmesine izin verir. LSTM modelinin kullanımıyla konuşma tanıma, ilk olarak Graves vd. (2004:9) tarafından gerçekleştirilmiştir.

Diyalog sistemleri, rastgele bir yanıt vermek yerine, alan dışı konuşma girdisine yanıt verebilmelidir. Ryu vd. (2017:3), iki LSTM katmanı kullanılarak bir ikili sınıflandırıcı oluşturulmuştur. Sınıflandırıcı, daha sonra alan dışı cümleleri tanımak amacıyla yalnızca alan içi verilerle eğitilmiştir.

#### **3.8.5. Bilgisayarlı görme**

LSTM ayrıca hareket ve eylem tanıma için de kullanılabilir. Bu alan, insan pozlarını ve etkileşimlerini tanımlamayı içermektedir. Bilakhia vd. (2015:52), taklit davranışının sosyal yargıları ve davranışları etkileme gücüne sahip olduğu için, taklit davranışının otomatik olarak tanınmasını araştırdılar. Taklit davranışı burada yüz ve baş hareketleri olarak tanımlanır. Taklit değişikliklerinin video kayıtları ağa beslenir ve diğer yöntemlerle, yani çapraz korelasyon ve genelleştirilmiş zaman atlama ile karşılaştırılmaktadır. LSTM, modelin mekansal-zamansal dönüşümleri işleme özelliğinden dolayı olağanüstü bir performans kaydedilmiştir. Bu deneylerde performansta önemli bir farklılık tespit edilmiştir, bu da iyileştirme için hala yer olduğunu göstermektedir.

### 3.9. Matlab Çerçevesi

Ağları derin öğrenme için eğitirken, genellikle eğitimin ilerlemesini izlemek yararlıdır. Eğitim sırasında çeşitli ölçümleri çizerek, eğitimin nasıl ilerlediğini öğrenilebilmektedir. Örneğin, eğitim ağının doğruluğunun artıp artmadığını ve ağın eğitim sürecine göre eğitim verilerini aşip aşmadığı görülebilmektedir. Eğitim seçeneklerinde 'Planlar' değeri olarak 'eğitim-ilerleme'yi belirtmeyi seçerken ve ağ eğitimini başlatırken, eğitim ağı, eğitimin her yinelemesi için parametrelerdeki değişiklikleri göstermek için bir grafik çizilmesi, modelde her yineleme, gradyanları ve ağırlıkları güncellemek içindir. Regresyon ağlarında Matlab, kök ortalama kare hatasını (RMSE) çizmektedir, ancak doğruluğu göstermez (BilstmLayer n.d.; LstmLayer n.d.). Verileri eğitmek için Momentumlu Stokastik Gradyan İnişini (SGDM) seçilmiştir.

Gradyan inişi, bir fonksiyonun minimum değerini bulmak için kullanılan birinci dereceden yinelemeli bir optimizasyon algoritmasıdır. Fonksiyonun yerel minimumunun bulunabilmesini sağlamak için, mevcut fonksiyon gradyanının karşısındaki adım boyutunu hesaplanması gerekmektedir. Eğitim süreci için seçenekler aşağıda listelenmiştir (Matlab Programı Resmi Sitesi Yardım Merkezi, 2021).

İlk öğrenme oranı, eğitim için kullanılan ilk öğrenme oranıdır. Bu parametre, eğitim sürecini etkileyen ağır bir ağırlığa sahiptir. Çok düşük bir değer seçersek, eğitim uzun zaman almaktadır. Seçim çok yüksekse, eğitim yetersiz bir sonuca ulaşabilmekte veya farklılaşabilmektedir. Öğrenme oranının çoğu 0.1-0.001 arasındadır. Aralarındaki değeri seçip ve eğitim sürecinde en düşük kayıp işlevini alabilecek en iyi değeri bulmaya çalışılmaktadır. Eğitim süreci sonuçları, varsayılan olarak eğitim ağında bu ilk öğrenme oranını tüm eğitim süreci boyunca kullanmaktadır. Öğrenme oranını bir faktörle çarparak her belirtilen dönem sayısında öğrenme oranı değiştirilmiştir. Eğitim süreci boyunca düşük, sabit bir öğrenme oranı kullanmak yerine, eğitimin başında daha önemli bir öğrenme oranı seçilmiş ve optimizasyon sırasında bu değeri kademeli olarak azaltılmıştır. Bunu yapmak eğitim süresini kısaltabilirken, eğitim ilerledikçe minimum kayba doğru daha küçük adımlar atılmasını sağlayabilmektedir.

Eğitim sürecindeki diğer seçenekler sabit olarak ayarlanmaktadır:

Maxepoches: 250, Gradyan eşiği: 1, Initial Learn Rate: 0.005, Learn Rate Schedule: piecewise, Learn Rate Drop Period: 125, Learn Rate Drop Factor: 0,2 Verbose: 0 elde edilir. En düşük RMSE ve kaybı elde etmek için, en iyi eğitim parametresini bulmak ve ilk öğrenme oranını değiştirilebilmek önem arz etmektedir.

## 4.UYGULAMA

Bu uygulamada, elektrik yük tahmini için YSA ve LSTM yöntemleri kullanılarak hangi yöntemin bu veriler özelinde tahmin performansının daha iyi sonuç verdiğini gözlemlemek amaçlanmaktadır.

### 4.1. Günlük Yük Tüketimi Verileri

Bu tez çalışmasında 1 Ocak 2017-31 Aralık 2019 tarihleri arası saatlik geçmiş yük tüketim verileri kullanılmıştır. Tüm Türkiye'deki elektrik enerjisi tüketim tesislerindeki gerçek zamanlı tüketim miktarı raporu günlük yük tüketim tahmininde ele alınmıştır. Kullanılan veriler ön işleme proseslerinden sonra kullanıma hazır hale getirilmiştir. EİPAŞ (Türkiye Elektrik İletim A.Ş.) şeffaflık internet sitesinden (URL-2) veriler elde edilmiştir. İki yıllık verinin kullanılmasının sebebi, önerilen model için veri setinin artırılarak yaklaşımın hata performansının minimize edilmesidir.

Çalışmada öncelikle verilerin bozucu etkisini ortadan kaldırmak amacı ile veri ön işleme yapılmıştır. Bu ön işlemler, verilerin normalize edilmesi, virgüllerin noktaya dönüştürülmesi, veri günlerinin koda uygun hale getirilmesidir. İkincil olarak, geçmiş yük verilerinden bir veri kümesi oluşturulmuştur. Tahmin çalışması için oluşturulan yapılar bu veri kümesi ile simüle edilmiş ve ortalama günlük MAE, maksimum günlük MAPE ve günlük RMSE değerleri olarak hesaplanmıştır. Tahmin hata yüzdelerini düşürebilmek adına yük tahmininde normalizasyon işlemi önerilmiş ve normalizeli yük tahmini yüzdeleri de MAPE olarak hesaplanmıştır. Ortalama günlük MAE, maksimum günlük MAPE ve Günlük RMSE değerleri tüm yapılar için normalizeli olarak karşılaştırılmıştır. Tüm bu adımlar aşağıda ayrıntıları ile açıklanmaktadır.

### 4.2. Veri Ön İşleme

Veri ön işleme için veriler öncelikle normalize edilmektedir. Normalize edilmiş verilerin çalışma kapsamında kullanılması daha iyi sonuçların elde edilmesi için gereklidir.

$$\frac{data_{ij} - \min(data_{ij})}{\max(data_{ij}) - \min(data_{ij})} \quad i=1, \dots, 24 \text{ ve } j=1, \dots, n \text{ için} \quad (4.1)$$

Burada;

*i*: bir gündeki 24 saatin her birini ifade eder

*j*: tüm günlerin her birini ifade eder

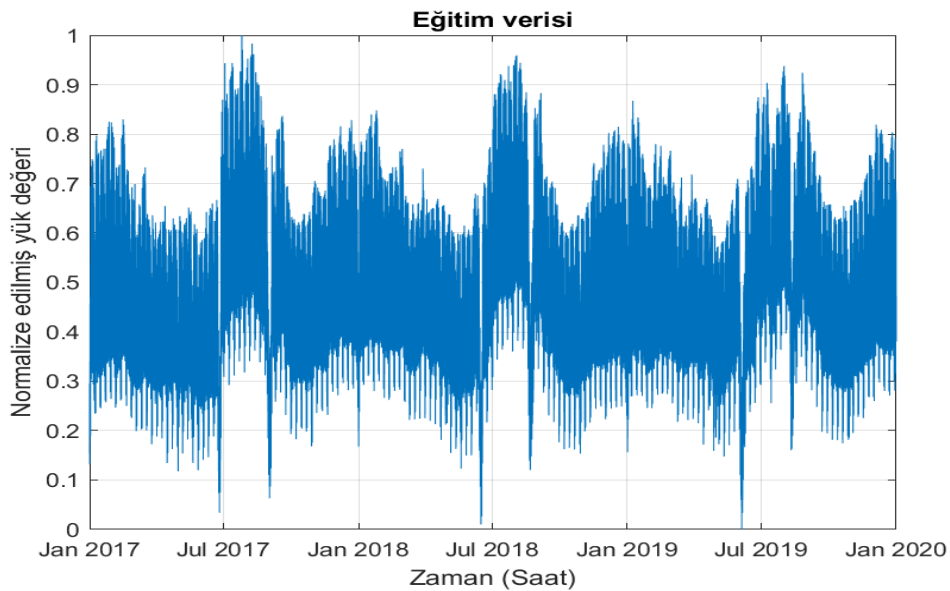
*data<sub>i</sub>*: *i*. saatteki veri

değerlerini ifade etmektedirler.

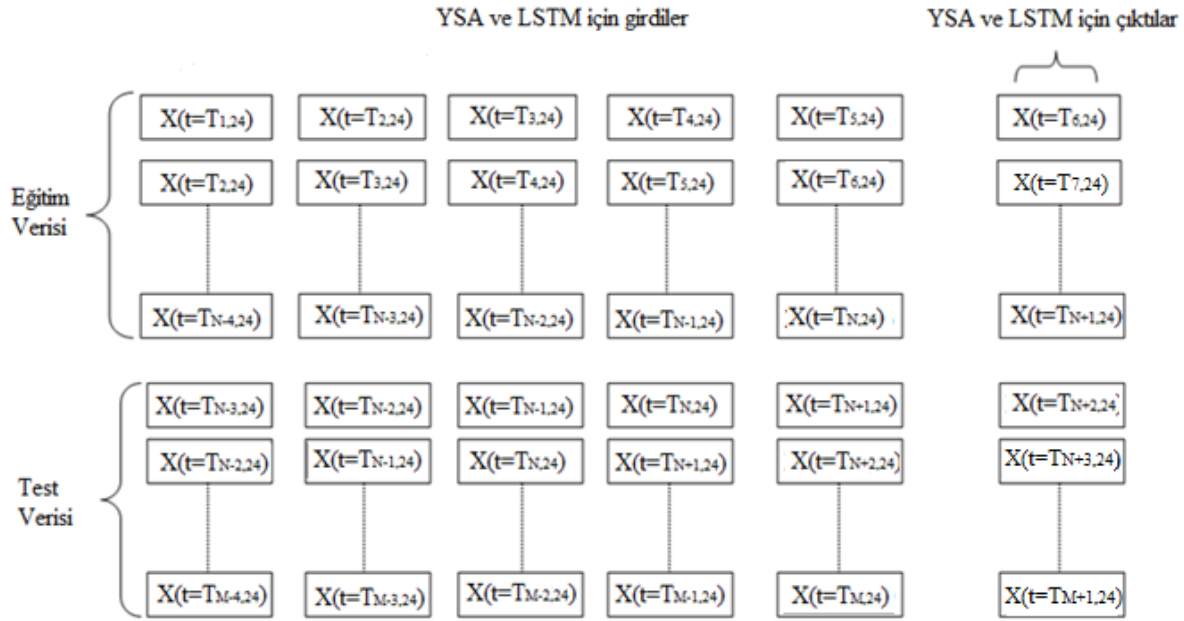
Ardından veriler 120 (5 gün) ve 144 (6 gün) saatlik girdi olarak yeni bir değişkene atanmıştır. 24 (1 gün) saatlik çıktı olarak ise yeni bir değişkene atanmıştır. Toplamda 2 yıllık veri kullanılmıştır. Son olarak verilerin %90'lık kısmı eğitim, %10'luk kısmı ise test için ayrılmıştır. Veri önışlemelerinden sonra test için kullanılacak olan %90'lık kısmın günlük verisinin son hali aşağıdaki Şekil 5.1'de gösterilmektedir. Grafikte tüm eğitim verileri bulunmaktadır.

Şekil 4.2 ve 4.3'de kayan pencere yaklaşımı girdi ve çıktı olarak hem eğitim verisi hem de test verisi için görselleştirilmiştir. Model 1 için kayan pencere yaklaşımında girdiler (Şekil 4.2'deki her bir kutucuk bir günü ifade edecek şekilde) 5 günlük olarak uygulanmıştır. Aynı yaklaşım Model 2 için de uygulanmıştır. Model 2 için girdiler (Şekil 4.3'teki her bir kutucuk bir günü ifade edecek şekilde) 6 günlük olarak alınmıştır.


Şekil 4.2'deki her bir kutucuk bir günü ifade ederken, 24 tane veri kullanılmaktadır. Diğer bir ifadeyle, bir günü ifade eden bir tane veri değil 24 tane veri bulunmaktadır. T değerlerinin ilk indisleri günü, ikinci indis ise her gün bulunan 24 saati ifade etmektedir. Görüldüğü üzere her bir penceredeki günler ve her günün 24 saatlik verileri temel alınmıştır. Örnek verilecek olursa  $X(t=T_{5,24})$  penceresinde 5. gündeki 24 tane olan 24 saatlik veriler kullanılmıştır. Aynı şekilde diğer tüm pencerelerde o günkü 24 saatlik 24 veri temel alınmıştır.



**Şekil 4.1.** Tahminde kullanılan tüm eğitim verisi



Şekil 4.2. Kayan pencere yaklaşımının Model 1 için gösterimi.

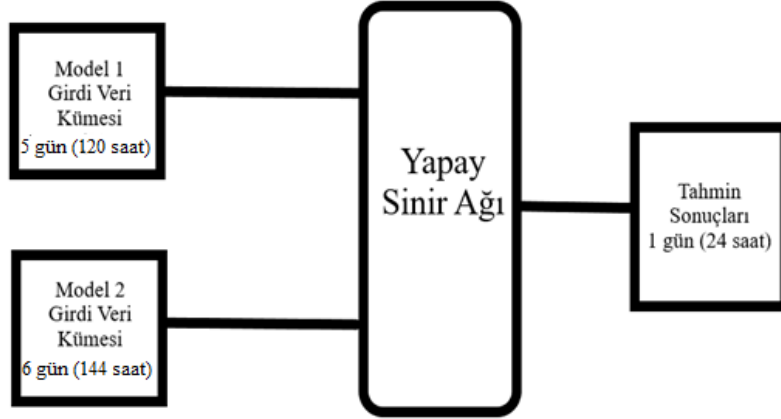


Şekil 4.3 Kayan pencere yaklaşımının Model 2 için gösterimi.

### 4.3. Yük Tahmininde YSA Modeli

Uygulama için tek gizli katmanlı, bir ileri beslemeli-geri yayımlı sinir ağı kullanılmıştır. Oluşturulan YSA yapısı ile Şekil 4.1’de belirtilen eğitim veri kümesi kullanılarak eğitim gerçekleştirilmiş ve giriş olarak verilen 120 ve 144 saatlik yük verisine göre tahmin gününe dair 24 saatlik tahmin sonuçları elde edilmiştir. Kayan pencere

yapısı Tablo 4.1’de gösterilmiştir. YSA yapısı blok diyagramı Şekil 4.2’de verilmiştir.



Şekil 4.4 YSA yapısı blok diyagramı.

Tablo 4.1. Modeller için kayan pencere tanımları.

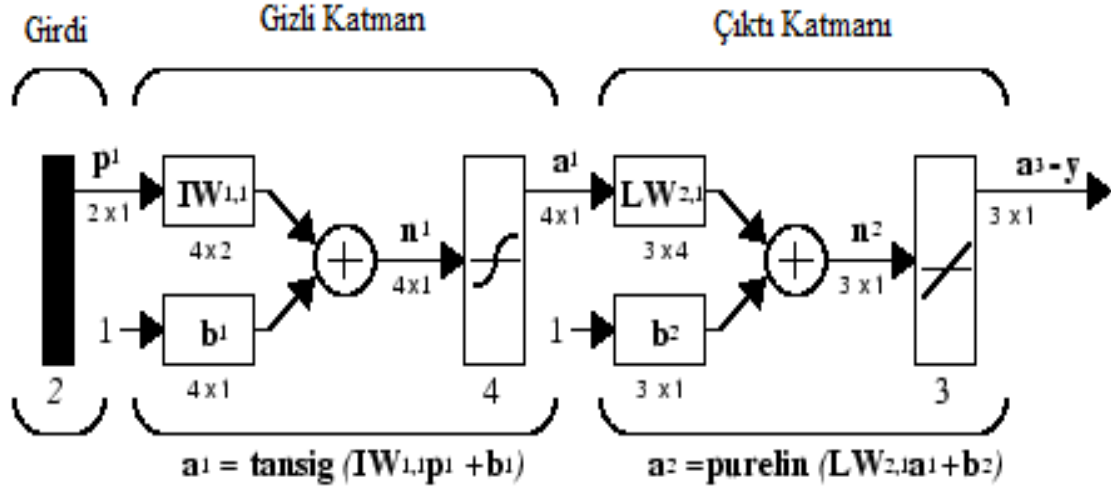
Modeller	Girdiler	Çıktı
MODEL <sub>1</sub>	$x(t), x(t-1), x(t-2), x(t-3), x(t-4)$	$x(t+1)$
MODEL <sub>2</sub>	$x(t), x(t-1), x(t-2), x(t-3), x(t-4), x(t-5)$	$x(t+1)$

Giriş ve çıkış katmanlarındaki nöron sayısı sırasıyla giriş ve çıkış sayısına eşittir. Gizli katman nöron sayısı deneme yanılma ile 250 olarak seçilmiştir. Sinir ağı “Levenberg-Marquardt” eğitim fonksiyonu ile eğitilmiştir. Gizli katman transfer aktivasyon fonksiyonu “tansig” ve çıkış katmanı transfer aktivasyon fonksiyonu “purelin” olarak kullanılmıştır. Şekil 4.3’te gizli katman transfer aktivasyon fonksiyonu “tansig” ve çıkış katmanı transfer aktivasyon fonksiyonu “purelin” gösterilmiştir.

Levenberg-Marquardt algoritmasını (LMA), sönümlü en küçük kareler yöntemine çözmek için kullanılan en küçük kareler doğrusal olmayan bir problemdir. Bu minimizasyon sorunları özellikle en küçük kareler eğri uydurmada ortaya çıkmaktadır.

LMA, genel eğri uydurma problemlerini çözmek için birçok yazılım uygulamasında kullanılır. Bununla birlikte, birçok uyum algoritmasında olduğu gibi, LMA yalnızca yerel bir minimum bulmakta ve bu global minimum değildir. LMA, Gauss – Newton algoritması (GNA) ve gradyan iniş yöntemi arasında interpolasyon yapmaktadır. LMA, GNA’dan daha çeviktir. Bu da çoğu durumda son minimumdan çok uzakta başlasa bile bir çözüm bulduğu anlamına

gelmektedir. İyi davranan fonksiyonlar ve mümkün başlangıç parametreleri için, LMA, GNA'dan biraz daha yavaş olma eğilimindedir.



Şekil 4.5. Tansig ve purelin aktivasyon fonksiyonları.

Tahmin hataları MAPE olarak hesaplanmıştır. Oluşturulan her bir yapı için ortalama günlük MAPE ve günlük maksimum MAPE hesaplanmış ve karşılaştırılmıştır. Günlük MAPE ve ortalama günlük MAPE sırasıyla Eşitlik 4.2 ve Eşitlik 4.3'te gösterildiği gibi hesaplanmıştır:

$$\text{Günlük MAPE} = \frac{1}{24} * 100 \sum_{s=1}^{24} \left| \frac{(\text{tahmin})_s - (\text{gerçek})_s}{(\text{gerçek})_s} \right| \quad (4.2)$$

$$\text{Ortalama Günlük MAPE} = \frac{1}{G} * \sum_{i=1}^G (\text{Günlük MAPE}) \quad (4.3)$$

Eşitlik 4.3'teki  $G$  terimi normal gün sayısını ifade etmektedir. Veriler YSA yapıları ile Matlab programlama dili kullanılarak elde edilmiş normalizeli tahmin sonuçları Model 1 ve Model 2 için sırasıyla Şekil 4.3-4.4'te yer almaktadır.

#### 4.4. Yük Tahmininde LSTM Modeli

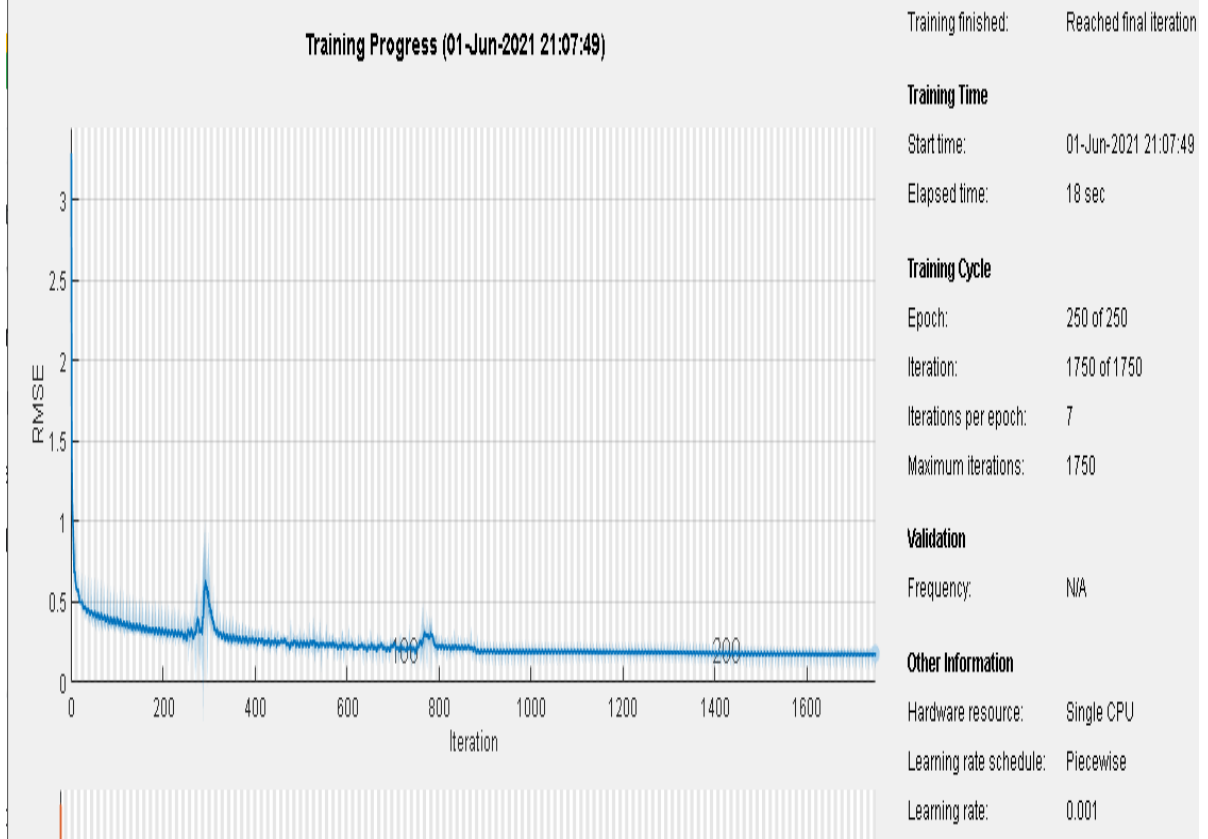
LSTM (Kısa Dönem Yük Tahmini için Yapay Zeka Modelleri) olarak adlandırılmış olan arayüz, kullanıcıya veri kümesi dahilinde istediği güne ait yük tüketimlerini oluşturulan yapılardan istediği ile tahmin edebilme olanağı tanımaktadır.

Çalışmada kullanılan 1 Ocak 2017-31 Aralık 2019 tarihleri arası saatlik geçmiş yük tüketim verileri arayüze yüklenmiştir. Bu verileri kullanarak yapılan çalışma, temel olarak arayüzde tasarlanan üç katmanla hesaplanmıştır. Kayan pencere olarak 120 saatlik ve 144 saatlik iki farklı model kullanılmıştır.

#### 4.4.1 Bulgular


Çalışmada kullanılan geçmiş yük verileri MATLAB arayüzüne yüklenmiştir. Bu veriler arasından tahmini yapılmak istenen gün ve uygulanmak istenen yapı YSA-LSTM’de seçilmiş ve tahmin sonuçları elde edilmiştir. Arayüzde, normalizesiz tahmin sonuçları için tahmin-gerçek yük eğrileri MAPE değerleri ile gösterilmiştir.

Aşağıda ilk öğrenme oranı 0.001 değeri seçilen eğitim aşaması gösterilmektedir.




Şekil 4.6. Veri eğitiminin ve öğrenmesinin görseli.

Veriler kullanılarak LSTM yapıları ile arayüzden elde edilmiş normalizeli tahmin sonuçları Model 1 ve Model 2 için sırasıyla Şekil 4.7 ve Şekil 4.8’te yer almaktadır.



Şekil 4.7. YSA ve LSTM için saatlik normalze edilmiş gerçek ve tahmin eğrileri (Model 1)



**Őekil 4.8.** YSA ve LSTM iin saatlik normalize edilmiř gerek ve tahmin eęrileri

(Model 2)

Tablo 5.2’de saatlik gerçek yük verilerinin ve oluşturulan yapılardan elde edilen saatlik tahmin sonuçlarının YSA ve LSTM’ye ait koyu yazılmış ortalama günlük MAE, Maksimum günlük MAPE ve Günlük RMSE değerleri ile verilmiştir. En düşük ortalama günlük hata, Maksimum günlük MAPE ve Günlük RMSE değerleri LSTM yapısından elde edilmiş ve tabloda altı çizili olarak belirtilmiştir.

**Tablo 4.2.** Hata değerlerinin YSA ve LSTM için karşılaştırması

	Ortalama günlük MAE		Maksimum günlük MAPE		Günlük RMSE	
	YSA	LSTM	YSA	LSTM	YSA	LSTM
Model 1	130,2456818	<u>94,299263</u>	%0,8879876	<u>%0,60411375</u>	151,41444	<u>114,31020</u>
Model 2	151,1554108	<u>79,728218</u>	%1,4018630	<u>%0,55998331</u>	193,96224	<u>95,033226</u>

Tablo 4.2’de saatlik gerçek yük verilerinin ve oluşturulan yapılardan elde edilen saatlik tahmin sonuçlarının YSA ve LSTM’ye ait koyu yazılmış ortalama günlük MAE değerleri ile verilmiştir. Model 1 ve 2 için en düşük maksimum günlük hata değeri LSTM yapısından elde edilmiş ve tabloda altı çizili olarak belirtilmiştir. Model 1’de 120 saatlik veri 24 saatlik tahmin için kullanılmıştır. Model 2’de ise 144 saatlik veri 24 saatlik tahmin için kullanılmıştır. Görüldüğü üzere LSTM için Model 2’nin hata değeri Model 1’den daha düşüktür.

Maksimum günlük MAPE değerlerine bakıldığında, her iki tahmin çalışmasında da en düşük hata yüzdesini yine LSTM vermiştir.

Tablo 4.2’de saatlik gerçek yük verilerinin ve oluşturulan yapılardan elde edilen saatlik tahmin sonuçlarının YSA ve LSTM’ye ait koyu yazılmış ortalama günlük RMSE değerleri ile verilmiştir. En düşük değer LSTM yapısından elde edilmiş ve tabloda altı çizili olarak belirtilmiştir. Görüldüğü üzere LSTM ve YSA için Model 2’nin hata değeri Model 1’den daha düşüktür. 144 saatlik veri ile tahmin yapmak 120 saatlik veri ile tahmin yapmaktan daha iyi performans göstermektedir.

RMSE değerine göre en düşük ortalama günlük değer LSTM yapısından elde edilmiş ve Tablo 4.2’de sunulmuştur.

## 5. SONUÇLAR

Bu tez çalışmasında, tüm Türkiye'deki elektrik tüketim tesisleri için tatil günleri (Cumartesi ve Pazar) hariç, 24 saatlik günlük yük tahmini amaçlanmış, sıcaklık ya da başka bir hava verisi kullanılmadan kabul edilebilir hata yüzdelerinde gerçekleştirilebilen bir tahmin sistemi önerilmiştir.

Önerilen tahmin sistemi, YSA ve LSTM olmak üzere iki yapıdan oluşmaktadır. Nöronların başlangıç ağırlıkları rastgele verildiğinden, YSA yapısının her simülasyon sonucunda farklı sonuçlar vermektedir. Bu sebeple birden fazla iterasyon adımı gerçekleştirilmiştir. En düşük ortalama günlük MAPE değerlerini, LSTM yapısı vermiştir. Tüm hata performans metriklerinin sonuçlarına göre LSTM modelinin klasik YSA modeline göre daha iyi sonuç verdiği gözlemlenmiştir. Ayrıca, hata yüzdelerine bakıldığında, YSA yapısının da kayda değer bir başarı gösterdiği görülmüştür.

Normalizeli yük tahmini çalışmasında, en düşük ortalama günlük hata yüzdelerini LSTM yapısı vermiştir. Ortalama günlük hata yüzdeleri, diğer yük hata yüzdelerinden daha düşük çıkmıştır. Görüldüğü üzere bazı hata değerlerine göre LSTM ve YSA için Model 2'nin hata değeri Model 1'den daha düşüktür. 144 saatlik veri ile tahmin yapmak 120 saatlik veri ile tahmin yapmaktan daha iyi performans göstermiştir.

## KAYNAKLAR

- Abu-Shikhah, N., Elkarmi, F., Aloquili, O.** (2011). Medium-Term Electric Load Forecasting Using Multivariable Linear and Non-Linear Regression. *Smart Grid and Renewable Energy*. 2.
- Akar, H. A.** (2005). Dağıtım Sisteminin Özelleştirilmesi ve Yapay Sinir Ağları ile Yük Tahmini, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Aksel, F.** (2000). Regresyon Analizi ve Yapay Sinir Ağı Yöntemleri ile Uzun Dönem Yük Tahmini, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- Alfares, H., and Mohammad, N.** (2002). Electric load forecasting: Literature survey and classification of methods. *International Journal of Systems Science* (January 2014).
- Alpaydm, E.** (2010). *Introduction to Machine Learning Second Edition* (2nd, Ed.). London: The MIT Press, pp.17-38.
- Alam, S.** (2018). Recurrent neural networks in electricity load forecasting.
- Amin S. M. and Wollenberg, B. F.** "Toward a smart grid: Power delivery for the 21st century," *IEEE power and energy magazine*, vol. 3, no. 5, pp. 34–41, 2005.
- Anderson, D., and Mcneill, G.** (1992). *Artificial Neural Network Technology, A DACS State-of-the-Art Report*.
- Austria. S.** (2016). Was sind Smart Grids? [Online]. Available: <https://www.smartgrids.at/smart-grids.html> (visited on 08/21/2018).
- Biçer, A.** (2018). Enerji Talep Tahminine Yönelik Program Geliştirme Ve Bir Bölge İçin Uygulaması, (Yüksek Lisans Tezi), Afyon Kocatepe Fen Bilimleri Enstitüsü, İstanbul.
- Bilakhia S, Petridis S, Nijholt A, Pantic M** (2015) The MAHNOB mimicry database: a database of naturalistic human interactions. *Pattern Recognition in Human Computer Interaction*, pp. 66:52–61.
- BilstmLayer.** (n.d.). <https://www.mathworks.com/help/deeplearning/ug/long-short-term-memorynetworks.html>
- Bishop, C. M.** (1995). *Neural Networks for Pattern Recognition*. Clarendon Press.
- Bouktif S., Fiaz A., Ouni A., Serhani M.A.** (2018). Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches. *Energies* (MDPI) 11:1–20.

- Box, G.E.; Jenkins, G.M.; Reinsel, G.C.** (2011). Time Series Analysis: Forecasting and Control; John Wiley & Sons: Hoboken, NJ, USA, Volume 734.
- Brownlee, J.** (2017). Gentle Introduction to the Adam Optimization Algorithm for Deep Learning, [Online]. Available: <https://machinelearningmastery.com/adam-optimizationalgorithm-for-deep-learning/> (visited on 07/16/2020)
- Butekin, T. Ç.** (2019). Ann based electricity consumption forecasting in Yasar University, Yayınlanmamış Yüksek Lisans Tezi. İzmir: Yaşar Üniversitesi.
- Cen Z, Wang J** (2019) Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. Energy 169:160–171.
- Ceylan, G.** (2004). Yapay Sinir Ağları İle Kısa Dönem Yük Tahmini, (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Charytoniuk, W. Chen, M. S.** (2000). Very Short-Term Load Forecasting Using Artificial Neural Networks, IEEE Transactions on Power Systems, Vol. 15, No.1, pp.263-268.
- Chollet, F.** Deep learning with python. Manning Publications Co., 2017.
- Curtis F. E. and Scheinberg, K.** “Optimization methods for supervised machine learning: From linear models to deep learning,” in Leading Developments from INFORMS Communities, INFORMS, 2017, pp. 89–114.
- Çevik, H.H.** (2013). Türkiye'nin Kısa Dönem Elektrik Yük Tahmini, Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya.
- Çilliyüz, Y.** (2006). Yapay sinir ağları ile çevre koşulları etkili bölgesel yük tahmini, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 10-11
- Demirel, Ö.** (2009). “ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini”, Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Ding, Q.** (2006). "Long-Term Load Forecast Using Decision Tree Method," Power Systems Conference and Exposition, PSCE 06, IEEE PES, Vol.1, pp.1541-1543.
- Dong, Y., Ma, X., Fu, T.** (2020). Electrical load forecasting: A deep learning approach based on K-nearest neighbors. Applied Soft Computing, (), 1–20.
- E. Commission.** (2017). Smart grids and meters, [Online]. Available: <https://ec.europa.eu/energy/en/topics/markets-and-consumers/smart-grids-and-meters> (visited on 05/30/2018)

- Eljazzar, M. M., and Hemayed, E. E.** (2017). Feature selection and optimization of artificial neural network for short term load forecasting. 2016 1th International Middle East Power Systems Conference, MEPCON 2016 -Proceedings,827–831.
- ENTSO-E and Eurelectric.** (2011). Deterministic frequency deviations: root causes and proposals for potential solutions. Technical Report December, 2011.
- ENTSO-E. ENTSO-E.** (2014). Network Code on Electricity Balancing. Technical report, 2014.
- Enerji Piyasaları İşletme A.Ş (EPIAŞ)**(2021) *.Elektrik Tüketim Verileri* [Erişim: 15.03.2021, <https://seffaflik.epias.com.tr/> ].
- EPDK,** (2009). Elektrik Piyasası Dengeleme ve Uzlaştırma Yönetmeliği, Ankara
- Esener, İ.I.** (2012). Akıllı Sistemler Kullanılarak Güç Sistemlerinde Yük Tahmini Analizi Ve Uygulaması, (Yüksek Lisans Tezi), Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü, Bilecik.
- Evren, V.** (2021). Yapay Zekâ Yöntemleri İle Kısa Dönemli Yük Tahmini, (Yüksek Lisans Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Fan, Z. Kulkarni, P. Gormus, S. Efthymiou, C. Kalogridis, G. Sooriyabandara, M. Zhu, Z. Lambotharan, S. and Chin, W. H.** “Smart grid communications: Overview of research challenges, solutions, and standardization activities,” IEEE Communications Surveys & Tutorials, vol. 15, no. 1, pp. 21–38, 2013.
- Fallah, S. N. Ganjkhani, M. Shamsirband S. and Chau, K.-W.** (2019). "Computational intelligence on short-term load forecasting: A methodological overview", Energies. 12(3):393.
- Feinberg, E.A.; Genethliou, D.** Load Forecasting; Springer: New York, NY, USA, 2005.
- Fernandes, K. C. Sardinha, R. Rebelo S. and Singh, R.** (2019). "Electric Load Analysis and Forecasting Using Artificial Neural Networks," 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, India, 1274-1278
- Fildes, R., & Goodwin, P.** (2007). Against your better judgment? How organizations can improve their use of management judgment in forecasting. Interfaces, 37, 570–576.
- Fischer T, Krauss C** (2018) Deep learning with long short-term memory networks for financial market predictions. Eur J Oper Res 270(2):654–669

- Franses, P. H., & Legerstee, R.** (2010). Do experts' adjustments on model-based SKU-level forecasts improve forecast quality? *Journal of Forecasting*, 29, 331–340.
- Gers F. A. and Schmidhuber, J.** “Recurrent nets that time and count,” in *ijcnn*, IEEE, 2000, p. 3189.
- Gers FA, Pérez-Ortiz JA, Eck D, Schmidhuber J** (2002) Learning context sensitive languages with LSTM trained with Kalman filters. In: *International conference on artificial neural networks*. Springer, pp 655–660
- Graves, A.** “Supervised sequence labelling,” in *Supervised sequence labelling with recurrent neural networks*, Springer, 2012, pp. 5–13.
- Greff, K. Srivastava, R. K. Koutnik, J. Steunebrink, B. R. and Schmidhuber, J.** “Lstm: A search space odyssey,” *IEEE transactions on neural networks and learning systems*, vol. 28, no. 10, pp. 2222–2232, 2017.
- Hong, T., Wilson, J., Xie, J.** (2014). Long term probabilistic load forecasting and normalization with hourly information. *IEEE Trans. Smart Grid* 5, 456–462.
- Hong, T., Fan, S.** (2016). Probabilistic electric load forecasting: A tutorial review. *Int. J. Forecast.* 32, 914–938.
- Hochreiter S. and Schmidhuber, J.** “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- Infield D.G. and Hill, D.C.** (1998). “Optimal Smoothing for Trend Removal in Short term Electricity Demand Forecasting,” *IEEE Transaction on Power System*, Vol.13, pp.1115-1120.
- Jacob M., Neves C., Vukadinović-Greetham D.** (2020). Short term load forecasting. *Forecast Assess Risk Individ Electr Peaks Math Planet Earth*, pp.15-37.
- Joechtl, G.** *Digital Signal Processing - Script for lecture DSP1/2*. University of Applied Sciences Salzburg, 2012.
- Kaplan, Y.** (2014). Sıklıkla kullanılan yapay sinir ağları algoritmalarının Antalya iline ait elektrik yük tahmini özelinde analitik olarak değerlendirilmesi. (Yayınlanmamış Yüksek Lisans Tezi). Altınbaş Üniversitesi, İstanbul.
- Karagülle, F.** (2008). “Destek vektör makinelerini kullanarak yüz bulma”, Yüksek Lisans Tezi,

Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne.

- Kavzoğlu, T. ve Çölkesen, İ.** (2010). “Destek Vektör Makineleri İle Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi”, Harita Dergisi, 144: 73-82.
- Keleş, M.S.** (2005). Elektrik enerjisi talep tahminleri ve Türkiye ekonomisine olan etkileri, Hazine Uzmanlık Tezi, Hazine Müsteşarlığı, Ankara, 2-3.
- Keleş, N.** (1998). Yük Tahmini ve Beyoğlu Bölgesine Uygulanması, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul
- Khan, U. N.** (2018). Short-term load forecasting by using artificial neural networks, Yayınlanmamış Yüksek Lisans Tezi. İstanbul: Bahçeşehir Üniversitesi.
- Khotanzad, A., Afkhami-Rohani, R., Lu, T. L., Abaye, A., Davis, M. ve Maratukulam, D. J.,** (1997). “Anntlf- A Neural-Network-Based Electric Load Forecasting System”, IEEE Transactions on Neural Networks, 8 (4): 835-846,4
- Khuntia, S.R., Rueda, J.L., van der Meijden, M.A.M.M.** (2016). Forecasting the load of electrical power systems in mid-and long-term horizons: A review. IET Gen. Trans. Distr. 10, 3971–3977
- Kim, N., Kim, M., Choi, J. K.** (2018). LSTM Based Short-term Electricity Consumption Forecast with Daily Load Profile Sequences. 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE), 136–137.
- Kingma D. P. and Ba, J.** “Adam: A method for stochastic optimization,” arXiv preprint arXiv:1412.6980, 2014.
- Lasfer, A.** (2013). Performance Analysis of Artificial Neural Networks in Forecasting Financial Time Series.
- Le, Q. V. Ngiam, J.Coates, A. Lahiri, A. Prochnow, B. and Ng, A. Y.** “On optimization methods for deep learning,” in Proceedings of the 28th International Conference on International Conference on Machine Learning, Omnipress, 2011, pp. 265–272.
- Learned-miller, E. G.** (2014). Introduction to Supervised Learning. 1–5.
- Li, Bh., Hou, Bc., Yu, Wt. et al.** Applications of artificial intelligence in intelligent manufacturing: a review. Frontiers Inf Technol Electronic Eng 18, 86–96 (2017).
- Liu Y** (2019) Novel volatility forecasting using deep learning-long short term memory

recurrent neural networks. *Expert Syst Appl* 132:99–109

**Liu, T., Jin, Y., Gao, Y.** (2019). A New Hybrid Approach for Short-Term Electric Load Forecasting Applying Support Vector Machine with Ensemble Empirical Mode Decomposition and Whale Optimization. *Energies* 12, 1520.

**LstmLayer.** (n.d.).

<https://www.mathworks.com/help/deeplearning/examples/time-series-forecastingusingdeep-learning.html>

**Mandal, P., Senjyu, T., Urasaki, N. ve Funabashi, T.,** (2006). “A Neural Network Based Several-Hour-Ahead Electric Load Forecasting Using Similar Days Approach”, *Electrical Power and Energy Systems*, 28: 367-373.

**Matthew, S., Satyanarayana, S.** (2016). An overview of short term load forecasting in electrical power system using fuzzy controller. 2016 5th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), 296–300.

**Matlab Programı Resmi Sitesi(2021).** *Yardım Merkezi*

[Erişim:15.03.2021,<https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html>]

**Mbamalu G.A.N. and El-Hawary, M.E.** (1992). “Load Forecasting Via Suboptimal Seasonal Autoregressive Models And Iteratively Reweighted Least Squares Estimation,” *IEEE Transaction on Power System*, Vol.8, pp.343-348.

**Metz C** (2016) An infusion of AI makes Google translate more powerful than ever. <https://www.wired.com/2016/09/google-claims-ai-breakthrough-machine-translation/>. Accessed 15 Nov 2019

**Morales-España Germán, Ramírez-Elizondo Laura, Hobbs Benjamin F.** Hidden power system inflexibilities imposed by traditional unit commitment formulations. *Appl Energy* 2017;191:223–238.

**Mutsena, J. T.** (2018). Short-term load forecasting for microgrids based on fuzzy logic, Yayınlanmamış Yüksek Lisans Tezi. İstanbul: Yıldız Teknik Üniversitesi.

**NERC.** 22:00 Frequency Excursions (Final Report). Technical report; 2002.

**Neto, L. S. R., Vellasco, M., Figueiredo, K., Pacheco, M. A.,** (2011). Modeling Neural Networks to Very Short-Term Load Forecasting.

- Nobari, A. G.** (2020). Short term load forecasting by using artificial neural networks, Yayınlanmamış Yüksek Lisans Tezi. İstanbul: İstanbul Teknik Üniversitesi.
- Oğurlu, H.** (2011). Matematiksel modelleme kullanarak Türkiye'nin uzun dönem elektrik yük tahmini". Yayınlanmamış Yüksek Lisans Tezi, Selçuk Üniv. Fen Bilimleri Ens., Konya, Türkiye.
- Oliver, A., Odena, A., Raffel, C., Cubuk, E. D., and Goodfellow, I. J.** (2018). Realistic Evaluation of Deep Semi-Supervised Learning Algorithms, NIPS'18: Proceedings of the 32nd International Conference on Neural Information Processing Systems, pp. 3239–3250.
- Osman, Z. H., Awad, M. L. ve Mahmoud, T. K.,** (2009). “Neural network based approach for short-term load forecasting”, Power Systems Conference and Exposition, 1-8.
- Ozoh, P., Abd-Rahman, S., Labadin, J.** (2015) Predicting electricity consumption: A comparative analysis of the accuracy of various computational techniques. 2015 9th International Conference on IT in Asia (CITA), 1–7.
- Özger, Y , Akpınar, M , Musayev, Z , Yaz, M .** (2019). Elektrik Yükünün Genetik Algoritma Temelli Holt-Winters Üstel Düzeltme Yöntemiyle Tahmini . Sakarya University Journal of Computer and Information Sciences , 2 (2) , 108-123 .
- Özkara, Yücel,** (2009), ‘Mevsimsel Ayırıştırma Temelli Gri Tahmin Yöntemi İle Aylık Elektrik Yük Tahmini’ Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Özsoy, B.** (2018). Very short term load forecasting aided hybrid state estimator with optimally placed pseudo-measurements, Yayınlanmamış Yüksek Lisans Tezi. Ankara: Orta Doğu Teknik Üniversitesi.
- Palit, A. K. ve Popovic, D.,** (2005). “Traditional Problem Definition”, Computational Intelligence in Time Series Forecasting, Springer, 17-75.
- Philipsen Rens, Morales-España Germán, de Weerd Mathijs, de Vries Laurens.** Imperfect Unit Commitment decisions with perfect information: A real-time comparison of energy versus power. In: 19th Power systems computation conference, PSCC 2016; pp.1-7.
- Pınarbaşı, M.** (2009). “Elektrik enerji sistemlerinde talep tahmin yöntemleri ve yapay sinir ağları uygulaması”, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

- Pino JM, Sidorov A, Ayan NF** (2017) Transitioning entirely to neural machine translation. <https://engineering.fb.com/ml-applications/transitioning-entirely-to-neural-machine-translation/>. Accessed 15 Nov 2020
- Rob H. and George, A.** (2017). Evaluating forecast accuracy, [Online]. Available: <https://www.otexts.org/fpp/2/5> (visited on 07/27/2020).
- Khuntia, S. R., Rueda, J. L., & van der Meijden, M. A. M. M.** (2016). Forecasting the load of electrical power systems in mid- and long-term horizons: a review. *IET Generation, Transmission & Distribution*, 10(16), 3971–3977.
- Ryu, S.; Noh, J.; Kim, H.** Deep Neural Network Based Demand Side Short Term Load Forecasting. *Energies* 2017, 10, 3.
- Saeli, H., Rosenberg, E., and Feilberg, N.** (2011). Estimating costs and benefits of the smart grid. a preliminary estimate of the investment requirements and the resultant benefits of a fully functioning smart grid. <http://www.rmi.org/Content/Files/EstimatingCostsSmartGRid.pdf>.
- Sabina Aouf R** (2019) Openai creates dactyl robot hand with “unprecedented” dexterity. <https://www.dezeen.com/2018/08/07/openai-musk-dactyl-robot-hand-unprecedented-dexterity-technology/>. Accessed 17 Nov 2020
- Sagheer A, Kotb M** (2019) Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing* 323:203–213
- Sak H, Senior A, Rao K, Beaufays F, Schalkwyk J** (2015) Google voice search: faster and more accurate.
- Senjyu, T. Sakihara, H., Tamaki, Y., Uezato, K.** (2001). Next-Day Load Curve Forecasting Using Neural Network Based On Similarity, *Electric Power Components and Systems*, Vol.29, pp.939-948
- Sharma. S.** (2017). Activation Functions: Neural Networks, [Online]. Available: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6> (visited on 07/07/2020).
- Shu, D.** (2009). Short-term load forecasting using system-type neural network architecture, Master Thesis, Baylor University, 1-2.
- Siami-Namini S. and Namin, A. S.** “Forecasting economics and financial time series:

Arima vs. lstm,” arXiv preprint arXiv:1803.06386, 2018.

**Singh, A., Nasiruddin, I., Khatoon, S., Muazzam, Md., Chaturvedi, D.** (2012). Load forecasting techniques and methodologies: A review. ICPES 2012 - 2012 2nd International Conference on Power, Control and Embedded Systems. 1-10.

**Sobhani, Masoud, Allison Campbell, Saurabh Sangamwar, Changlin Li, and Tao Hong.** (2019). "Combining Weather Stations for Electric Load Forecasting" *Energies* 12, no. 8: 1510.

**Soliman, S.A. and Al-Kandari, A.M.** (2010). *Electrical Load Forecasting*, Elsevier, Burlington, 79-82

**Somasundaram, Kamalakkannan & Surekha, G & Dr.S, Mathivilasini.** (2019). Artificial Intelligence: Major Place In Online Learning. *International Journal of Mechanical and Production Engineering Research and Development (IJMPERD)*, 8(3) 387-392.

**Som, A.** (2010). *Uzun Dönem Yük Tahmini: Manisa Örneği, (Yüksek Lisans Tezi)*, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü, Kütahya.

**Taik, A., Cherkaoui, S.** (2020). Electrical Load Forecasting Using Edge Computing and Federated Learning. *ICC 2020 - 2020 IEEE International Conference on Communications (ICC)*, 1–6.

**The AlphaStar Team** (2019) *Alphastar: Grandmaster level in starcraft ii using multi-agent reinforcement learning*. <https://deepmind.com/blog/article/AlphaStar-Grandmaster-level-in-StarCraft-II-using-multiagent-reinforcement-learning>. Accessed 15 Nov 2019.

**Toker, A.C. ve Korkmaz, O.** (2011). Türkiye'nin kısa süreli elektrik talebinin saatlik olarak tahmin edilmesi, 17.Uluslararası Enerji ve Çevre Konferansı, İstanbul, 32- 35.

**Trapero, J. R., Pedregal, D. J., Fildes, R., & Weller, M.** (2011). Analysis of judgmental adjustments in presence of promotions. Paper presented at the 31th international symposium on forecasting. ISF2011. Prague.

**Türkiye Elektrik İletim A.Ş. (EİPAŞ) Şeffaflık** (2020). *Gerçekleşen Gerçek Zamanlı Üretim Verileri*. [Erişim Tarihi: 04.04.2021, <https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml>]

**Vogels W** (2016) *Bringing the Magic of Amazon AI and Alexa to Apps on AWS*.

<https://www.allthingsdistributed.com/2016/11/amazon-ai-and-alexa-for-all-aws-apps.html>. Accessed 15 Nov 2020

- Wang, Z.;** Srinivasan, R.S. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models. *Renew. Sustain. Energy Rev.* 2017, 75, 796–808.
- Yan H, Ouyang H** (2017) Financial time series prediction based on deep learning. *Wirel Pers Commun* 102:1–18
- Yıldız, B., Bilbao, J. I., and Sproul, A. B.** (2017). A review and analysis of regression and machine learning models on commercial building electricity load forecasting. *Renewable and Sustainable Energy Reviews*, 73(March 2016), 1104–1122.
- Yoldaş, U.C.** (2006). Türkiye'nin 2005–2020 Yılları Arasındaki Elektrik Enerjisi Talep Gelişimi Ve Arz Planlaması, (Yüksek Lisans Tezi), Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Yu Y, Si X, Hu C, Zhang J** (2019) A review of recurrent neural networks: LSTM cells and network architectures. *Neural Comput* 31(7):1235–1270
- Zakarya S., Abbas H., Belal M.** (2017). Long-term deep learning load forecasting based on social and economic factors in the Kuwait region. *J Theor Appl Inf Technol* 95:1524–1535.
- Zhang Z, Li H, Zhang L, Zheng T, Zhang T, Hao X, Chen X, Chen M, Xiao F, Zhou W** (2019) Hierarchical reinforcement learning for multi-agent moba game. arXiv preprint arXiv:1901.08004.