



**MİKRO ŞEBEKELERDE YÜK VE YENİLENEBİLİR ENERJİ KAYNAKLARI
TAHMİNİNE DAYALI EKONOMİK YÜK DAĞITIMI**

YÜKSEK LİSANS TEZİ

Mehmet DAYIOĞLU

Danışman

Prof. Dr. Rıdvan ÜNAL

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Mayıs 2023

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MİKRO ŞEBEKELERDE YÜK VE YENİLENEBİLİR ENERJİ
KAYNAKLARI TAHMİNİNE DAYALI EKONOMİK YÜK
DAĞITIMI

Mehmet DAYIOĞLU

Danışman

Prof. Dr. Rıdvan ÜNAL

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Mayıs 2023

ÖZET

Yüksek Lisans Tezi

MİKRO ŞEBEKELERDE YÜK VE YENİLENEBİLİR ENERJİ KAYNAKLARI TAHMİNİNE DAYALI EKONOMİK YÜK DAĞITIMI

Mehmet DAYIOĞLU

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Rıdvan ÜNAL

Hızla büyüyen dünyada elektrik enerjisine olan talep giderek artmaktadır ancak enerji ihtiyacını karşılamak için halen yoğun bir şekilde kullanılan fosil kaynaklar için durum aynı değildir. Bu nedenle her geçen gün popülaritesi artan yenilenebilir enerji kaynaklarının enerji şebekelerine entegrasyonu önemli hale gelmiştir. Özellikle fotovoltaik ve rüzgâr gücündeki hızlı gelişmeler mikro şebeke kavramının gelişmesinde büyük rol oynamıştır. Mikro şebekeler yüklerinin enerji ihtiyacını bünyesinde bulunan dağıtık üretim kaynakları aracılığı ile sağlayan yapılardır. Mikro şebekeler ana şebekeden tamamen bağımsız işletilebileceği gibi dağıtık üretimin cevap veremediği enerji talebini gidermek adına enterkonnekte şebeke ile bağlı olarak da çalışabilir. Bunun tersi olarak yenilenebilir üretimin fazla olduğu koşullarda mikro şebeke talep fazlası enerjiyi ana şebekeye aktararak ekonomik gelir sağlayabilir.

Mikro şebeke yüklerinin enerji ihtiyacı yoğunlukla yenilenebilir enerji kaynakları aracılığı ile karşılanır. Ancak bu kaynakların hava koşullarına bağlılığı mikro şebeke için enerjide süreklilik sorunları oluşturabilir. Bu nedenle şebeke yüklerinin tahmini ve dağıtık üretim kaynaklarının operasyonun bu tahmin doğrultusunda planlanması sürdürülebilir güç için önem taşır. Bu çalışmada bir mikro şebekenin geçmiş dönem yük verileri ve hava durumu verileri kullanılarak kısa dönem yük tahmini yapılmıştır. İstatistiksel ve makine öğrenmesine dayalı tahminler performans metrikleri ile değerlendirilerek bu mikro şebeke için hata payı en düşük tahmin algoritması

belirlenmiştir.

Çalışmanın devamında yük profili oluşturulan mikro şebekenin farklı senaryolar üzerinden ekonomik analizleri yapılarak en düşük maliyetle elektrik üretimi sağlayan durum belirlenmiştir. Yirmi beş sene için projelendirilen mikro şebeke için yatırım analizi yapılarak senaryolar arasındaki nakit akış farkı irdelenmiştir. Çalışmanın sonucunda tasarlanan yeni mikro şebekenin mevcut şebekeye oranla daha ekonomik olarak enerji ürettiği ve yatırım maliyetini kısa bir sürede amorti ettiği görülmüştür.

2023, xii + 94 sayfa

Anahtar Kelimeler: Mikro şebeke, Dağıtık üretim, Yük tahmini, Yenilenebilir enerji kaynakları, Ekonomik yük dağıtımı.

ABSTRACT

M.Sc. Thesis

ECONOMIC LOAD DISTRIBUTION BASED ON LOAD AND RENEWABLE ENERGY RESOURCES FORECAST IN MICROGRIDS

Mehmet DAYIOĞLU

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Prof. Rıdvan ÜNAL

The demand for electrical energy is constantly increasing in the rapidly growing world, but the situation is not the same for fossil resources, which are still used extensively to meet this energy need. For this reason, the integration of renewable energy sources, whose popularity is increasing day by day, into energy networks has become important. Particularly, rapid developments in photovoltaic and wind power have played a major role in the development of the microgrid concept. Microgrids are structures that provide the energy needs of their loads through their distributed generation resources. Microgrids can be operated completely independently from the main grid, or they can also work in conjunction with an interconnected grid in order to meet the energy demand that distributed generation cannot respond. Conversely, in conditions where renewable generation is high, micro-grid excess demand can now provide economic income by transferring energy to the main grid.

It is possible that there will be continuity problems in supplying energy to the loads, since the microgrid loads mostly meet the energy needs with renewable sourced generation methods and these resources are dependent on weather conditions. Therefore, the estimation of the grid loads and the planning of the operation of the distributed generation resources in line with this estimation are important for sustainable power. In this study, short-term load estimation of a microgrid was made using historical load data and weather data. Statistical and machine learning-based predictions were evaluated with performance metrics and the lowest margin of error prediction algorithm was determined for this

microgrid.

In the continuation of the study, economic analyzes of the micro-grid with a load profile were made over different scenarios, and the situation that provides electricity production with the lowest cost was determined. The cash flow difference between the scenarios was observed by making an investment analysis for the micro-grid projected for twenty-five years. As a result of the study, it has been seen that the new micro grid designed produces energy more economically than the existing grid and pays off the investment cost in a short time.

2023, xii + 94 pages

Keywords: Microgrid, Distibuted generation, Load forecasting, Renewable energy resources, Ekonomic load dispatch.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Prof. Dr. Rıdvan ÜNAL'a ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Mehmet DAYIOĞLU
Afyonkarahisar 2023

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	viii
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xxiii
1. GİRİŞ	1
2. LİTERATÜR BİLGİLERİ	4
2.1 Mikro Şebekeler	4
2.2 Mikro Şebeke Türleri.....	6
2.2.1 AC Mikro Şebeke.....	6
2.2.2 DC Mikro Şebeke.....	6
2.2.3 Hibrit Mikro Şebeke.....	7
2.3 Mikro Şebeke Kararlılığı	7
2.3.1 Mikro Şebekelerde Operasyon ve Kontrol	8
2.3.2 Mikro Şebekelerde Koruma.....	9
2.3.3 Mikro Şebekelerde Güç Kalitesi	10
2.4 Elektriksel Yük Tahmini	10
2.4.1 Yük Tahminini Etkileyen Faktörler	15
2.4.2 Tahmin Algoritmaları.....	19
2.4.2.1 Lineer Regresyon Analizi	19
2.4.2.2 Gauss Süreç Regresyonu.....	21
2.4.2.3 Regresyon Ağacı.....	23
2.4.2.4 Destek Vektör Regresyonu.....	27
2.4.2.5 Yapay Sinir Ağları.....	32
2.5 Yenilenenebilir Enerji Kaynakları Tahmini	36
2.5.1 Güneş Enerjisi Tahmini	37
2.5.2 Rüzgar Enerjisi Tahmini.....	38
2.6 Literatür Taraması	39

2.6.1 Ulusal Çalışmalar	39
2.6.2 Uluslararası Çalışmalar	43
3. MATERYAL ve METOT	46
3.1 Elektriksel Yük Tahmini Uygulaması	46
3.1.1 Veri Toplama	46
3.1.2 Veri Seti Oluşturma ve Analizi	49
3.1.3 YSA ile Yük Tahmini	52
3.1.4 Performans Metrikleri	56
3.2 Mikro Şebeke Ekonomik Analizi	58
3.2.1 Dağıtık Üretim Kaynakları	59
3.2.1.1 FV Sistem Ekonomik Modeli	60
3.2.1.2 Rüzgar Enerjisi Ekonomik Modeli	62
3.2.1.3 Dizel Jeneratör Ekonomik Modeli	63
3.3 Sanal Mikro Şebeke Tasarlanması	64
4. BULGULAR	66
4.1 Yük Tahmini	66
4.2 Elektrik Üretim Maliyeti Karşılaştırılması	74
5. TARTIŞMA ve SONUÇ	80
6. KAYNAKLAR	82
ÖZGEÇMİŞ	89
EKLER	90

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

\$	Dolar
¢	Cent
CIGS	Bakır indiyum galyum seleid
C-Si	Kristal silikon
kW	Kilovat
kWh	Kilovat saat
mg	Miligram
MW	Megavat
MWh	Megavat saat
TWh	Teravat saat
C°	Santigrat derece

Kısaltmalar

AC	Alternating current
ANFIS	Adaptive neuro fuzzy interface systems
API	Application programming interface
AR	Autoregressive
ARIMA	Autoregressive integrated moving average
ARMA	Autoregressive moving average
BLR	Basit lineer regresyon
BY	Bayesian regularization
CS	Coarse tree
ÇLR	Çoklu lineer regresyon
DC	Direct current
DST	Daylight saving time
DUQ	Duqense
DÜ	Dağıtık üretim
DVM	Destek vektör makineleri
DVR	Destek vektör regresyonu
EDS	Enerji depolama sistemleri
EKK	En küçük kareler
ELU	Ekspansiyonel doğrusal birim
EST	Eastern standard time
FT	Fine tree
FV	Fotovoltaik
GARCH	Generalized autoregressive conditional heteroskedasticity
GSR	Gauss süreç regresyonu
HOMER	Hybrid optimization of multiple energy resources
IEA	International energy agency
IRR	İç kararlılık oranı
İ&B	İşletme ve bakım
LCOE	Levelized cost of energy
LM	Levenberg-Marquardt

Kısaltmalar (Devam)

LR	Lineer regresyon
LSTM	Long short term memory
MA	Moving average
MAE	Mean absolute error
MAPE	Mean absolute percentage error
MSE	Mean squarred error
MŞ	Mikro şebeke
MT	Medium tree
NARX	Nonlinear autoregressive network with exogenous
NHT	Nümerik hava tahmin
NVP	Net present value
PBP	Payback period
PJM	Pennsylvania-New Jersey-Maryland interconnection
POWER	Prediction of worldwide energy resource
R	Korelasyon katsayısı
RA	Regresyon ağacı
ReLU	Rectified linear unit
RMSE	Root mean square deviation
ROI	Return of investment
RTF	Radyan taban fonksiyonu
SA	Sinir ağları
SCG	Scaled conjugate gradient
UTC	Universal time coordinated
YEK	Yenilenebilir enerji kaynakları
YSA	Yapay sinir ağları

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1	Temsili bir mikro şebeke	5
Şekil 2.2	2010-2027 yıllarındaki güç üretim yöntemleri arasındaki kümülatif güç kapasitesi paylaşımı	6
Şekil 2.3	Hibrit mikro şebekedeki güç baraları, dağıtık üretim elemanları, yükler ve çift yönlü enerji dönüşüm elemanları.....	7
Şekil 2.4	2020 yılında ülkelerin haftalık yük talebinin önceki seneye göre değişimi	13
Şekil 2.5	(a) 2020 ve 2019 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi. (b) 2021 ve 2020 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi. (c) 2022 ve 2021 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi (Teiaş 2023).....	14
Şekil 2.6	2016 ile 2019 yıllarındaki Türkiye’deki MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023)	15
Şekil 2.7	Türkiye’deki farklı altı yıldaki 15 Haziran günü için MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).....	16
Şekil 2.8	Türkiye’deki 01.04.2022-31.05.2022 tarihleri arasındaki MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).....	17
Şekil 2.9	Türkiye’deki 2022 yılına ait altı farklı gün için MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).....	18
Şekil 2.10	LR doğrusu	19
Şekil 2.11	EKK yöntemi ile oluşturulmuş regresyon doğrusu.....	20
Şekil 2.12	Kalp krizi hastalarını risk oranına göre sınıflandıran karar ağacı modeli	24
Şekil 2.13	Dozaj ve ilaç verimliliği modeli	25
Şekil 2.14	Dozaj miktarına göre ilacın etki oranını belirten regresyon ağacı modeli	25
Şekil 2.15	İkili ve çoklu sınıflandırma örneği.....	27
Şekil 2.16	Lineer sınıflandırma ve lineer olmayan sınıflandırma temsili (Kowsari vd. 2019).....	27
Şekil 2.17	Hard ve soft marjin özellikleri	29
Şekil 2.18	Lineer olmayan destek regresyonu (Sarraf vd. 2021)	30

Şekil 2.19 YSA modeli için aşırı öğrenme ve en uygun karmaşıklık durumu (Bejani vd.2021).....	33
Şekil 2.20 YSA yapısı (Juan vd. 2022).....	34
Şekil 3.1 PJM bölge haritası.....	46
Şekil 3.2 PJM bünyesindeki çeşitli iletim bölgelerini gösteren harita.....	47
Şekil 3.3 Duquesne bölgesi için MW cinsinden 7 yıllık yük verisi	48
Şekil 3.4 Sıcaklık ve yük değişkenlerine ait dağılım grafiği	51
Şekil 3.5 Nem ve yük değişkenlerine ait dağılım grafiği.....	51
Şekil 3.6 LM algoritması için nöron sayısı ve hata miktarı ilişkisi.....	53
Şekil 3.7 BR algoritması için nöron sayısı ve hata miktarı ilişkisi	53
Şekil 3.8 SCG algoritması için nöron sayısı ve hata miktarı ilişkisi	54
Şekil 3.9 YSA modeli	54
Şekil 3.10 YSA ile tahmin sürecinin akış diyagramı.....	55
Şekil 3.11 Sigmoid ve tanh fonksiyonları.....	56
Şekil 3.12 Yıllara göre farklı teknolojiler için \$/MWh cinsinden LCOE ortalamaları ..	60
Şekil 3.13 Dizel jeneratör LCOE unsurlarının dağılım grafiği	63
Şekil 4.1 (a) Interactions LR için cevap grafiği, (b) fine RA için cevap grafiği, (c) fine gaussian DVR için cevap grafiği, (d) üstel GSR için cevap grafiği	68
Şekil 4.2 (a) Interactions LR için regresyon grafiği, (b) fine RA için regresyon grafiği, (c) fine gaussian DVR için regresyon grafiği, (d) üstel GSR için regresyon grafiği	69
Şekil 4.3 YSA modeli eğitim, validasyon ve test verileri performans grafiği	70
Şekil 4.4 YSA modeli eğitim, validasyon ve test verileri için regresyon grafiği.....	71
Şekil 4.5 Gerçek değerler ile YSA ve üstel GSR model çıktılarının karşılaştırılması ...	72
Şekil 4.6 Gerçek değerler ve üstel GSR tahmin değerlerinin karşılaştırma grafiği	73
Şekil 4.7 Gerçek değerler ve YSA tahmin değerlerinin karşılaştırma grafiği	73
Şekil 4.8 Tasarlanan sanal MŞ	74
Şekil 4.9 Sunulan ve baz durum için 25 yıllık nakit akış grafiği	76
Şekil 4.10 Farklı kaynaklar için aylık elektrik üretimi	76
Şekil 4.11 Yıllık şebekeden satın alınan ve satılan enerji grafiği	78
Şekil 4.12 25 senelik süre periyodu için baz ve en düşük maliyetli senaryolar için kümülatif nominal nakit akışı eğrisi.....	79

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Aktivasyon Fonksiyonları.....	35
Çizelge 3.1 Veri setini oluşturan tarihsel, meteorolojik ve yük parametrelerine ait değer aralıkları ve birimler.	50
Çizelge 3.2 Veri setindeki tahmin parametreleri ile yük değeri arasındaki korelasyon katsayısı	52
Çizelge 3.3 MŞ elemanlarının maliyet unsurları.....	64
Çizelge 4.1 Farklı tahmin modellerinin performans metriklerine göre değerlendirilmesi	66
Çizelge 4.2 YSA modeli eğitim, validasyon ve test verileri için performans değerlendirmesi	70
Çizelge 4.3 Üstel GSR ve YSA modelleri ile tahmin sonuçlarının değerlendirilmesi...	72
Çizelge 4.4 MŞ senaryoları için ekonomik analiz.....	75
Çizelge 4.5 MŞ ve enterkonnekte şebeke arasındaki ay bazında enerji alışverişi	77

1. GİRİŞ

Geçtiğimiz son bir yılda elektrik enerjisine olan talep ekonomik büyüme ve iklim değişikliklerinin getirdiği ek ısıtma ve soğutma ihtiyacı ile %6'dan fazla artmıştır. Bu talep artışının büyük bir kısmı kömür yakıtlı elektrik üretim santralleri ile karşılanmıştır (IEA 2022). Enerji talebindeki bu artışın etkisiyle 2021 yılında Dünya'nın kömür üretimi %5,7 seviyesinde artmıştır. Ayrıca buna paralel olarak bu süreçte CO₂ emisyonu %5,4 artarak rekor seviyeye ulaşmıştır (İnt. Kyn. 1). Dünya'nın elektrik üretiminin %60'dan fazlası fosil yakıtlarla sağlanmaktadır. Ancak her geçen gün artan elektrik talebiyle fosil yakıtların tükenmekte olduğu da bir gerçektir. Bu durumun sonucu olarak yenilenebilir enerji kaynaklarına (YEK) verilen önem hızla artmaktadır (İnt. Kyn. 3).

YEK'leri kullanan enerji üretim yöntemleri hem insan sağlığına ve çevreye olan etkisi hem de elektrik enerjisi üretmek için tükenen bir hammaddeye ihtiyaç duymaması nedeniyle fosil yakıt kaynaklı enerji üretim yöntemlerine göre daha avantajlı görülmektedir. 2020 yılında yenilenebilir elektrik üretimi 7 468 TWh iken bunun %59'u hidroelektrik, %21'i rüzgâr, %11'i güneş, %8'i biyoenerji ve %1'i jeotermal enerji kaynaklıdır. Yenilenebilir enerjideki küresel trendi incelemek adına bir önceki yıl olan 2019 ile bir karşılaştırma yapıldığında yenilenebilir enerji kaynaklı üretimdeki en büyük artışın %22 oranıyla güneş enerjisi ve %12 oranıyla rüzgâr enerjisinde olduğu görülmektedir. Bunları takip eden biyoenerjinin %4,7, hidroelektriğin %3,7 ve jeotermalin ise %2,9 arttığı görülmüştür (IRENA 2022).

Her ne kadar YEK'lerin elektrik üretiminde kullanımının yaygınlaşması temiz ve ekonomik enerji üretiminde büyük bir önem arz etse de şebeke yüklerindeki ani değişimler ve YEK'lerin ortam şartlarına olan bağımlılığı YEK'lerin kullanımına kısıtlamalar getirmektedir (Querini vd. 2021). Bu nedenle elektrik enerjisi üretiminde YEK'lerin tek kaynak olarak kullanılması yetersiz kalmaktadır. Halen Dünya'da üretilen elektrik enerjisinin %60'a dayanan bölümü kömür, doğalgaz ve petrol kaynaklı fosil yakıtlar ile sağlandığı görülmektedir. Geri kalan kısmı ise yenilenebilir enerji olan hidroelektrik, rüzgâr, güneş ve benzeri kaynaklar ile sağlanmaktadır (İnt. Kyn. 4).

Yenilenebilir kaynakların bir diğer önemi ise beklenmedik bir kriz anında enerji tedariki adına dışa bağımlılığı azaltmasıdır. Bilindiği üzere 2022 yılının şubat ayında Rusya ve Ukrayna arasında başlayan savaş küresel bir enerji krizine yol açmıştır. Rusya'nın Ukrayna'yı işgali sonrası birçok ülke ve kuruluş Rusya'ya ciddi ekonomik yaptırımlar uygulamıştır. Bunun sonucu olarak Avrupa dünyanın en büyük petrol, doğalgaz ve kömür ihracatçısı olan Rusya'ya karşı alternatif bir arayışa girmiştir. Takip eden günlerle kış aylarının yaklaşması ile ısınma ihtiyacından doğan artan kaynak talebini karşılayabilmek adına özellikle doğalgaz adına Rusya'ya uygulanan yaptırımlar gevşetilmiştir. Bu durum enerjide dışa bağımlılığın azaltılması adına YEK'lere olan yönelimi arttırmıştır (Umar vd. 2022).

Elektrik üretimi için kaynak çeşitliliğinin bu denli fazla olması merkezi bir enerji kaynağına alternatif olarak merkezi olmayan birçok enerji kaynağının entegre bir üretim yapmasını bir seçenek haline getirmiştir. Bu sebeple dağıtık üretim (DÜ) kavramı doğmuştur (Hatziaargyriou ve Meliopoulos 2002, Almogrbi 2017). Bu yöntemle şebekedeki yükler başta yenilenebilir olmak üzere alternatif kaynaklarla beslenebilir hale gelmektedir. Merkezi üretimde genelde yaşam alanlarına uzak bir noktadaki elektrik üretim santralinde üretilen elektrik enerjisi enerji iletim hatları vasıtasıyla son kullanıcıya kadar taşınmaktadır. Yüksek enerji üretme kapasitesine sahip kömür, gaz ve nükleer gibi elektrik santralleri hem boyutları hem de çevreye olan etkileri yüzünden yerleşim yerlerinden uzak konumlandırılmak istenmiştir. Hidroelektrik veya gelgit enerjisi gibi çevre bağımlılığı olan santrallerde benzer şekilde yerleşim yerlerine uzaktır. Bu nedenle merkezi üretim ile üretilen enerjinin kullanıcıya aktarılması birkaç evreden oluşmaktadır. Üretilen enerjinin son kullanıcıya verimli bir şekilde iletimi için trafo merkezleri aracılığı ile güç dönüşümünden geçmesi gereklidir. Bundan farklı olarak son yıllarda güneş ve rüzgâr enerjisinin kullanımının yaygın ve özellikle güneş santrallerinin maliyet bakımından son kullanıcı açısından erişilebilir hale gelmesi dağıtık üretime olanak sağlamaktadır. Dağıtık üretimde merkezi üretim santralleri dışında kullanıcının talebinin karşılayabilecek yerel elektrik enerjisi üretim noktaları bulunmaktadır. Bu kaynakların kullanıcıların yaşam alanı içine yayılması iletimden doğan gideri ve kayıpları minimize etmektedir. Ayrıca DÜ kullanıcıların taleplerini aşan artık elektriği şebekeye satarak gelir elde edilebilmesini mümkün kılarak temiz elektrik enerjisi üretimini teşvik etmektedir.

Bu noktada DÜ kaynaklarının şebekeye dahil olabilmesi adına Mikro şebeke (MŞ) kavramı doğmuştur. MŞ'lerde elektrik enerjisi talebine cevap verebilmek önemlidir. Aksi takdirde yük enerji dengesizliğinden kaynaklı frekans kaymaları ve hatta şebekede çökmelerin yaşanması muhtemeldir. Böyle bir sorunla karşılaşmamak adına MŞ için talep – üretim planlaması iyi yapılmalıdır. Bu noktada başta yenilenebilir enerji vasıtası ile üretim yapılan MŞ'de YEK'lerin tahmini ve şebekedeki yüklerin enerji talebinin tahminini yapmak önemlidir. Böylece elektrik enerjisi talebine göre yapılan bir üretim planlamasıyla hem enerji talebi sağlanırken hem de elektrik enerjisi için kaynak tüketen tesisler minimum kapasite ile çalıştırılarak elektrik enerjisi üretiminin ekonomik yükünden olabildiğince kaçınılmaktadır.

Bu tez ile sanal bir MŞ'deki yüklerin elektrik talebi tahmin edilerek üretim kaynakları arasında ekonomik yük dağıtımı yapılması hedeflenmiştir. Böylece MŞ'de elektrik üretim maliyetini en düşük seviyeye getiren dağıtık üretim kaynakları (DÜK) ve bu kaynakların kapasiteleri belirlenecektir. Oluşturulan bu yeni MŞ ile hali hazırda kullanılan konvansiyonel şebekenin mali farkları ortaya koyularak MŞ yatırımının getiri ve götürüleri sunulacaktır.


2. LİTERATÜR BİLGİLERİ

Bu bölümde MŞ'ler, yük ve YEK tahmin yöntemleri ile ilgili genel bilgiler sunulmuştur. Ayrıca bu alanda yapılan ulusal ve uluslararası çalışmalar incelenmiştir.

2.1 Mikro Şebekeler


Mikro şebekeler, temelde dağıtık enerji kaynakları, batarya sistemleri ve elektriksel yükleri kapsayan enerji sistemleridir. MŞ'deki elektriksel yükler MŞ'nin bünyesinde bulunan DÜK'ler sayesinde elektrik enerjisi ihtiyacını merkezi enerji üretim santrallerine asgari gereksinimle karşılamaktadır. Bu durum MŞ'ler ile YEK'ler arasındaki ilişkiyi vazgeçilmez kılmaktadır. Görece daha erişilebilir olan YEK'ler MŞ'lerin temelini oluşturmaktadır. MŞ'lerin bir diğer avantajı ise enerjinin tüketiciye merkezi santrallere göre daha yakına konumlandırılabilen DÜK'ler vasıtası ile sağlanmasıdır. Bu durum birçok avantajı yanında getirmektedir. İlk olarak elektrik enerjisinin yoğunlukla YEK'ler vasıtası ile üretilmesi sonucu doğaya salınan CO₂ miktarı azaltılarak daha temiz bir çevre imkânı sunulmaktadır. Ayrıca üretilen elektrik enerjisinin iletim mesafesinin daha kısa olmasından kaynaklı enerji kaybı azaldığı gibi enerji iletim hatlarına yapılan yatırım maliyeti de azalmış olur. Bir MŞ elektrik enerjisine olan talep doğrultusunda ana şebekeden bağımsız olarak işletilebilir. Bu durumda MŞ'de üretilen elektrik enerjisinin yüklere dağıtımında sürekliliği sağlamak önemlidir. Örneğin elektrik üretim kaynağı olarak güneş enerjisinden yararlanılan bir MŞ'de güneş ışımasının yoğun olduğu saatlerde yapılan elektrik üretimi yüklerin talebini karşılayabilirken ışımanın daha az olduğu sabah ve akşam saatlerinde üretilen elektrik enerjisi miktarı ciddi oranda düşer ayrıca gece boyunca elektrik üretimi durur. Benzer şekilde rüzgâr türbinlerinin de enerji verimliliği rüzgâr hızı ile ilişkilidir. YEK'lerin verimliliklerinin doğa ile artıp azalıyor olmasına rağmen enerji sistemindeki yükler için durum böyle değildir. Bu durum yükler için enerjide süreksizliğe neden olmaktadır. MŞ'ler bu süreksizliği giderebilmek adına yapılarında enerji depolama sistemleri (EDS) bulundurur. Ayrıca dizel jeneratör gibi petrol kaynaklı enerji üretim birimleri de elektrik enerjisi talebinin yüksek olduğu anlarda sisteme dahil olarak enerji sürekliliğini sağlama noktasında önemlidir. MŞ'ler ana şebekeden bağımsız işletilebildiği gibi ihtiyaç doğrultusunda ana şebekeyle bağlantı

kurarak güç akışı gerçekleştirebilir. Bu durum mikro şebeke ve makro şebekeler arasında karşılıklı güç akışına olanak sağlamaktadır. Güç akışı için oluşturulan fiyatlandırma politikaları dahilinde, bünyesinde enerji üretim birimleri bulunduran yükler enerji taleplerini aşan artık enerjiyi makro şebekeye aktararak bir anda üretici konumuna geçebilir. Bunun tersine mikro şebekenin enerji talebinin EDS'ler ve ek jeneratörlere rağmen karşılanamadığı durumlarda makro şebekeden tedarik edilen enerji yüklerin talebini karşılayabilmektedir. Şekil 2.1'de temsili bir MŞ yer almaktadır.



Şekil 2.1 Temsili bir mikro şebeke.

Şekil 2.2'deki enerji sektöründe güç üretimi yöntemlerinin yıllara göre kümülatif güç kapasitesi paylaşımı incelendiğinde, 2022 yılı itibarı ile doğalgaz, kömür ve hidroelektrik enerjiye göre geride kalan fotovoltaik (FV) ve rüzgâr enerjisinin takip eden yıllarda kurulu gücünün giderek artması beklenmektedir. International Energy Agency (IEA) tahminlerine göre 2027 yılında kurulu FV güç kapasitesinin, kömür kapasitesinin önüne geçmesi beklenmektedir. Düşük kurulum maliyeti ve kişisel kullanıma uygunluğu ile her geçen yıl yaygınlaşan güneş enerjisinin gelecek yıllarda Dünya'nın temel elektrik enerjisi kaynağı olması beklenmektedir. Güneş enerjisindeki bu denli büyümeye paralel olarak MŞ'lerin kullanımının yaygınlaşması muhtemeldir (IEA 2022).



Şekil 2.2 2010-2027 yıllarındaki güç üretim yöntemleri arasındaki kümülatif güç kapasitesi paylaşımı.

2.2 Mikro Şebeke Türleri

Mikro şebekeler türleri bakımında 3'e ayrılmaktadır. Bunlar alternatif akım (AC) MŞ, doğru akım (DC) MŞ ve hibrit MŞ'dir.

2.2.1 AC Mikro Şebeke

AC mikro şebekelerde tüm DÜK'ler ve şebeke yükleri bir AC güç barasına bağlıdır. Güneş enerjisi gibi DC üretim elemanları ve EDS'ler AC baraya güç eviricileri ile evirilerek bağlanırken rüzgâr enerjisi ve dizel jeneratörler gibi rotor dönüşüyle AC enerji üreten sistemler doğrudan güç barasına bağlanır. Bu durumda MŞ'deki DC yükler AC – DC doğrultucular ile beslenmektedir.


2.2.2 DC Mikro Şebeke

DC mikro şebekelerinde durum AC MŞ'lerden farklıdır. Bu sefer genel güç barası

DC'dir. AC güç üreten DÜK'ler DC baraya AC – DC doğrultucular ile bağlanır ve MŞ'deki AC yükler DC – AC eviriciler kullanılarak beslenir.

2.2.3 Hibrit Mikro Şebeke

Hibrit MŞ'lerde hem AC bara hem de DC bara mevcuttur. Bu durumda dağıtık üretim elemanları ve batarya sistemleri kendi türüne uygun baraya bağlanır. Aynı şekilde AC yükler AC güç barasına, DC yükler DC güç barasına bağlanır. Bu durum anlatılan diğer iki MŞ türüne göre daha az güç dönüşümüne maruz kaldığı için evirici ve doğrultucu kullanımını azaltır. Ayrıca bu türde dizel jeneratörün çalışması bağımsız olarak yönetilebildiği için enerji talebinin yoğun olduğu anlarda jeneratör devreye alınarak talep karşılanabilmektedir (Almogrbı 2017).



Şekil 2.3 Hibrit mikro şebekedeki güç baraları, dağıtık üretim elemanları, yükler ve çift yönlü enerji dönüşüm elemanları.

2.3. Mikro Şebeke Kararlılığı

MŞ'ler bünyesinde birden fazla güç ünitesi ve yük bulundurduğu için MŞ'lerde kararlılığı sağlamak önemlidir. MŞ kararlılığını sağlamak adına üç temel gereklilik sağlanmalıdır. Bu gereklilikler olan operasyon ve kontrol, koruma, güç kalitesi MŞ'nin işleyişinin sorunsuz bir şekilde sağlanması için önemlidir (Basak vd. 2012).

2.3.1 Mikro Şebekelerde Operasyon ve Kontrol

Geleneksel güç sistemlerinde kararlılığı sağlamak adına gerekli üç temel unsur MŞ'lerin kararlılığı için de gereklidir. Bunlar rotor açısı kararlılığı, gerilim kararlılığı ve frekans kararlılığıdır. Rotor açısı kararlılığı güç sistemindeki jeneratörlerin bir bozucu etki sonrasında senkron duruma dönebilme yeteneğidir. Bu bozucu etkinin büyüklüğüne bağlı olarak rotor açısı kararlılığı küçük işaret kararlılığı ve geçici hal kararlılığı olarak iki başlıkta irdelenebilir. Küçük işaret kararlılığı güç sistemlerindeki üretilen enerji – yük dengesizliği gibi geçici durumlara karşı sistemin senkronizasyonu sağlayabilmesidir. Geçici hal kararlılığı ise güç sisteminin kısa devre veya senkron jeneratörlerden biri ya da birkaçının devreden çıkması gibi büyük bir bozucu etki sonrasında senkronizasyonu koruyabilme durumudur. Gerilim kararlılığı güç sisteminin bozucu etkiler karşısında sabit gerilim değerinde kalma yeteneği iken benzer şekilde frekans kararlılığı da sistemin frekansını sabit tutma yeteneğidir. Geleneksel şebekelerdeki kararlılığı etkileyen bu unsurlar enerji üretim sistemleri ile ilişkili olduğundan, temel enerji kaynağı DÜ olan MŞ'ler için de bu kararlılık şartlarının sağlanması gereklidir. DÜK'ler olan FV, rüzgâr, mikro gaz türbinleri gibi sistemlerde üretilen gücün gerilim ve frekans değerleri giriş kaynakları ile ilişkilidir. FV sistemlerde bu kaynak güneş ışımasını iken rüzgâr veya gaz türbinlerinde ise türbinin dönme hızıdır. Bu nedenle sabit bir değeri olmayan bu kaynaklar ile üretim yapan sistemlerin gerilim ve frekans kararlılığını sağlamak adına DÜK'ler ve EDS'ler genellikle gerilim dönüştürücüleri ve gerilim kaynaklı eviriciler ile MŞ'ye bağlanır. Gerilim kaynaklı eviriciler DC gerilimi AC gerilime çevirirken gerilimin genliğini ve frekansını istenilen seviyede sabit tutmayı hedefleyen güç elektroniği sistemleridir. Bununla birlikte dizel jeneratör ve küçük hidroelektrik türbini gibi DÜK'ler direkt olarak şebekeye bağlanabilmektedir (Shuai vd. 2015).

MŞ, ana şebekeye bağlı işletilirken ana şebekeye oranla çok daha küçük hacim kaplaması nedeniyle yük dalgalanmasından kaynaklı gerilim ve frekans dalgalarından etkilenmez. Bu durumda sistem referans olarak ana şebekeyi alır. Ancak MŞ ana şebekeden bağımsız olarak çalıştığında yük dalgalanmasına bağımlı gerilim ve frekans kaymalarını önlemek önem taşır. Özellikle gerilim ve frekans dalgalarından kötü etkilenecek kritik yükleri ve şebekeyi korumak adına MŞ ana şebekedeki önemli bir hata sonrası ortak bağlantı

noktasından ayrılarak kendini bağımsız çalışma bir diğer deyişle ada moduna alabilir (Basak vd. 2012).

DÜ için gerilim ve frekans kararlılığını sağlamak adına voltaj-frekans (V/F) kontrolü, aktif-reaktif güç (PQ) kontrolü ve düşüm (droop) kontrolü ve gibi yöntemler kullanılır. V/F kontrol yönteminde DÜK'ün çıkış geriliminin genliği ve frekansı belirli bir değer referans alınarak belirlenir. V/F kontrol yöntemi genellikle enerjinin kendi içerisinde depolandığı ada tipli MŞ'lerde kullanılırken, MŞ'nin ana şebekeye bağlanması durumunda ise DÜK tarafından üretilen gücün gerilim ve frekans için ana şebekenin değerleri referans olarak alınır. Diğer bir kontrol yöntemi olan PQ kontrolünde ise üretilen aktif ve reaktif gücün belirlenen referans değerinde sabit kalması hedeflenmektedir. Bu yöntemle üretilen gerilimin genliği ve frekansının belirli bir toleransın altındaki değişimi üretilen aktif ve reaktif gücün değerini değiştirmez ve böylece PQ kontrolü sağlanmaktadır. PQ kontrol yöntemi genellikle şebekeye bağlı MŞ'lerde kullanılırken ada tipi mikro şebekelerde yüklerin ani değişimine cevap verebilmek ve kısa zaman aralıklarında yaşanan gerilim ve frekans sapmalarına cevap verebilmek adına DÜK'lerin kontrolü V/F yöntemi ile yapılmaktadır (Wu vd. 2018). Bir diğer kontrol yöntemi olan düşüm kontrolünde ise yükün dalgalanmasına bağlı olarak bir kontrol döngüsü DÜK'lerin çıkış gücünü ayarlamaktadır. Bu kontrol yöntemleri kullanılarak DÜK'ler tarafından üretilen ve şebekeye aktarılan gücün gerilim ve frekans değeri için bir standart oluşturularak DÜK'ler arasında enerji akışının önüne geçilmektedir (Altın ve Eyimaya 2021).

2.3.2 Mikro Şebekelerde Koruma

Mikro şebekelerde koruma geleneksel şebekelere göre farklılıklar göstermektedir. Bu farklar MŞ koruması adına bazı zorlayıcı unsurlar oluşturur. MŞ'lerin ana şebekeye bağlı veya ada modunda çalışması durumundaki arıza akımı seviyelerindeki fark bu zorlayıcı unsurların başında gelir. Ana şebekeye bağlı çalışan MŞ'ler kısa devre anında ana şebekeden yüksek miktarda arıza akımı çekerek koruma sistemleri devreye girerken ada modunda oluşabilecek bir kısa devre anında limitli arıza akımı nedeniyle koruma röleleri arızayı durduramayabilir (Hooshyar ve Iravani 2017).

2.3.3 Mikro Şebekelerde Güç Kalitesi

Güç kalitesi, elektrik sisteminin sağladığı enerjinin uygun voltaj, akım, frekans ve dalga şekli gibi özelliklere sahip olması anlamına gelmektedir. Mikro şebekeler, değişken güç kaynaklarına bağlı olduklarından, güç dalgalanmaları, harmonikler, gerilim düşüşleri ve diğer güç kalitesi sorunları yaşayabilirler. Bu sorunlar, sistem performansını etkileyebilir ve elektrikli cihazların hasar görmesine, hatta arızalanmasına neden olabilir.

Bu nedenle, mikro şebekelerin güç kalitesini iyileştirmek için çeşitli önlemler alınabilir. Bu önlemler arasında güç kalitesi izleme ve analizi, güç faktörü düzeltilmesi, voltaj regülasyonu, harmonik filtreleme ve yalıtım yer alır. Ayrıca, güç kaynaklarının uygun boyutlandırılması, yük dengelemesi ve anahtarlamalı güç elektroniği kullanımı gibi tasarım faktörleri de güç kalitesi sorunlarını önlemeye yardımcı olabilmektedir.

2.4. Elektriksel Yük Tahmini

Elektrik güç sistemlerinde, yük kullanıcılar tarafından talep edilen elektrik enerjisidir. Güç sisteminde üretilen elektrik ve talep edilen elektrik arasında bir denge olmalıdır. Talep edilenden fazla üretilen elektrik, maliyetinden dolayı çoğu zaman depolanamaz. Bu durumda üretilen artık elektrik enerjisi kullanılamaz ve elektrik üretiminde kullanılan hammadde gereksiz yere tüketilmiş olur. Bunun tersine üretilen elektriğin talebin altında olması güç sisteminde kararsızlığa, gerilim ve frekans kaymalarına neden olabilir. Sistemdeki elektriğe olan bu arz ve talep makasın açılması güç sisteminde çökmeye kadar gidebilecek sorunlar doğurabilir. Bu nedenle güç sistemlerinde elektrik talebini belirleme adına yük tahmini kritiktir. Yük tahminleri sonucunda kısa vadede elektrik üretimi ve tüketimi dengesi kurularak hem sistem stabil tutulup hem de artık enerjiden doğan maddi kayıplar daha az seviyelere indirebilir. Orta ve daha uzun vadelerde ise sistemin elektrik tüketim trendi ortaya konularak sistem planlaması yapılabilir. Böylece artan talebi karşılamak adına bir üretim tesisi yatırımı yapılabilir ya da mevcut üretim santralleri ile yapılacak olan enerji tedarik sözleşmeleri planlanabilir.


FV ve rüzgâr enerji sistemlerinin MŞ'lere entegrasyonu ile kullanıcıların hem tüketici hem de üretici olduğu göz önünde bulundurulursa MŞ'nin işletilmesi için yük tahmininin önemi büyüktür. Bir MŞ bünyesindeki yüklerin enerji talebini tahmin ederek bu talebi karşılayabilecek miktarda enerji üreterek dış kaynaklara ihtiyacı kalmadan enerji akışını devam ettirebilir. Bunu sağlayabilmek adına MŞ'de kontrol edilebilir jeneratörlerin günlük devreye alınıp alınmaması ve batarya sistemlerinin şebeke ile yaptığı çift yönlü güç akışı kontrol edilmelidir. Yük tahmini ile jeneratör sistemlerini minimum seviyede aktif ederek ve batarya sistemini verimli bir şekilde kullanarak MŞ'nin elektrik üretim maliyeti azaltılabilir (Querini vd. 2021).

MŞ'deki yükler ertelenebilir ve ertelenemez yükler olarak sınıflandırılır. Ertelenebilir yüklere bulaşık makinası, çamaşır makinası, su pompaları ve yaygınlaşmaya başlayan elektrikli arabalar örnek verilebilir. Ertelenemez yükler ise buz dolabı, derin dondurucu ve aydınlatma sistemleri gibi kullanımı başka bir zaman aralığına kaydırılamayacak yüklerdir (Reka ve Ramesh 2016). MŞ'lerde yenilenebilir enerjinin süreksizliğini gidermek amacı ile aküler, volanlar, süper kapasitörler ve süper iletken manyetik enerji depolama gibi sistemler kullanılmaktadır. Bu EDS'lerin bazı problemleri vardır. Enerji depolama ve talep anında enerji sağlama amaçlı kullanılan aküler maliyetleri, boyutları ve kullanım ömürleri nedeniyle kısıtlı bir kullanım sunmaktadır. Diğer bir EDS olan volan ise elektrik enerjisini bir rotoru döndürerek mekanik enerjiye çevirir. Rotorun devri artarak depoladığı mekanik enerjiyi artırır, yük arttığı zamanda ise sistem volandan elektrik enerjisi çekerek rotorun devrini azaltır ve sisteme elektrik enerjisi aktarır. Süper kapasitörler ise her ne kadar kısa süreli enerji taleplerine hızlı cevap verebiliyor olsa da yüksek kapasiteli ve uzun süreli taleplere cevap veremezler. Bir diğer enerji depolama yöntemi hidroelektrik depolamada ise enerji dönüşümünden faydalanılarak üretilen elektriğin talepten fazla olduğu anlarda bir su hacminin pompalar yardımı ile yüksek seviyelere taşınmasından kazandığı potansiyel enerjiden yararlanılmaktadır. Sistemin enerji talebinin arttığı anlarda ise suyun yüksekten salınarak bir hidroelektrik türbinini çevirmesiyle elektrik talebine cevap verilebilmektedir. Ancak bu yöntemde suyun yüksekliği fazla olan bir bölgede konumlandırılması gerektiği ve suyun bu bölgeye taşınması için gereken pompa ve hazne yatırımından doğan maliyet sistemin kullanılabilirliğini kısıtlamaktadır (Kocaman 2013). EDS'lerdeki kısıtlamalar nedeniyle

MŞ'deki ertelenebilir yükleri talebin daha az olduğu saat aralıklarına çekerek üretim yük dengesi sağlanabilmektedir. Bunu sağlamak adına elektrik sağlayıcıları tarifeli faturalandırmaya geçerek puant yük anında elektrik fiyatını arttırarak ve talebin az olduğu anlardaki fiyatı azaltarak talebe bir denge getirmeyi hedeflemiştir. Bu son kullanıcıları elektrik enerjisini talebin az olduğu saatlere yayarak kullanmaya teşvik ederek talepteki pik noktasını düşürmeyi hedeflemektedir.

Yük tahmini kısa dönem, orta dönem ve uzun dönem olmak üzere farklı zaman aralıkları üzerinden yapılmaktadır. Kısa dönemli yük tahminleri genellikle saatlik tahminler olup elektrik talebinde bir gün veya bir hafta ileriye tahmin etmeyi amaçlar. Özellikle MŞ'lerde DÜ elemanlarının günlük aktivasyonunun belirlenmesi adına önemi fazladır. Böylece kontrol edilebilen kaynaklar ile yapılan elektrik üretimi ihtiyaca göre planlanarak elektrik üretiminden doğan maliyet daha düşük seviyelere düşürülebilmektedir. Ayrıca DÜK'ler için hammadde tedariki ve DÜK'ler ve EDS'lerin bakım ve onarımı için optimum koşullar bu kısa dönem yük tahminine göre planlanabilmektedir (Akman vd. 2018). Orta dönem yük tahmini ise genellikle bir yıla kadar ki süreyi kapsamaktadır. Orta dönem tahmin verileri ise üretilen enerjinin son kullanıcıya satışındaki sözleşme detaylarının belirlenmesinde ve elektrik üretimi için hammadde planlaması yapılmasına ışık tutmaktadır. Ayrıca güç sistemindeki üretim elemanları, iletim hatları ve trafo merkezleri için bakım planlaması yapılabilmesine olanak sağlamaktadır. Uzun dönem yük tahmini ise bir yılı aşkın süreler içindir. Uzun dönem yük tahmini şebekedeki yüklerinin geleceğe dair eğilimi hakkında yorum yapabilmeyi amaçlamaktadır. Böylece yüklerin davranışı ortaya konularak güç sisteminde köklü değişiklikler yapılabilir. Tüketicilerin enerji talebinin bir önceki yıllara göre ivmelenerek artması gibi bir durumda yeni bir enerji üretim santrali planlamak gerekebilir. Büyük çaplı üretim tesislerinin kurulumun gerektirdiği maliyet ve inşa süresi nedeniyle uzun dönem yük tahmin verileri bu tür yatırımların planlamasında önemli rol oynamaktadır (Aslan vd. 2005). Orta ve uzun dönem yük tahminlerinin MŞ'ler özelinde de önemli bir rolü vardır. Ana şebekeye bağlı işletilen MŞ'lerde ana şebeke ile yapılacak olan enerji tedarik sözleşmesinin detaylarını belirlemede bu tahmin verileri önemlidir. Böylece sözleşme dönemi boyunca talep edilecek toplam elektrik enerjisi hakkında bir öngörü yapılarak MŞ için optimum şartlarda enerji tedarik sözleşmesi oluşturulabilir (Querini vd. 2021).


Yük tahmininde bulunurken gerçeğe en yakın tahmini yapabilmek önemlidir. Yük tahmini temelde yükün önceki dönemlerdeki değerlerine göre yapılmasına rağmen bu tahmini yanıltan durumlarda oluşabilir. Örneğin 2019 yılının sonunda etkilerini gösteren Koronavirüs hastalığı küresel anlamda elektrik tüketimini etkilemiştir. Özellikle hastalığın yayılmasını önlemek amacı ile dünya genelinde uygulanan kapanmalarla birlikte sanayi ve hizmet sektöründeki kısıtlamaların sonucunda elektrik tüketimi azalmıştır. Kapanmaların yaşandığı nisan ve mayıs aylarından sonra tüketimin beklenen değerlere yaklaştığı görülmeye rağmen takip eden haziran ve temmuz aylarında elektrik tüketimi önceki yıl olan 2019'a göre %10 ile %5 arasında azalmıştır. Senenin sonunda ise kapanmanın elektrik talebine olan etkileri azalarak talebin beklenildiği gibi geçmiş seneye göre ortalama %8 civarı artış gösterdiği görülmüştür. Şekil 2.4'de Koronavirüs'ün küresel elektrik tüketimine etkisi ifade edilmiştir (IEA 2021).



Şekil 2.4 2020 yılında çeşitli ülkelerin haftalık yük talebinin önceki seneye göre değişimi.

Türkiye için de 2020 ve 2019 yılları arasındaki enerji talebi incelendiğinde dünya geneline benzer bir sonuç görülmüştür. Şekil 2.5(a)' da görüldüğü üzere Türkiye'de

Koronavirüs’e bağlı karantinaların yaşandığı mart ve nisan aylarında elektrik enerjisine olan talep bir önceki yıla göre %20’ye yakın azalmıştır. Haziran ayı ile beraber ise elektrik enerjisi talebi önceki seneye göre artış göstererek yine dünya geneline benzer bir davranış ortaya koymuştur. Benzer şekilde Şekil 2.5(b)’deki grafikten 2021 ve 2020 yılları arasındaki fark incelendiğinde neredeyse sene boyunca elektrik tüketiminde bir artış trendi görülmektedir. Bu durum Türkiye için Koronavirüs kapanmalarının elektrik talebine olan etkisini açıkça ortaya koymuştur. Karşılaştırma yapabilmek adına Şekil 2.5(c)’de ise Koronavirüs’ün elektrik tüketimine etkisinin azaldığı 2022 yılı ile bir önceki yıl olan 2021’in elektrik talep farkı karşılaştırıldığında, tepe noktalarının merkeze daha yakın olduğu ve yıl boyunca talep farkının yaklaşık olarak %5 seviyelerinde değiştiği görülmektedir.




Şekil 2.5 (a) 2020 ve 2019 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi. (b) 2021 ve 2020 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi. (c) 2022 ve 2021 yılları arasında Türkiye’deki brüt elektrik talebinin aylara göre yüzdelik değişimi (Teiaş 2023).


Yük tahminini bu gibi öngörülemez durumların dışında doğruya en yakın şekilde yapabilmek önemlidir. Literatürde yük tahmini ile ilgili birçok çalışma yapılmıştır. Lineer Regresyon (LR) analizi, Zaman Serileri analizi, Destek Vektör Makinaları (DVM) ve Yapay Sinir Ağları (YSA) gibi makine öğrenmesine dayalı algoritmalar sıklıkla yük tahmininde kullanılmıştır.

2.4.1 Yük Tahminini Etkileyen Faktörler

Literatürde bulunan çoğu yük tahmin algoritması tahmin yaparken temelde yükün geçmiş dönem verilerinden yararlanıyor olsa da tahmini etkileyen önemli unsurlar vardır. Takvim etkisi, hava durumu etkisi, ekonomik faktörler ve fiyatlandırma gibi birçok unsur yük tahmininde etkili olabilir. Ayrıca bu faktörlerle beraber tamamen rastgele olarak oluşabilecek durumlarda yük tahminini etkileyebilir. Yük tahmini yapılırken kullanılan algoritmaya yükün tarihsel verisi ile birlikte girdi olarak sunulan bu faktörlerin doğru analiz edilmesi ve sınıflandırılması yapılan tahminin başarı oranını yüksek tutmak adına önemlidir. Bu girdiler sonucunda tahmin başarısı artabileceği gibi ilişkisiz girdiler sonucu tahmin başarısı düşebilir. Takvim etkisi, kısa dönem yük tahmininde en etkili unsurlardan biridir. Bunun nedeni ani değişimlerin olmadığı elektrik talebinin periyodik bir davranış sergiliyor olmasıdır. Şekil 2.6’da farklı yıllar için Türkiye genelindeki saatlik elektrik tüketim verileri incelendiğinde yılların aynı dönemlerindeki elektrik tüketimlerinin benzer olduğu açıkça görülmektedir. Mevsim geçişlerinin etkiler olan sıcaklık farklı, gün içerisindeki güneşlenme süresinin değişmesi gibi nedenler elektrik tüketimini etkiler. Her ne kadar enerji tüketimi her geçen yıl ile birlikte genel bir artış eğiliminde de olsa tüketimin maksimum ve minimum değerleri her yılın benzer dönemlerinde görülmüştür.




Şekil 2.6 2016 ile yıllarındaki Türkiye’deki MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023)



Şekil 2.7 Türkiye’deki farklı altı yıldaki 15 Haziran günü için MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).

Şekil 2.7’de ise 15 Haziran günü için geçtiğimiz son altı yıl için günlük elektrik tüketimi gösterilmiştir. Farklı senelerden alınan bu beş gün için elektrik tüketimi verileri tüm gün boyunca benzer eğilimde olmuştur. Ancak 2018 yılında 15 Haziran gününün Ramazan Bayramı olması nedeniyle tüketimin gün boyunca diğer senelere göre bariz bir şekilde düşük olduğu görülmektedir. Birçok sanayi ve iş yerinin kapalı olmasından kaynaklı özel günlerin elektrik tüketimine etkisi vardır. Bu nedene özel günlerde yük tahminini etkileyen faktörlerden biridir. Şekil 2.8’de 2020 yılının sekiz haftalık bir döneminde Ramazan Bayramı’nı kapsayan haftanın takip eden haftalara göre elektrik tüketiminin daha az olduğu görülmektedir.


Bu durum Dünya’nın farklı coğrafyaları ve kültürleri içinde geçerlidir. National Grid ESO çalışmalarına göre Büyük Britanya’nın 25 Aralık’ta kutlanılan Noel günü elektrik tüketiminin yılın en düşük seviyelerinde olduğu ifade edilmiştir. Okullar, iş yerleri ve fabrikaların kapalı olması nedeniyle elektrik tüketiminde düşüş Türkiye’de ki bir tatille benzer sonuçlar vermiştir (İnt. Kyn. 2).



Şekil 2.8 Türkiye’deki 01.04.2022-31.05.2022 tarihleri arasındaki MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).

Takvimsel faktörlerin bir diğeri ise günlük etkidir. Elektrik tüketiminin gün içerisinde yoğunlaştığı ve azaldığı saatler mevsimden bağımsız olarak benzerlik gösterir. Şekil 2.9’da 2022 yılındaki rastgele altı günün günlük elektrik tüketimi gösterilmiştir. Yaz veya kış fark etmeksizin her bir gün için elektrik tüketiminde saat 24 ile 7 arası düşüş eğilimi görülürken saat 7’den sonra 12’ye kadar genel bir artış görülmektedir. Yüksek elektrik talebi saat 21’e kadar devam ederken 21’den sonra ise tekrardan düşüşe geçmektedir.

Ayrıca günün hafta içi veya hafta sonu oluşundan kaynaklı olarak elektrik talebindeki değişim veya hafta başı olan pazartesi gününün sabah erken saatlerindeki elektrik tüketiminin diğer günlere göre düşük olması gibi haftalık faktörlerde takvimsel olarak yük tahminini etkilemektedir (Cevik vd 2016).



Şekil 2.9 Türkiye’deki 2022 yılına ait altı farklı gün için MWh cinsinde saatlik elektrik tüketimi (Teiaş 2023).

Hava durumu etkisi ise temelde kış aylarında soğuyan havadan dolayı ısıtma için gereken enerji artışı tam tersine yaz aylarında ise ısınan havanın etkisi ile soğutma için gereken enerji ihtiyacı ile ilişkilidir. Literatürde birçok kaynak nem, yağış ve rüzgâr hızı gibi faktörlerinde enerji tüketimine etkisi olduğuna değinmiştir. Havadaki nem miktarının fazla olması yaz aylarının olduğundan daha sıcak hissedilmesine ve dolaylı olarak enerji tüketiminin artmasına sebep olmaktadır. Kar veya yağmur yağışının yoğun olduğu günlerde ise insanların evlerinde kalma eğilimin olduğu ve bu nedenle elektrik tüketiminin arttığı görülmüştür (Fahad ve Arbab 2014).

Ekonomik faktörler ise tüketicilerin türü, ekonomik gelişimi, sosyal durumu gibi tüketicilerin enerji talebine olan yönelimini belirlemektedir. Bu durumlar genellikle uzun soluklu süreçler olup yıllar sonraki enerji trendi hakkında fikir edinilmesine yardımcı olabileceği için genellikle uzun dönem yük tahmini yapmada etkilidir. Ancak kısa dönem tahminleri için yük değişimlerini yakalamada yetersizdir. Fiyatlandırma faktörü ise günün farklı saatlerinde olan enerji talebi doğrultusunda elektrik enerjisinin birim fiyatını farklı tutarak kullanıcıları elektrik kullanımının yoğun olmadığı saatlerde elektrik kullanmaya teşvik eden etkinin sonucudur. Ülkemizde de gündüz, puant ve gece olmak üzere üç farklı tarife ile elektrik satılarak puant yük azaltılmak istenmiştir (Singh vd. 2014).

2.4.2 Tahmin Algoritmaları


Literatürde yük tahmini genellikle istatistiksel yöntemler olan zaman serileri, makine öğrenmesi yöntemleri ve farklı modellerin birlikte kullanımından türeyen hibrit yöntemler ile yapılmıştır. Bu çalışmada makine öğrenmesine dayalı farklı tahmin algoritmaları incelenerek başarı oranları karşılaştırılmıştır.

2.4.2.1 Lineer Regresyon Analizi

Basit lineer regresyon (BLR) modeli tek bir bağımsız değişken ile bir bağımlı değişken arasındaki doğrusal ilişkiyi ifade ederek bağımsız değişkenin değerini bağımlı değişkene atanan değerler yardımı ile tahmin edilmesini amaçlar. BLR denklem (2.1)'de ifade edildiği üzere


$$y = \beta_0 + \beta_1 x + \varepsilon \quad (2.1)$$

y bağımlı yanıt (response) değişkeni, x bağımsız bağlayıcı (regressor) değişkeni, β_0 ve β_1 bilinmeyen sabitler, ε rastgele hata bileşeni olmak üzere modellenir. Regresyon katsayıları olarak da adlandırılan β_0 ve β_1 değerleri regresyon modelini hakkında yorum yapmaya olanak sağlar. β_1 katsayısı regresyon doğrusunun eğimini ifade eder ve x değişkenleri tarafından türetilen y değerlerinin dağılımının ortalama değişimini ifade etmektedir. Eğer x değişkenlerinin $x = 0$ için y değeri biliniyorsa β_0 katsayısı yani eksen kesme değeri y değerinin dağılımının ortalamasıdır. Şekil 2.10'da bir veri grubunu için oluşturulan regresyon doğrusu görülmektedir (Montgomery vd. 2013).



Şekil 2.10 LR doğrusu.

LR doğrusunu belirlemek için literatürde en küçük kareler yöntemi (EKK) kullanılır. EKK yöntemi veri setindeki gerçek veriler ile tahmin edilen verilerin arasındaki sapma miktarının (residual) karesini en aza indiren doğruyun oluşturulmasını amaçlar. Şekil 2.11’de sapma miktarları üzerinden EKK yöntemi ile oluşturulan regresyon doğrusu görülmektedir.



Şekil 2.11 EKK yöntemi ile oluşturulmuş regresyon doğrusu.

Çizilen doğrunun denklemi belirlenerek doğrunun eğimi olan β_1 parametresi ve y eksenini kestiği nokta olan β_0 parametresi ifade edilmiş olur.

$$\beta_1 = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sum(x_i - \bar{x})^2} \quad (2.2)$$

$$\beta_0 = \bar{y} - \beta_1 \bar{x} \quad (2.3)$$

Burada x_i bağımsız değişkenleri, $\bar{x}$ bağımsız değişkenlerin ortalamasını, y_i bağımlı değişkenleri, $\bar{y}$ bağımsız değişkenlerin ortalamasını ifade etmektedir. Büyük veri setlerinde bu parametrelerin belirlenebilmesi için bilgisayarın ve makine öğrenmesi kavramının önemi büyüktür. Regresyon katsayıları belirlendikten ve bağımsız değişkenler ile birlikte modele yerleştirildikten sonra tahmin fonksiyonu oluşturulmuş olur.

LR’de yük tahmininde olduğu gibi tahmini etkileyen birçok bağlayıcı değişkenin modellenenebilmesi için çoklu lineer regresyon (ÇLR) modeli kullanılır. Bu durumda birden fazla etmenin cevap değişkeni üzerindeki etkisi tek bir regresyon modeli ile ifade edilebilir.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (2.4)$$

Burada y basit regresyonda olduğu gibi cevap değişkenini ifade ederken x_1 cevabı etkileyen ilk bağlayıcı değişkeni, x_2 ise ikinci bağlayıcı değişkeni ifade eder. β_0 , β_1 ve β_2 ise değişkenlerin sabit katsayılarıdır.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \varepsilon \quad (2.5)$$

ÇLR modelinde bağımsız değişken sayısı tahmini etkileyen faktörlerin sayısı kadar artırılabilir. Bu durumda n değişken için model denklem (2.5)’teki gibi evrilir.

2.4.2.2 Gauss Süreç Regresyonu

Gauss Süreç Regresyonu (GSR), bir sistemin girdileri ve çıktıları arasındaki ilişkiyi modellemeye yönelik parametrik olmayan çekirdek (kernel) tabanlı olasılıksal bir yaklaşımdır. Parametrik olmamalarının nedeni fonksiyonun parametrelerini bir modele uyarlamaya çalışmak yerine ölçülen tüm verilerin ilişkisini modellemeye çalışmasıdır (30-Melo 2012). Temelleri Williams ve Rasmussen tarafından oluşturulan GSR, öğrenilecek işlevden önce bir Gauss süreci ve işlev üzerinde bir sonsal dağılım oluşturmak için bir olasılık işlevi kullanılmaktadır (Rasmussen ve Williams 2006).

GSR N çift x_n d boyutlu giriş vektörü değişkeni ve y_n tek boyutlu gürültülü yanıt değişkeninden oluşan vektör ise $D = \{(y_n, x_n), n = 1, \dots, N\}$ $x \in R^d$, $y \in R$ şeklinde ifade edilen veri seti regresyonu eğiten giriş parametresi olarak kullanır ve ölçüm hatalarından ve yuvarlamalardan kaynaklı oluşabilecek gürültü de göz önünde bulundurularak tahmin çıktısının belirlenemeyen girdi konumlarındaki dağılımını ifade eden bir model oluşturulmuştur (Wan ve Sapsis 2017).

$$y = f(x) + \varepsilon \quad \varepsilon \approx N(0, \sigma_{noise}^2) \quad (2.6)$$

Denklem (2.6)'da σ_{noise}^2 gürültünün varyansını ifade ederken gürültünün toplamsal sıfır ortalamalı ve normal dağılımlı olduğu varsayılırken, y yanıt değişkenini ve x giriş değişkenini ifade eder. Bir $f(x)$ fonksiyonu rastgele girdiler ile denklem (2.7)'deki gibi gösterilir.

$$f(x) = GP(m(x), k(x, x')) \quad (2.7)$$

Burada $k(x, x')$ kovaryans fonksiyonu (kernel) ve $m(x)$ ise ortalama vektörü ifade eder. Ortalama vektörü denklem (2.8)'da ki gibi ifade edilirken kernel fonksiyonu veri setinin yapısına göre farklılaşabilir.

$$m(x) = \mathbb{E}[f(x)] \quad (2.8)$$

En yoğun kullanılan ve denklem (2.9)'da gösterilen kare üstel kernel verilerin artan hızla arttığı veri setlerinde ve ekonomik veya biyometrik modeller ile kullanılır.

$$k(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (2.9)$$

Bir başka kernel olan rasyonel kuadratik bir rasyonel fonksiyonun kare üstel bir türevi olduğu modeldir. Genellikle yüksek boyutlu veri setleri için kullanılır. Denklem (2.10) bu model için kernel fonksiyonunu ifade etmektedir.

$$k(x, x') = \left(1 + \frac{d(x, x')^2}{2\alpha l^2}\right)^{-\alpha} \quad (2.10)$$

Üstel kernel ilişkisiz ve doğrusal olmayan veriler arasındaki ilişkiyi ifade etmekte iyidir. Genellikle makine öğrenmesi ve veri madenciliğinde kullanılmaktadır. Denklem (2.11) üstel kernel fonksiyonunu ifade etmektedir.

$$k(x, x') = \exp\left(-\frac{\|x - x'\|}{2\sigma^2}\right) \quad (2.11)$$

Matern 5/2 iki veya daha fazla parametre ile özelleştirilmiş bir kernel fonksiyonudur. Denklem (2.12)'de ifade edilen fonksiyon genellikle geostatik ve finansal modellemelerde kullanılmaktadır.

$$k(x, x') = \sigma^2 \left(1 + \gamma\sqrt{5}d\left(\frac{x}{l}, \frac{x'}{l}\right) + \frac{5}{3}\gamma^2 d\left(\frac{x}{l}, \frac{x'}{l}\right)^2 \right) \exp\left(-\gamma\sqrt{5}d\left(\frac{x}{l}, \frac{x'}{l}\right)\right), v = \frac{5}{2} \quad (2.12)$$


Görüldüğü üzere özelleşen kernel fonksiyonları ile oluşturulan farklı GSR modelleri tahmin veya sınıflandırma yapacağı veri yapılarına göre farklı başarı oranlarına sahip olacaktır. Bu nedenle çalışılan veri setinin özelliklerine uygun kernel fonksiyonunu belirlemek önemlidir.

2.4.2.3 Regresyon Ağacı

Regresyon ağacı (RA), karar ağacı adı verilen modelin regresyon uygulamaları için türetilmiş halidir. Karar ağacı ilk olarak 1960'lı yıllarda kullanılmaya başlamıştır. Bu model ağaç yapısına benzeyen bir dallanma sistemi ile verilerdeki desenleri keşfeder. Model bir kök düğümden başlar ve ardından dallanarak iç düğümleri oluşturur. Her iç düğüm kendi içerisinde belirli özelliklere göre sınıflandırılır ve en sonunda yaprak bölümüne ulaşılır ve veriler ayrıştırılır (Demirel vd. 2019).

Breimen ve arkadaşları bir hastanedeki kalp krizi hastaların ilk yirmi dört saatteki verilerine göre hayati risklerini belirlemek için bir karar ağacı modeli sunmuşlardır. Model belirli parametrelere evet veya hayır cevaplarını vererek yüksek veya düşük risk olan sonuçlara götürmektedir. Şekil 2.12 bu karar ağacı modelini göstermektedir. Yöneltilen sorulara verilen cevaplara göre hastanın yüksek risk grubunda olması 'G' harfi ile düşük risk grubunda olması 'F' harfi ile ifade edilmiştir (Breiman 1984).

Karar ağacı modeli, verileri bölerek karar verme sürecini basitleştirir ve doğrusal olmayan ilişkileri modelleyebilir. Ayrıca diğer makine öğrenimi tekniklerine kıyasla daha kolay anlaşılabilir ve yorumlanabilir olması nedeniyle popüler bir yöntemdir




Şekil 2.12 Kalp krizi hastalarını risk oranına göre sınıflandıran karar ağacı modeli.

RA, bağımlı değişkenin bir veya daha fazla bağımsız değişkene bağlı olarak tahmin edilmesine yardımcı olan bir makine öğrenmesi algoritmasıdır. Regresyon ağaçları, karar ağaçlarına benzer şekilde ağaç yapısı kullanır, ancak bu ağaçların dalları, bağımsız değişkenlerin bölünmesine dayanır ve her dalın sonunda bir regresyon (tahmin) değeri verilmektedir.


RA modeli, veri setindeki bağımlı değişkenin değerini tahmin etmek için kullanılır. Bu amaçla, öncelikle, bağımlı değişkenin tahmin edilmesine en çok katkıda bulunan bağımsız değişken belirlenir ve bu değişkenin veri setindeki değerleri, belirli bir eşik değeriyle bölünür. Daha sonra, bu alt gruplara ayrılmış veriler üzerinde aynı işlem yapılır, alt gruplar daha küçük gruplara bölünür ve bu işlem sonlanana kadar devam etmektedir.

RA modelini ve regresyon değerini görebilmek adına Şekil 2.13’de temsilen bir ilacın kullanılan dozajına karşı etkinliğini veren bir grafik verilmiştir. Bu modelde veriler lineer değildir ve ilacın dozajı arttıkça ilacın etkinliği paralel olarak artmaz. Bununla birlikte 14 – 29 mg aralığı ilaç verimliliği açısından ideal aralık olarak görülmektedir (İnt. Kyn. 7).



Şekil 2.13 Dozaj ve ilaç verimliliği ilişkisi

Bu veri seti regresyon ağacı modeline uygulandığında karar ağacından farklı olarak her bir yaprak bir regresyon değerine sahip olur. Böylece veriler sınıflandırılmış olur ve model kullanılarak yapılacak tahminler için bir cevap değeri elde edilmiş olur. Bu sisteme ait RA Şekil 2.14’de ifade edilmiştir.



Şekil 2.14 Dozaj miktarına göre ilacın etki oranını belirten regresyon ağacı modeli.

Sınıflandırma ağacı ve regresyon ağacı modelinde en zorlayıcı unsur karşılaştırma parametrelerinin çok olduğu karmaşık veri setlerinde kök ve gövdeyi oluşturan düğümler için doğru yapıyı oluşturmaktadır. Bu yapıyı en doğru şekilde oluşturmak adına safsızlık ölçütü olarak adlandırılan Gini indeksi ve Twoing kuralı gibi algoritmalar geliştirilmiştir. Gini indeksi, bir örnek kümesinin saflık derecesini ölçer. Değeri “0” yani tüm örnekler aynı ile “1” yani örnekler sınıflar için eşit bölünmüş arasında değişir. İki alt kümenin ağırlıklı Gini endeksinin toplamı en düşük olan bölünme, en iyi bölünme olarak seçilir. Twoing kuralında ise her düğümde en iyi bölünmeyi belirlemek adına iki alt kümedeki pozitif örneklerin oranındaki farka bakılır. Alt kümeler arasındaki oran farkı en yüksek olan bölünme, en iyi bölünme olarak seçilir.

Sınıflandırma ağaçları, kategorik yanıt değişkenleri için tasarlanmıştır ve bu değişkenlerin sınıflandırılması veya tahmin edilmesi amaçlanmaktadır. Ancak regresyon ağaçları, sürekli yanıt değişkenleri için tasarlanmıştır ve bu nedenle Gini indeksi ve Twoing kuralı gibi sınıflandırma ağaçlarında kullanılan ölçütler, regresyon ağaçlarında kullanılmaz. Bunun yerine, regresyon ağaçlarında LR ile benzer olarak EKK gibi diğer yöntemler kullanılır. EKK, sürekli yanıt değişkenleri arasındaki ilişkiyi belirlemek için kullanılır ve veriyi homojen alt gruplara ayırmayı hedefler. EKK’de amaç öngörülen değerlerle yanıt değişkeninin gerçek değerleri arasındaki kare farklarının toplamını minimize eden bölümü seçmektir (Özkan 2012).


Regresyon ağacının derinliğine ve düğümlerinin yapılarına göre ayrılan üç farklı algoritma vardır. Bunlar kaba ağaç (coarse tree - CS), orta ağaç (medium tree - MT) ve ince ağaç (fine tree - FT) olarak adlandırılmaktadır. CS modeli, regresyon ağacının en basit halidir ve daha az dallanma yani değişken kullanmada limitleme anlamına gelir. MT modeli, CS'den daha karmaşık bir ağaç yapısına sahiptir. Bu model daha fazla değişkenin kullanıldığı ve ağacın daha derin bir maksimum derinliğe sahip olduğunu göstermektedir. FT modeli, regresyon ağacının en karmaşık halidir. Bu modelin daha fazla esnek hale gelmesine ve verilerdeki daha ince ayrıntıları modellemesine izin verir. Ancak FT modeli aşırı uyuma daha yatkındır ve daha büyük veri setlerinde daha uzun süreler gerektirebilir (Ren vd 2020).

2.4.2.4 Destek Vektör Regresyonu


Destek Vektör Regresyonu (DVR) veriler arasındaki ilişkiyi tanımlayarak belirli bir hedef değişkeni ile bağımsız değişken arasındaki ilişkiyi kullanarak hedef değişkenine ulaşmayı amaçlar. DVR Vapnik tarafından geliştirilen Destek Vektör Makineleri (DVM) algoritmasının Smola ve diğerleri tarafından regresyon uygulamaları için uyarlanmış halidir (Smola ve Schölkopf 2004).

DVM, GSR ile benzer şekilde kernel tabanlı olarak veriler arasındaki parametrik olmayan ilişkiyi modellemekte kullanılmaktadır. Temelleri 1990'lı yıllara dayanan bu makine öğrenme tekniği ikili sınıflandırma (binary classification) ve çoklu sınıflandırma (multi-class classification) problemlerini çözmek için kullanılmaktadır.

Görüntü verilerini sınıflandırma, metin sınıflandırma, genom analizi ve finansal verilerin analizi gibi birçok farklı alanda verileri kategorize etmekte DVM yönteminden faydalanılabilir. Şekil 2.15'de ikili ve çoklu sınıflandırma örneği görülmektedir.



Şekil 2.15 İkili ve çoklu sınıflandırma örneği.




Şekil 2.16 Lineer sınıflandırma ve lineer olmayan sınıflandırma temsili (Kowsari vd 2019).

DVM ile modellenecek veriler lineer bir yapıda veya lineer olmayan bir yapıda ayrılabilir. Lineer ayrılma durumunda sınıflandırılacak veri türleri bir doğru ile sınıfsal olarak ayrılabilirken bunun mümkün olmadığı durumlarda lineer olmayan bir sınıflandırıcı kullanılabilir. Şekil 2.16’de lineer ve lineer olmayan şekilde sınıflandırma yapılan veri seti gösterilmektedir. Bu veri seti için lineer sınıflandırma yapıldığında üçgenler ve daireler ile temsil edilen farklı iki gruptan sarı renk ile gösterilen veriler hatalı grupta yer almaktadır. Buna benzer birbiri içerisine girmiş verileri lineer olmayan bir sınıflandırıcı ile modellemek verilerin yanlış gruplar içerisinde ifade edilmesinin önüne geçmektedir. Şekil 2.17’de iki boyutlu bir veri setinde kesintisiz çizgi şeklinde görülen ve veri setini gruplara ayıran doğru hiper düzlem olarak ifade edilir. Kesikli çizgiler ile ifade edilen bölge ise marjin olarak adlandırılır ve hiper düzlem ile ayrılan farklı iki veri grubundan her bir grup için en yakın veri referans alınarak oluşturulur.

Hiper düzlemi ifade etmek adına eğitim veri seti $\{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \subset X \times R$ şeklinde tanımlanan ve X ’in uzaydaki giriş düzenini ifade ettiği varsayılırsa DVR her bir x reel sayısına karşılık gerçek değerinden en fazla sapmaya (ϵ) sahip y çıktı elemanını veren ve aynı zamanda en düz olan $f(x)$ fonksiyonunu bulmayı amaçlar. Gerçek değer ile tahmin değeri arasındaki fark ϵ değerinden küçük ise hata tolerans içerisinde kabul edilirken bu değerden büyük hatalar toleransın dışında kalmaktadır. $f(x)$ fonksiyonu denklem (2.13)’teki gibi tanımlanır (Smola ve Schölkopf 2004).

$$f(x) = w^T \phi(x) + b \quad (2.13)$$

Burada $f(x)$ tahmin fonksiyonudur, w ağırlığı ifade eder, $\phi(\cdot)$ eğitim verilerinin kernel uzayına dönüşümünü ifade eden bir fonksiyondur ve b ise sapma miktarıdır.



Şekil 2.17 Hard ve soft marjin özellikleri.

Veri setine göre marjin iki farklı çeşitte oluşabilir. Bu nedenle sert (hard) marjin ve yumuşak (soft) marjin kavramları doğmuştur. Hard marjinde verilerin tamamı sınıflandırılır ve verilerin ayrımı keskin ve nettir. Soft marjinde ise veriler marjinin dışına çıkarak birbirini içerisine geçmiştir ve sınıflandırılması daha zordur.

Şekil 2.17’de düz çizgi olarak gösterilen hiper düzlem $w^T x - b = 0$ doğrusu ile ifade edilir, w bu hiper düzlemin normalidir. Marjin genellikle hiper düzleme göre ± 1 değerinde bir ofset referans alınır. Bu marjin $\frac{2}{\|w\|}$ olarak ifade edilir. DVR Marjin bölgesini maximize ederek hata oranını en aza indirmeyi amaçlar. Bu amaçla marjini ifade eden $\frac{2}{\|w\|}$ değerini maximize etmek için $\|w\|$ değerini minimize etmek gerekir. Hard marjin için denklem (2.14)’de görüldüğü üzere denklem (2.15)’teki kısıtlamalar göz önünde bulundurularak verileri en düzgün şekilde modelleyen DVM için uygun w ve b parametrelerine ulaşılmış olur (Smola ve Schölkopf 2004).

$$\text{Minimizasyon} \quad \frac{1}{2} \|w\|^2 \quad (2.14)$$


$$\text{Kısıtlamalar} \quad \begin{cases} y_i - w^T \phi(x_i) - b \leq \varepsilon \\ w^T \phi(x_i) - y_i + b \leq \varepsilon \end{cases} \quad (2.15)$$

Soft marjinde ise marjinin dışında kalan verileri ifade etmek gerekir. Bu nedenle modele hatayı ifade eden C parametresi eklenir. Bu durumda DVR modeli denklem (2.16)’deki şekline evrilir. Kısıtlamalar ise benzer şekilde denklem (2.17)’de görülmektedir.

$$\text{Minimizasyon} \quad \min_{w,b,\xi_i,\xi_i^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (2.16)$$

$$\text{Kısıtlamalar} \quad \begin{cases} y_i - w^T \phi(x_i) - b \leq \varepsilon + \xi_i^*, & i = 1, \dots, N \\ w^T \phi(x_i) - y_i + b \leq \varepsilon + \xi_i, & i = 1, \dots, N \\ \xi_i, \xi_i^* \geq 0, & i = 1, \dots, N \end{cases} \quad (2.17)$$

N veri setindeki eleman sayısıdır. C değeri hata derecesini belirleyen sabittir. Düz bir $f(x)$ regresyon fonksiyonu elde edebilmek için w değeri olabildiğince en küçük değeri almalıdır. ξ_i ve ξ_i^* ise slack değişkenleri olarak adlandırılır. Veri setindeki ε değerinin dışındaki verileri modeller. ξ_i ε 'nin altındaki sapmayı gösterirken, ξ_i^* ise ε 'nin üzerinde kalan sapmayı temsil eder. Şekil 2.18'de kırmızı noktalar $f(x) + \varepsilon$ ve $f(x) - \varepsilon$ ile gösterilen marjinin dışında kalan verilerdir (GroB vd. 2021).



Şekil 2.18 Lineer olmayan destek regresyonu (35- Sarraf 2021).

Denklem (2.16)'yı daha kolay ifade edilebilmek adına Lagrange çarpanı metodu uygulanarak denklem (2.18)'deki haline döndürülmüştür.

$$\left[-\frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x, x') - \varepsilon \sum_{i=1}^m (\alpha_i - \alpha_i^*) + \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) \right] \quad (2.18)$$

$$\text{Kısıtlamalar} \quad \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \text{ ve } \alpha_i, \alpha_i^* \in [0, C] \quad (2.19)$$

Burada α_i ve α_i^* Lagrange çarpanları olarak adlandırılır. $\langle x, y \rangle$ ise kernel fonksiyonunu ifade eder.

DVR metodunda da aynı GPR’da olduğu gibi çeşitli kernel fonksiyonları ifade edilmiştir. En yaygın fonksiyonları olan lineer kernel, polinom kernel, radyal taban fonksiyonu kernel ve sigmoid kernel veriler arasındaki ilişkiyi modelleyebilmek adına farklı veri setleri için özelleştirilmiştir.

$$k(x, x') = x \cdot x' \quad (2.20)$$

Lineer kernel en genel ve basit olan kernel fonksiyonu olup değişkenler arasındaki ilişkinin doğrusal olduğu, yani verinin yaklaşık olarak doğrusal olarak ayrılabilir olduğu veri setleri için uygundur. Ayrıca, çok sayıda özellik ve nispeten az veri noktasına sahip veri kümeleri için iyi bir seçimdir. Denklem (2.20)’de lineer kernel fonksiyonu ifade edilmiştir (Ren vd. 2016). Verilerin lineer olmadığı verileri modellemek için lineer kernel dışında lineer olmayan kernel tipleri de türetilmiştir.

$$k(x, x') = (\gamma(x \cdot x') + c)^d \quad (2.21)$$

Polinom Kernel, değişkenler arasındaki ilişkilerin doğrusal olmayan olduğu veriler için uygundur. Orta ila yüksek düzeyde doğrusal olmayan özellik gösteren veri kümeleri için en uygun seçenektir. Polinom çekirdeğin derecesi d ile ifade. Denklem (2.21)’de polinom kernel fonksiyonu ifade edilmiştir. Polinom kernelde çekirdeğin derecesi yani d değeri iki olursa fonksiyon kuadratik kernel ismini alırken üç olma durumunda ise kübik kernel olarak adlandırılmaktadır (Ren vd. 2016).

$$k(x, x') = \exp(-\gamma|x - x'|^2) \quad (2.22)$$

Radyal taban fonksiyonu (RTF) kernel, doğrusal olmayan veriler için uygun bir seçenektir. Ayrıca, az sayıda özellik ve çok sayıda veri noktasına sahip veri kümeleri için de uygun bir seçenektir. RTF çekirdeğinin gama parametresi (γ), çekirdeğin genişliğini kontrol eder ve değişkenler arasındaki ilişkilerin karmaşıklığına göre seçilmelidir. Fine Gaussian, medium gaussian ve coarse gaussian kernel tiplerinde RTF kernel formülü kullanılır. Gama parametresinin büyüklüğü bu üç tip arasındaki farkı oluşturur. Fine gaussian en küçük γ değerlerinde çalışırken medium ve coarse tipi için γ değeri giderek

artar. Böylece fine gaussian kernel daha pürüzsüz sınırları olan bir karar sınırı sağlarken coarse gaussian daha keskin bir karar sınırı sağlamaktadır. Bu denklem (2.22)'de RTF kernel fonksiyonu ifade edilmiştir (Ren vd. 2016).

$$k(x, x') = \tanh(\gamma(x \cdot x') + c) \quad (2.23)$$

Sigmoid kernel, değişkenler arasındaki ilişkilerin doğrusal olmayan olduğu veriler için uygundur, ancak diğer çekirdek fonksiyonlarına göre daha az kullanılmaktadır. Denklem (2.23)'de sigmoid kernel fonksiyonu ifade edilmiştir (Ren vd. 2016).


Uygulamada, farklı çekirdek fonksiyonlarını denemek ve veri kümesine ve problem özelliğine göre performanslarını karşılaştırmak genellikle iyi bir fikirdir. Çapraz doğrulama ve hiperparametre ayarı, farklı çekirdek fonksiyonlarının performansını değerlendirmek ve probleme en iyi uygun olanı bulmak için kullanılabilir (Yılmaz ve Kasapbaşı 2021).

2.4.2.5 Yapay Sinir Ağları

Yapay sinir ağları (YSA) veya sinir ağları (SA), biyolojik merkezi sinir hücreleri yani nöronlardan esinlenerek oluşturulan sınıflandırma, örüntü, tanıma ve tahmin gibi birçok farklı uygulamada kullanılabilen makine öğrenmesine dayalı bir veri analiz algoritmasıdır (Var ve Türkay 2014). YSA kavramı, 1943 yılında Warren McCulloch ve Walter Pitts tarafından ortaya atılmıştır. Yayınladıkları makalede, bir sinir hücresinin diğer sinir hücreleriyle olan etkileşimlerinin matematiksel bir modellemesi sunulmuştur. Bu model, YSA'nın temel yapısını oluşturmaktadır (McCulloch ve Pitts 1943).


YSA genellikle bir girdi katmanı, bir çıktı katmanı ve bir veya daha fazla gizli katmandan oluşmaktadır. Girdi katmanı, veri setindeki her bir özelliğin bir nörona bağlandığı yerdir. Çıktı katmanı, modelin tahmin ettiği çıktıyı temsil etmektedir. Her nöron, modelin çıkışına bir katkı sağlar. Gizli katmanlar, modelin verilen girdiye dayanarak bir sonraki katmanın aktivasyonlarını hesaplamak için ağırlıkları ayarladığı yerlerdir. Bu katmanlar, modelin özellikleri arasındaki ilişkileri öğrenmesine yardımcı olurlar. Her gizli

katmandaki nöron sayısı, modelin karmaşıklığını belirleyen parametredir. Daha fazla gizli nöron, modelin daha karmaşık ve esnek hale gelmesine neden olabilir, ancak aynı zamanda aşırı öğrenme (overfitting) riskini de artırabilir. Aşırı öğrenme ağın eğitim verilerini çok iyi genellemesine rağmen tekrar edilmeyen giriş değişkenlerine başarısız çıktılar vermesidir. Bu nedenle SA için doğru nöron sayısını belirlemek önemlidir (Bejani ve Ghatee 2021).



Şekil 2.19 YSA modeli için aşırı öğrenme ve en uygun karmaşıklık durumu (Bejani ve Ghatee 2021).

Şekil 2.19’da farklı nöron sayıları için eğitilen SA, eğitim veri setinde dört nöronlu yapıdan sonra çıktı ile gerçek değer arasındaki kaybı minimize etmesine rağmen test verileri için alınan sonuçlarla gerçek değerler arasındaki kayıp miktarı azalmak yerine artışa geçmektedir. Bu durum dört nörondan sonrası için modelin aşırı öğrenmeye geçtiği anlamını taşımaktadır. Model için en uygun karmaşıklık düzeyini belirleyebilmek adına eğitim ve test verileri için kayıp miktarının ortak olarak düşük seviyelere indiği nöron sayısı seçilebilir. İleri besleme (feed forward) olarak ifade edilen YSA yapısında tek yönlü bir sinyal akışı vardır. Giriş değerleri tek katmanlı veya çok katmanlı oluşu fark etmeksizin gizli katmandaki nöronlara iletilir. Çok katmanlı yapılarda giriş katmanından alınan veriler yine katmanlar arasında tek yönlü bir şekilde işlenirken son olarak çıkış katmanı ile çıktı değeri oluşturulur.



Şekil 2.20 YSA yapısı (Juan vd. 2022).

Şekil 2.20'deki modelde $x_1, x_2, \dots, x_n$ giriş değerlerini ifade ederken bu değerler her bir değere ait $w_1, w_2, \dots, w_n$ ağırlıkları ile çarpılarak bir toplama işleminden geçirilir (denklem (2.24)). Bu ağırlıklar SA modeli üzerindeki her bir girdinin etkisini ifade eden parametrelerdir. Elde edilen toplam bir aktivasyon fonksiyonundan geçirilerek y çıkış değerine ulaşılmış olur. Ayrıca b ile gösterilen sapma (bias) değeri tüm girdi değerlerinin sıfır olma durumunda bir çıkış elde edebilmek amacı ile toplama eklenir. Böylece YSA modelinin matematiksel modeli ifade edilebilir (Olvera 2022).

$$z = \sum_{i=1}^n (x_i w_i) + b \quad (2.24)$$

Girdi değerlerinin ağırlıklar ile çarpılarak toplamından elde edilen ve ağırlıklı toplam olarak ifade edilen z , denklem (2.25)'de $\sigma(\cdot)$ olarak gösterilen aktivasyon fonksiyonundan geçirilerek y çıktı değeri elde edilir.

$$y = \sigma(z) \quad (2.25)$$

Aktivasyon fonksiyonları, YSA'da kullanılan sinir hücrelerinin çıkışını belirler ve bu nedenle YSA'nın performansını etkiler. YSA'da kullanılan en yaygın aktivasyon fonksiyonları arasında lineer, sigmoid, tanh, doğrultulmuş lineer birim (rectified linear unit – ReLU), eksponansiyel doğrusal birim (exponential linear unit – ELU) ve softmax fonksiyonları bulunur. Bu fonksiyonlar, YSA'nın farklı uygulamalarında kullanılır ve farklı özelliklere sahiptir. Lineer fonksiyon basit yapısı ile girdinin aynı şekilde çıkışa

aktarılmasını sağlamaktadır. Sigmoid girdiyi minimize ederek 0 ile 1 arasında ifade eder bu fonksiyon genellikle ikili sınıflandırmada kullanılmaktadır. TanH fonksiyonu sigmoide benzer şekilde girdiyi -1 ile 1 arasında minimize eder. ReLU girdinin sıfırdan küçük olması durumunda sıfırı, sıfırdan büyük olması durumunda ise kendisini çıkış olarak verir. ELU, ReLU fonksiyonu ile benzer yapıdadır ancak sıfırın altındaki değerler için bir eğri oluşturur, ELU fonksiyonu karmaşık yapısı ile ReLU'ya göre daha iyi sonuçlar verebilir. Softmax aktivasyon fonksiyonu çoklu sınıflandırma problemlerinde kullanılır. Girdiler, 0 ile 1 arasında bir değere dönüştürülerek toplamaları 1 olacak şekilde normalize edilir (Bircanoğlu ve Arıca 2018). Çeşitli aktivasyon fonksiyonları Çizelge 2.1'de ifade edilmiştir.

Çizelge 2.1 Aktivasyon fonksiyonları.

Fonksiyon İsmi	Fonksiyon $\sigma(\cdot)$
Lineer	$\sigma(z) = z$
Sigmoid	$\sigma(z) = \frac{1}{1 + e^{-z}}$
TanH	$\sigma(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$
ReLU	$\sigma(z) = \begin{cases} 0 & \text{eğer } z < 0 \\ z & \text{eğer } z \geq 0 \end{cases}$
ELU	$\sigma(z) = \begin{cases} \alpha(e^z - 1) & \text{eğer } z \leq 0 \\ z & \text{eğer } z > 0 \end{cases}$
Softmax	$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$

YSA'nın modern kullanımı ve gelişimi, 1980'lerde Rumelhart ve arkadaşları tarafından geliştirilen geri yayılım (backpropagation) algoritması olarak adlandırdıkları yöntem ile başlamıştır. Geri yayılım algoritması, ağıın tahmin çıktıları ile gerçek çıktılar arasındaki hata farkını minimize edebilmek amacı ile ağıdaki ağırlıkları sürekli şekilde ayarlar. YSA'nın eğitimini hızlandıran ve doğruluğunu artıran bu algoritma sayesinde, YSA'lar birçok uygulama alanında kullanılmış ve popüler hale gelmiştir (Rumelhart vd. 1986).

Veri seti YSA modeli uygulanırken genellikle üç sınıfa ayrılır. İlk kısım olan eğitim (train) veri setinde modeli eğitmek için kullanılan veriler bulunur ve bu veriler üzerinden ağırlıklar ve katsayılar hesaplanır. İkinci kısım olan validasyon (validation) bölümü eğitim verilerinden bir kısmını içerir ve model parametrelerinden iyileştirme yaparak optimum parametrelere ulaşılmaya çalışılır. Son kısım olan test veri setinde ise test veri setinde ise modelin verimliliği test edilir. Bu bölümde tahmin verileri ile gerçek veriler karşılaştırılır.

Levenberg-Marquardt (LM), Bayesian regularization (BR) ve Scaled Conjugate Gradient (SCG) YSA'ların eğitiminde yaygın olarak kullanılan optimizasyon algoritmalarıdır. LM algoritması ağırlık hata fonksiyonunu minimuma indirmek için iteratif bir yöntem kullanır. Bu yöntemde, bir hata fonksiyonu hesaplanır ve bir dizi ağırlık güncellemesi yapılır. Algoritma, güncellemelerin hatanın azalmasına neden olması durumunda ağırlıkları artırırken, hatanın artmasına neden olması durumunda ağırlıkları azaltır. Bu yöntem, özellikle büyük boyutlu ve karmaşık YSA'ların eğitiminde kullanılır. BR ise YSA'nın eğitimi sırasında, ağırlık vektörüne prior bir dağılım ekleyerek aşırı uyumu engellemeyi amaçlar. Bu dağılım, ağırlıkların bir arada bulunabileceği olası bir değer aralığı belirler. Bu yöntem, aşırı uyumu azaltarak daha iyi genelleştirme yapılmasını sağlar. SCG algoritması, ağırlık hata fonksiyonunu minimuma indirmek için bir gradient yöntemi kullanılmaktadır. Bu yöntemde, ağırlık ağırlıkları iteratif olarak güncellenir ve hata fonksiyonu minimumuna yaklaştırılır. SCG, aynı zamanda hızlı bir öğrenme oranı sağlar ve diğer yöntemlerden daha hızlı çalışmaktadır (Bataineh ve Kaur 2018).

2.5 Yenilenebilir Enerji Kaynakları Tahmini

YEK'ler kesintili ve kontrolsüz bir şekilde enerji üretimi yaptığı için güç şebekesine dahil edilmesi beraberinde bazı zorlukları getirmektedir. Özellikle MŞ'ler enerji ihtiyacının büyük bir kısmına yenilenebilir kaynaklarla cevap vermeyi amaçlamaktadır. Fakat şebeke yüklerinin kesintisiz ve belirsiz elektrik talebine cevap vermesi gereklidir (Demirtaş 2019). Ancak YEK'lerin hava faktörlerine olan bağımlılığı bu durumu her zaman için mümkün kılmayabilir. Bu nedenle MŞ'de bulunan YEK'lerin bireysel olarak anlık enerji üretimi hakkında fikir sahibi olmak önemlidir. Böylece üretim elemanların günün her

saati için üreteceği elektrik enerjisi tahmin edilerek farklı enerji kaynakları yüklerin ihtiyaçları çerçevesinde aktif hale getirilebilir. Güneş ve rüzgâr enerjisi kaynaklı üretimin yoğun olarak yapıldığı MŞ'lerde güneş ışıması, sıcaklık, rüzgâr hızı ve yönü gibi genellikle iklim şartları veya panellerin ve türbinlerin temizliği ve bakımı gibi faktörler üretilen elektrik enerjisini miktarını belirler. Yani birçok faktörden etkilenen yenilenebilir üretimde şebeke yüklerine cevap verebilmek ve üretim elemanlarının operasyon stratejisini ortaya koyabilmek adına YEK'lerin tahmini önemlidir.

2.5.1 Güneş Enerjisi Tahmini

Son zamanlarda konvansiyonel şebekelerin artan enerji talebine cevap verebilmede FV sistemler oldukça yaygın olarak kullanılmaktadır. Bunun nedeni FV sistemlerin en temiz ve ekonomik elektrik enerjisi üretme yöntemlerinden biri olmasıdır. Ancak güneş enerjisinin kesintili ve çevre etmenlerine karşı olan duyarlılığı nedeniyle tüketicilere sürekli güç sağlayamamaktadır. Bu nedenle FV sistemle üretilen gücü yüksek doğrulukla tahmin etmek önem taşır. FV sistemin çıkış gücü temelde güneş ışıması olmak üzere bulutluluk, sıcaklık, nem ve rüzgâr hızı gibi değişkenlere bağlıdır.

Güneş ışımasını tahmininde nümerik hava tahmin (NHT) yöntemleri, makine öğrenmesine dayalı yöntemler, uydu görüntüleme ve gökyüzü görüntüleme gibi farklı yöntemlerle birlikte bu yöntemlerin beraber kullanıldığı hibrit yaklaşımlar da kullanılmıştır. Nümerik yöntemler veriye dayalı istatistiksel yöntemler olan zaman serilerinden yararlanarak tarihsel güneş ışıması verilerini kullanarak tahmin yapmaktadır. Makine öğrenmesi algoritmaları ise girdi verileri arasındaki lineer olmayan ilişkiyi modelleyerek güneş ışımasını tahmin etmektedir. Görüntü tabanlı modeller uydu veya kameralar ile kaydedilen gökyüzü görüntülerini işleyerek tahmin yapmaya çalışmaktadır. MŞ'lerde solar ışıma tahmini amacına uygun olarak kısa, orta ve uzun olmak üzere farklı zaman aralıklarıyla yapılmaktadır. Böylece kısa zamanlı tahminler ile gün içerisindeki kaynaklar arası gerçek zamanlı yük dağıtımı veya mikro ve makro şebekeler arası enerji transferinin planlanması yapılabilir. Orta dönem tahminlerle ise kaynaklar için rezerv planlaması veya bakım-onarım planlaması yapılabileceği gibi uzun dönem tahminlerle FV sistem planlamaları ve elektrik satış tarifeleri üzerinde optimizasyon çalışmaları yapılabilmektedir. Güneş

ışması tahmininde kullanılan metotların farklı zaman aralıkları için tahmin başarısı değişiklik gösterir. Bu nedenle istenilen amaca en uygun tahmin metodu kullanılmalıdır (Kumar vd. 2020).

Literatürde solar ışıma tahmini otoregresif (auto regressive - AR), hareketli ortalama (moving avarage - MA), otoregresif hareketli ortalama (auto regressive moving avarage - ARMA), otoregresif entegre hareketli ortalama (auto regressive integrated moving average - ARIMA), genelleştirilmiş özbağlanımlı koşullu değişen varyans (generalized autoregressive conditional heteroskedasticity - GARCH) gibi istatistiksel metotlar ile tarihsel güneş ışıması değerleri arasındaki ilişki modellenerek yapılmıştır. Bu modeller genellikle bir gün zaman aralığı sonraki tahminlerde daha iyi başarı gösterirken lineer olmayan regresyon, DVM, YSA gibi makine öğrenmesine dayalı tahmin yöntemleri bir saat ile bir gün zaman aralığı için tahminler yapmada daha başarılıdır. Uydu görüntülemesine dayalı bulut izleme metotları erişilebilirliği daha zor ve zamansal çözünürlüğünün az olması nedeniyle uzun zaman aralıkları için tercih edilmezler fakat birkaç saat ve hatta dakikalar gibi kısa zaman aralıklı tahminler için en başarılı sonuçları sunarlar (Krishnan vd. 2023).

2.5.2 Rüzgâr Enerjisi Tahmini

Rüzgâr enerjisi tahmini amaç ve yöntem olarak güneş enerjisine oldukça benzerlik göstermektedir. Rüzgâr enerjisi tahmini ile MŞ'lerde ekonomik yük dağıtımı, sistem planlaması ve kaynak yönetimi yapılabilir. Üretilen rüzgâr gücü miktarı türbinin tipi, kanat sayısı, yerden yüksekliği gibi karakteristik özelliklerin dışında konumlandığı bölgedeki rüzgâr hızı, rüzgâr yönü, hava basıncı, sıcaklık ve nem gibi atmosferik etkilere de bağlıdır.

Rüzgâr hızı tahmin yöntemleri güneş enerjisine benzer şekilde fiziksel uygulamalar olan NHT metotları ve istatistiksel uygulamalar olan zaman serileri ve makine öğrenmesi metotları olarak gruplandırılabilir. NHT tarihsel meteorolojik veriler üzerinden oluşturulan modellerle rüzgâr hızını tahmin etmektedir. NHT uzun dönem tahminlerinde daha başarılı tahminler yaparken istatistiksel uygulamalar tarihsel rüzgâr hızı ölçümleri

üzerinden tahminler yapmaktadır. AR, MA, ARMA ve ARIMA benzeri zaman serilerine dayalı tahmin yöntemleri kısa ve orta dönemli tahminlerde daha başarılı iken makine öğrenmesine dayalı YSA modelleri saatlik tahminler yapmada daha başarılıdır. Ayrıca bu yöntemlerin birbiri ile etkileşimi sonucu oluşan hibrit yapılar da rüzgâr hızı tahmininde kullanılmıştır (Dhiman ve Deb 2009).

2.6 Literatür Taraması

Bu tez için yapılan çalışma üç ana bölüm altında toplanmıştır. Bunlardan ilki MŞ'lerin yapısı ve MŞ'lerde yük dağıtımı iken ikincisi elektriksel yük tahmini ve son olarak YEK tahminidir. Bu kısımda bu üç bölümle ilgili ulusal ve uluslararası literatürde yer alan çalışmalardan bir kısmı ele alınarak kullanılan materyaller ve metotlar incelenmiş ve modeller için performans değerlendirmeleri sunulmuştur.

2.6.1 Ulusal Çalışmalar

Literatürde çeşitli algoritmalar ile elektriksel yük tahmini çalışmaları yapılarak bu tahminler için performans kıyaslamalarında bulunulmuştur. Bu bölümde yük tahmini ile ilgili ulusal literatürde bulunan çalışmalardan birkaçı yer almaktadır.

2006 yılında Aslan ve arkadaşları, YSA modeli kullanarak Kütahya ili için beş yıllık geriye dönük verileri kullanarak ay bazında puant yük tahmini yapmışlardır. 9 nöronlu ve logaritma sigmoid aktivasyon fonksiyonunu kullanan YSA modeli için ortalama olarak %4,5 civarı hata payı ile 2005 yılı için aylık puant yükü tahmin etmişlerdir (Aslan vd. 2006).

2008 yılında Akman ve arkadaşları, regresyon analizi, zaman serileri analizi, YSA ve DVM modelleri hakkında temel materyal ve metot hakkında bilgi verip yük tahminin enerji sistemlerinin işletilmesindeki kritik öneminin haricinde enerji sektöründe piyasa yapılandırması için önemine de değışmişlerdir. Ayrıca yük tahmin modellerinin ihtiyaçlar ve uygulama bölgesi özelinde değerlendirilmesi gerektiği düşünülerek tahmin algoritmaları arasında net bir başarı karşılaştırılması sunulmamıştır (Akman vd 2018).

2018 yılında Haliloğlu ve Tutu, kısa dönem elektrik yük tahminine en önemli parametrenin sıcaklık olduğunu belirtmiştir. Kurdukları model ile 2012-2018 yılları arasındaki Türkiye için günlük elektrik tüketim verilerini kullanarak EKK yöntemi ile aylık periyotlarla elektrik tahmini yapmışlardır. Oluşturdukları modelin elektrik tüketim talebini %92,8 başarı oranı ile tahmin ettiğini belirtmişlerdir (Haliloğlu ve Tutu 2018).

2010 yılında Demirel ve arkadaşları, adaptif ağ tabanlı bulanık çıkarım sistemi (Adaptive Network Based Fuzzy Interface-ANFIS) ve Otoregresif Hareketli Ortalamalar (Autoregressive Moving Average-ARMA) teknikleri ile yük tahmini yapmışlardır. 1970-2007 yılları arasındaki Türkiye için enerji tüketim verileri kullanılarak 2015-2010 yılları arasındaki enerji tüketimi tahmin edilmiştir. Böylece 2015 ve 2016 yılları için tahmin sonuçları gerçek değerlerle kıyaslanabilmiştir. Yıl bazında değerlendirme hatası RMSE, MAE ve MAPE değerlendirme kriterleri ile hesaplanmıştır. Bunun sonucu ANFIS ve ARMA modelleri için sırasıyla RMSE 709,26 ve 8211,46, MAPE 0.474 ve 5,315, MAE ise 709,150 ve 8008,65 olarak hesaplanmıştır. Yazarlara göre ANFIS modelinin adaptif öğrenme yeteneğinin karşılaştırılan iki model arasındaki başarı farkını oluşturmuştur (Demirel vd. 2013).

2020 yılında Gökgöz ve Filiz, 400 farklı YSA modeli ile elektrik yük tahmini yaparak tahmin sonuçlarını MAPE ve Diebold-Mariano testi ile karşılaştırmıştır. Türkiye için 2014-2016 yılları arasındaki elektrik yükü verilerini eğitim veri seti olarak kullandıkları çalışma sonucu en iyi performansa ait model Log-sigmoid aktivasyonuna sahip LM algoritması ile eğitilen YSA modeli olmuştur. Bu modelde hata değeri olarak MAPE %2,2040 olarak belirtilmiştir (Gökgöz ve Filiz 2020).

2021 yılında Kamber ve arkadaşları, YSA'ya dayalı kısa dönem yük tahmini yapmışlardır. İspanya'nın 2015-2016 yılları arasındaki elektrik tüketim verilerini kullanarak uzun kısa dönemli bellek (Long Short-Term Memory – LSTM) mimarisini ARIMA modeli ile karşılaştırılmıştır. Bir yıllık veriler üzerinden bir haftalık tahmin yapılan çalışmanın sonucunda LSTM modeli için MAE 28697,6085 ve RMSE 7069,1917 olarak hesaplanırken ARIMA model için MAE 3927,255 ve RMSE 4992,951 olarak

hesaplanmıştır. Yazarların ifadesine göre bu çalışmada hava faktörlerinin modele dahil edilmemesinin sonucunda hata oranı yüksek olarak gözlemlenmiştir. Bununla birlikte küçük bir eğitim veri setinin sonucu olarak ARIMA modeli karşılaştırılan LSTM modeline göre daha başarılı sonuçlar vermiştir (Kamber vd. 2021).

Bu bölümde tez içeriğinde incelenen YEK'ler olan güneş ve rüzgâr enerjisi tahmini ile ilgili ulusal çalışmalar incelenmiştir.

2017 yılında Filik ve Filik, kısa dönem rüzgâr hızı tahmininde AR ve YSA tabanlı hibrit bir yaklaşım geliştirmişlerdir. Rüzgâr türbinlerinin güvenli bir şekilde işletilebilmesi ve şebeke içinde rüzgâr gücünün ekonomik dağıtımı için rüzgâr hızının öneminden bahseden yazarlar Eskişehir bölgesine ait yedi yıllık saatlik ortalama rüzgâr verilerini kullanarak bir yıllık rüzgâr hızını tahmin etmişlerdir. AR, YSA ve geliştirdikleri hibrit sistemin tahmin başarısını RMSE ve MAE kriterleri ile değerlendirdiklerinde hibrit sistemin AR yöntemine göre %5,61, YSA yöntemine göre %3 daha az hataya sahip olduğunu belirtmişlerdir (Filik ve Filik 2017).

2019 yılında Unes ve arkadaşları, Nevada eyaletindeki iki yıllık ortalama buharlaşma ve hava sıcaklığı ve rüzgâr hızı verilerini kullanarak ÇLR, bulanık mantık Mamdani ve bulanık mantık Sugeno yöntemleri ile rüzgâr hızı tahmininde bulunmuşlardır. Modeller MAE, MSE ve R (korelasyon katsayısı) ölçütlerine göre değerlendirilmiş olup R değerleri ÇLR için 0,80, bulanık mantık Mamdani için 0,84 ve bulanık mantık Sugeno için 0,83 olarak hesaplanmıştır (Unes vd. 2019).

2019 yılında Demirtaş ve arkadaşları, akıllı şebekelerin temel amaçlarından birinin YEK kaynaklarının şebekeye entegrasyonu olduğuna değinen yazarlar kesintili ve kontrol edilemeyen yapıları dolayısı ile YEK'lerin tahminin önemine vurgu yapmışlardır. Bu nedenle atmosferik ölçümlere dayalı ve saatlik periyotlarla güneş enerjisi tahmin modeli geliştirmişlerdir. Çoklu doğrusal regresyon, Powell optimizasyonu ve Markov Chain Monte Carlo simülasyonlarına dayanan modeller ile yapılan tahmin sonucunda enerji üretimi analitik yaklaşımlar ile %80 doğrulukla tahmin edilirken olasılıksal yaklaşımlara %95 civarı doğrulukla tahmin edilmiştir (Demirtaş vd. 2019).

2021 yılında Sarı ve diğerleri, doğrusal olmayan otoregresif eksojen (Nonlinear Autoregressive Exogenous-NARX) modeli kullanarak güneş ışıma verisi tahmini gerçekleştirmişlerdir. Harici veri olarak sıcaklık, nem ve yağış miktarı kullanılan çalışmalarda en başarılı güneş ışıma tahmini harici veri olarak sıcaklığın kullanıldığı model olmuştur ve 0.00457 MSE değeri ile ışıma tahmini yapılmıştır (Sarı vd. 2021)

2022 yılında Maham ve Akarslan, tarafından yapılan çalışmada güneş ışımasını YSA, ridge regresyon, NARX ve metotları beraber kullanımından doğan hibrit yaklaşımla güneş ışıma tahmini yapılmıştır. Deney sonunda YSA modeli için RMSE değeri 67,66 NARX modeli için 58,96 ridge regresyon modeli için ise 119,81 olarak hesaplanmıştır. Sunulan hibrit yaklaşım ile RMSE değeri 57,92 değerine düşürülerek daha başarılı bir tahmin modeli ortaya konulmuştur (Maham ve Akarslan 2022).

Bu bölümde MŞ'lerde ekonomik yük dağıtımını konu alan çalışmalar incelenerek yapılan yatırımlar sonucu enerji üretim maliyetindeki düşüşler ve buna bağlı olarak sistem yatırımının amortisman süresi incelenmiştir.

2014 yılında Kocaman, şehir merkezinden uzak küçük bir yerleşim yeri için ana şebekeden bağımsız bir MŞ için bir enerji yönetim uygulaması yapmıştır. Geliştirdiği bilgisayar programı ile enerji üretim verileri ve yük verilerini analiz eden Kocaman yük tarafından talep edilen enerjinin en uygun kaynaktan sağlanması için bir kontrol yöntemi tasarlamıştır. Yaptığı çalışmayı sonucunu bir günlük analiz üzerinden sunan yazar YEK ve enerji depolama birimleri ile 24 saat boyunca talep edilen gücün sağlandığı ve artık gücün enerji depolama birimlerince depolandığını ifade etmiştir (Kocaman 2014).

2018 yılında Çetinbaş ve diğerleri, Eskişehir Osmangazi Üniversitesi kampüsünde FV ve enerji depolama sistemlerinden oluşan bir MŞ tasarımı gerçekleştirmişlerdir. Üç farklı senaryo üzerinden oluşturdukları tasarımı analiz ederek elektrik enerjisi maliyetini farklı senaryolar arasında %43,16'ya kadar azaltmışlardır. Bunun sonucu olarak MŞ kurulum maliyetini yaklaşık olarak 34 aylık süre zarfında amorti edileceği belirtilmiştir (Demirtaş vd. 2019).

2021 yılında Çetinkaya, Kayseri ilinin 12 ilçesi için örnek bir MŞ oluşturarak bu şebekeye rüzgâr enerjisinin entegrasyonu üzerine çalışmıştır. Modellenen şebeke için gerilim kararlılığı iyileşirken enerji taşıma hatlarından doğan kayıp miktarının azaldığı görülmüştür. Ayrıca bu bölgenin mevcut güç ihtiyacının bir termik santral tarafından karşılandığı durumla kendi modelini ekonomik olarak karşılaştırılmıştır. Yazar yıllık termik santral ile yapılan üretimin 52 362 204 \$ değerine karşılık bir miktarda azaldığını ifade etmiş ve yapılan tasarımın kurulum maliyeti olan 175 000 000 \$'ı yaklaşık olarak 3 yıl 4 ayda amorti edeceğini eklemiştir (Karlitepe 2021).

2.6.2 Uluslararası Çalışmalar

Bu bölümde yük tahmini metotları ile ilgili uluslararası çalışmalar incelenmiştir. Farklı zaman aralıkları için yük tahmin metotları kıyaslanarak yöntemlerin başarıları incelenmiştir.

2015 yılında ve Zhang arkadaşları, büyük veri teknolojilerine dayalı geliştirdikleri yük tahmin metodu ile kısa dönem yük tahmini yapmışlardır Akıllı şebekeler için yük tahminin önemi vurgulanan çalışmada yapılan 24 saatlik tahmin sonucu ortalama bağlı hata DVM metodu için %1,61, YSA metodu için %3,40 iken geliştirdikleri yöntemle %1,16 hataya ulaşmışlardır (Zhang vd.2015).

2017 yılında Qiuyu ve Yang, NHT'ye dayalı kısa dönem yük tahmini yapmışlardır. Tarihsel yük ve hava verilerini kullanarak DVR modeli ile Çin'in güneyindeki bir şehir için yaptıkları tahminde %4,43 olan MAPE değerini geliştirdikleri yük ayrıştırma modeli ile %2,21'e düşürmüşlerdir. Benzer şekilde YSA modeli ile %4,89 olarak hesapladıkları MAPE değerini yine yük ayrıştırma metodu ile %2,96 seviyesine indirmişlerdir (Qiuyu vd. 2017).

2022 yılında Tarmanini ve arkadaşları, yenilenebilir enerji sistemlerinde yük tahmininin planlama, kurulum ve uygulamadaki öneminden bahsederken saatlik yük tahmini makine öğrenmesi algoritmaları olan YSA ve ARIMA modelleri üzerinden yapmışlardır.

İrlanda'daki 709 bireysel konut için 18 aylık periyot için günlük elektriksel yük tahmini sonucu modellerin performansı karşılaştırılmıştır. Yazarlar YSA modelinin lineer olmayan yük profili için ARIMA modeline göre daha başarılı olduğunu ifade etmişlerdir (Tarmanini vd. 2022).

2022 yılında Ibrahim ve arkadaşları, enerji sektörünün gelecek vizyonu olarak nitelendirdikleri akıllı şebekeler için planlı ve güvenilir bir yapı oluşturabilmek için yük tahmin modellerinin önemine değinmişlerdir. Sundukları yük tahmin modeli için en önemli parametrenin tahmin edilecek saatin önceki haftaki aynı saatteki değeri olduğunu belirttikleri çalışmalarında 1 saatten 24 saate kadar olan kısa dönem yük tahminleri üzerinde durmuşlardır. Çeşitli makine öğrenmesi yöntemlerini üzerinden Panama'daki bir bölge için yaptıkları durum çalışmasında derin öğrenme regresyon modeli ile %2,9 MAPE değeri ve 0,93 R² değerini elde etmişlerdir (Ibrahim vd. 2022).

Bu bölümde tez içeriğinde incelenen YEK'lerden olan güneş ve rüzgâr enerjisi ile ilgili uluslararası çalışmalar incelenmiştir.

2017 yılında Rodrigues ve arkadaşları, YSA modeli ile MŞ kontrolü amacı ile hava tahminine dayalı güneş enerjisi üretimini tahmin etmişlerdir. Kısa dönemli enerji tahmini çalışmalarında havanın açık veya bulutlu olduğu günleri sınıflandıran yazarlar güneşli günlerde ortalama %0,4225, parçalı bulutlu günlerde ortalama %1,75 bulutlu günlerde ise ortalama %4,95 hata ile üretilen enerji miktarını tahmin etmişlerdir. İnternete bağlı olarak işletilen akıllı MŞ'lerin güneş enerji tahminine dayalı olarak şebeke kontrolü ile ilgili çalışan yazarlar çalışmalarının sonunda bu kontrol mekanizmasının güneşli günlerde güvenli ve yeterli çalışıyor olmasına rağmen bulutlu günlerde enerji akışının dengesizliğinden doğan enerji açığını kapatmak için ek enerji sağlayıcı önlemler alınması gerektiğini belirtmişlerdir (Rodríguez vd. 2017).

2020 yılında Dupré ve arkadaşları, yarım saatlik zaman aralıkları için rüzgâr hızı ve rüzgâr enerjisini tahmin etmişlerdir. Fransa'nın Bonneval bölgesinde yer alan rüzgâr tarlası için hem 100 m yükseklikteki rüzgâr hızını hem de türbinlerin enerji üretimini tahmin etmek için istatistiksel modeller ve NHT modellerinin kombine edildiği bir

uygulama geliřtirmiřlerdir. alıřmalarının sonucunda geliřtirdikleri metodun rüzgâr enerjisi tahmininde sıklıkla kullanılan zaman serileri analizi metoduna göre daha başarılı olduğunu görmüşlerdir ve tahmin kararlılığını %5'den %28,9'a geliřtirdiklerini belirtmişlerdir (Dupré vd. 2020).

2023 yılında Krishnan ve Inda, solar radyasyon tahmin yöntemleri üzerinde yaptıkları kapsamlı literatür taramasında gökyüzü görüntüleme tekniklerinin 30 dakikalık zaman periyodunda daha başarı tahminler yaptığı ifade edilirken uydu görüntüleme tekniklerinin 4 saate kadar olan tahminlerde daha başarılı olduğu belirtilmiştir. Bununla birlikte makine öğrenmesine dayalı modellerin bir günün altındaki tahminleri yapma başarısının yüksek olduğu söylenmiştir. NHT modelleri ise bir günü aşan zamanlar için diğer yöntemlere göre daha başarılı bulunurken her yöntemin konuma ve zamana bağılı olarak değerlendirilmesi gerektiğini ancak farklı konumlar için optimizasyon analizleri yapılabilmesinin makine öğrenmesi modellerinin evrensel model olarak düşünülebileceğinden bahsedilmiştir (Krishnan ve Inda 2023).


3. MATARYEL VE METOT

3.1 Elektriksel Yük Tahmini Uygulaması

3.1.1 Veri Toplama

Yük tahmini yapabilmek için MŞ'nin tarihsel elektrik yük verileri ve MŞ'nin konumlandığı bölge için geçmiş dönem meteoroloji verileri edinilmiştir. Ayrıca MŞ'nin yenilenebilir kaynaklı elektrik üretimini öngörebilmek adına yine aynı bölgeye ait YEK verileri edinilmiştir.


Bu çalışmada MŞ tasarımı için Amerika Birleşik Devletleri'nin Pensilvanya eyaleti içerisinde Pittsburgh metropolü içerisinde yer alan Duquesne (DUQ) bölgesi uygun görülmüştür. DUQ bölgesinin MŞ tasarımı için seçilmesinin nedenleri diğer bölgelere göre daha az enerji tüketiminin olması ve 600000 civarı tüketici ile Alegheny ve Beaver bölgelerinde nispeten daha küçük bir nüfusa enerji sağlıyor oluşudur (İnt. Kyn. 6).



Şekil 3.1 PJM bölge haritası


Yük verileri için Pennsylvania-New Jersey-Maryland Interconnection (PJM) adı verilen bölgesel iletim organizasyonu olan ve 13 eyaletin elektrik hareketini kontrol eden

organizasyondan yararlanılmıştır. Dünyadaki en büyük elektrik piyasası olan PJM bu bölgede 60 milyondan fazla insana yıllık 40 milyar dolar üzerinde elektrik işlemi yapmaktadır.



Şekil 3.2 PJM bünyesindeki çeşitli iletim bölgelerini gösteren harita.

PJM “Data Miner” ismini verdiği veri yönetim sistemi ile kullanıcılara ölçümlenen verilere ulaşım imkânı sunmaktadır. Data Miner sistemi kullanılarak Duquesne bölgesi için 01.01.2015 ve 28.02.2023 tarihleri arasındaki yükler tarafından tüketilen elektrik enerjisi saatlik olarak MW cinsinden elde edilmiştir.



Şekil 3.3 Duquesne bölgesi için MW cinsinden 7 yıllık yük verisi.

İkinci veri türü olan meteoroloji verisi için ise hava durumu tahmini ve meteorolojik verileri sağlayan OpenWeather isimli web hizmetinden yararlanılmıştır. Sistem kullanıcılara tarihsel hava durumunu bir doküman olarak sunmanın yanı sıra uygulama programlama arabirimi (Application Programming Interface -API) sayesinde meteoroloji verileri için otomatik sorgu yapma imkânı sunar. Duquesne bölgesi için 01/01/2015 ve 28/02/2023 tarihleri arasında edinilen veriler arasında yük tahminini etkileyen sıcaklık ve basınç verileri mevcuttur. Benzer şekilde bir saatlik zaman hassasiyetine sahip ölçümler kullanılmıştır.

Üçüncü veri türü olan YEK'ler için HOMER (Hybrid Optimization of Multiple Energy Resources) Energy bünyesindeki Homer Pro programından yararlanılmıştır. Temel amacı MŞ'lerin tasarlanması, analiz edilmesi ve optimizasyonu olan program, seçilen enlem ve boylam değerleri ($40^{\circ}26.2'K$, $79^{\circ}59.4'B$) vasıtasıyla yeryüzündeki bir noktanın YEK profilini NASA Prediction of Worldwide Energy Resource (POWER) altyapısını kullanarak belirler. Bu sistem vasıtasıyla FV sistem için panellerden üretilen elektrik enerjisinde belirleyici rol oynayan günlük radyasyon ve açıklık indeksi, rüzgâr enerjisi için de ortalama rüzgâr hızı gibi parametreler edinilerek enerji üretim senaryoları modellenebilmektedir.

3.1.2 Veri Seti Oluşturma ve Analizi


Elde edilen verilerin yük tahmininde kullanılabilmesi için belirli bir formatta düzenlenerek bir veri seti haline getirilmesi gerekmektedir. Bu işlemi yapabilmek ve tüm verileri tek bir tablo haline getirebilmek adına Microsoft Excel yazılımından yararlanılmıştır. İlk olarak karışıklığı önlemek ve anlaşılabilirliği arttırmak amacı ile yük ve meteoroloji verileri Kuzey Amerika’da kullanılan zaman dilimi olan EST’den (doğu standart saat) dünya genelinde standart olan zaman dilimi UTC’ye (koordinatlı evrensel saat) göre standardize edilmiştir. Elde edilen verilerde tarih sütunu GG/AA/YYYY SS:DD şeklinde gün, ay, yıl, saat ve dakika formatında olup bir saatlik zaman hassasiyetine karşılık gelen yük ve meteoroloji değerlerini ifade etmektedir. Bu tarih değerleri kullanılarak literatür kısmında bahsedilen yük tahmininde girdi olarak kullanılan tarihsel faktörler elde edilmiştir. Excel programının içerdiği “=YIL(X), =AY(X), =GÜN(X), =SAAT(X)” fonksiyonları kullanılarak tarih tipindeki veriler için sırasıyla yıl, ay, gün ve saat sütunları oluşturulmuştur. Sonrasında “=METNEÇEVİR(X,"dddd")” fonksiyonu kullanarak tarihlere karşılık gelen gün isimleri elde edilmiştir. Böylece elde edilen gün isimleri birtakım denklemler aracılığı ile filtrelenerek hafta içi ve hafta sonu olan günler tespit edilmiştir. Hafta sonu indeksi olarak ifade edilen bu parametre hafta içi günler için 0 değerini alırken hafta sonu günlerde 1 değerini almaktadır. Bir başka parametre olan haftanın kaçınıcı günü olduğunu ifade eden parametre yine gün isimleri kullanılarak elde edilmiştir. Saat indeksi günün uyanık olunan ve uyku saatlerini ifade eden bir başka parametredir. Saat indeksi saat 23:00’dan 06:00’a kadar 0 olarak belirlenmiştir. Günün geri kalan ve genelde uyanık olarak geçirilen kısmı ise 1 olarak ifade edilmiştir. Ayrıca ikinci bir saat indeksi ile günü şafak, sabah, öğlen, akşam ve gece şeklinde beş ayrı bölüme bölerek tahmin başarısını arttırmak amaçlanmıştır. Son olarak Amerika Birleşik Devletleri’nde uygulanan yaz saati uygulamasının (daylight saving time-DST) aktif ve pasif olduğu zaman aralıkları 0 ve 1 olarak belirlenip tarihsel parametrelere eklenmiştir. Ayrıca tarihsel parametrelerin dışında meteoroloji olarak ifade edilen sıcaklık ve nem verilerine ek olarak sıcaklığın 15 C°’nin altında olduğu saatleri 0 üstünde olduğu saatleri ise 1 kabul eden ve sıcaklık indeksi olarak adlandırılan parametre veri setine eklenmiştir. Son olarak MATLAB programı kullanılarak yük verilerinin ölçülemediği ‘NULL’ yani değerin olmadığı satırlar

“**isnun(X)**” fonksiyonu kullanılarak tespit edilmiş bu değerlerin yerine bir saat önceki ve sonraki yük değerlerinin ortalamaları atanmıştır. Böylece ölçümden kaynaklı eksik veriler sistematik bir şekilde tamamlanmış ve veri seti eksiksiz olarak oluşturulmuştur. Bunun sonucunda Çizelge 3.1’deki 13 parametreden oluşan veri seti analize uygun ve literatür kısmında değinilen tahmin algoritmalarına girdi olabilecek formata getirilmiştir. Ayrıca veri setinden küçük bir örnek EK 1’de sunulmuştur.


Çizelge 3.1 Veri setini oluşturan tarihsel, meteorolojik ve yük parametrelerine ait değer aralıkları ve birimler.

Kategori	Tahmin parametresi	Değer aralığı	Birimi
Tarihsel	Yıl	2015 - 2023	[y]
	Ay	1 - 12	[a]
	Gün	1 - 31	[g]
	Saat	0 - 23	[s]
	Saat indeksi	0 - 1	[-]
	Saat indeksi-2	0 - 4	[-]
	Haftanın günü	1 - 7	[-]
	Hafta sonu indeksi	0 - 1	[-]
	DST indeksi	0 - 1	[-]
Meteorolojik	Sıcaklık	-24.3 - 35.68	[°C]
	Nem	10 - 100	[%]
	Sıcaklık indeksi	0 - 1	[-]
Yük	Ölçülen yük	943 - 2804	[MW]

Tahmin algoritmaları için yapılan literatür taramasında değişkenler arasındaki lineerliğin doğru algoritma seçimindeki önemi vurgulanmıştır. Bu amaçla cevap değişkeni olan yük verisi ile tahmin değişkenleri arasındaki lineerliği anlamak amacı ile dağılım grafiği veya korelasyon analizi gibi yöntemler kullanılabilir. Dağılım grafiğinde iki değişken türü bir dağılım grafiğinde ifade edilerek veriler arasındaki olağan lineer ilişki gözlemlenir. Eğer noktalar bir doğru üzerinde toplanma eğiliminde ise bu veriler arasındaki lineer bir ilişkiyi gösterir. Şekil 3.4 ve Şekil 3.5 sırasıyla sıcaklık ve nemin elektrik tüketimine olan etkisini göstermektedir.



Şekil 3.4 Sıcaklık ve yük değişkenlerine ait dağılım grafiği.



Şekil 3.5 Nem ve yük değişkenlerine ait dağılım grafiği.

Korelasyon katsayısı ise iki değişken arasındaki doğrusal ifadeyi matematiksel olarak ifade eden istatistiksel bir yöntemdir. Korelasyon katsayısı -1 ile +1 arasında bir değer alır ve bu değer +1'e yaklaşması değerler arasındaki lineer ilişkiyi, -1'e yaklaşması ise lineer olmayan ilişkiyi ifade eder.

Çizelge 3.2 Veri setindeki tahmin parametreleri ile yük değeri arasındaki korelasyon katsayısı.


Tahmin parametresi	Korelasyon katsayısı
Yıl – Yük	-0.1496
Ay – Yük	-0.0092
Gün – Yük	0.0130
Saat – Yük	0.3235
Saat indeksi – Yük	0.0880
Saat indeksi-2 – Yük	0.3441
Haftanın günü – Yük	-0.1318
Hafta sonu indeksi – Yük	-0.1729
DST indeksi – Yük	0.0534
Sıcaklık – Yük	0.3279
Nem – Yük	-0.2112
Sıcaklık indeksi – Yük	0.3554

Şekil 3.4’de görülen dağılım grafiği sıcaklık ve elektrik tüketimi arasındaki ilişkiyi ifade eder. Havanın ısınmasının ve soğumasının sonucu olan soğutma ve ısıtma sistemlerinin elektrik tüketimine etkisi bu grafikte de gözlemlenebilmiştir. Ancak her ne kadar grafik iki parça olarak düşünülüp 15 C° üzeri ayrı aşağısı ayrı incelendiğinde verilerin bir doğru etrafında yayıldığı gözlemlense de grafik bütün olarak göze alındığında bu durum söz konusu değildir. Bu durum Çizelge 3.2’de de benzer şekilde gözükmemektedir. Sıcaklık ve yük ilişkisindeki korelasyon katsayısı tüm veri setindeki en yüksek değerlerden biri olmasına rağmen bu değer 0.3279 olup güçlü bir lineerlik ifade etmemektedir. Nem ve yük ilişkisi için ise lineerlikten ifade etmek zordur. Benzer şekilde tüm tahmin parametreleri için yapılan korelasyon analizinin sonuçları Çizelge 3.2’de gösterilmiştir. Veri setindeki parametrelerin genelinin yük verisi ile lineerlikten uzak olması nedeniyle bu veri seti ile yük tahmini yapılırken lineer olmayan kernel fonksiyonlarının ve lineer olmayan algoritmaların daha başarılı olması öngörülmektedir.


3.1.2 YSA ile Yük Tahmini

Elektriksel yük tahmini yapabilmek adına MATLAB 2020b programı kullanılarak YSA modeli oluşturulmuştur. On iki bağımsız girdi değişkeni ve bir bağımlı çıktı değişkeni bulunan ve 2015 yılının başından 2023 yılının sonuna kadar olan verileri içeren veri


setinden son iki haftanın verileri değerlendirme yapabilmek için çıkartılmıştır. Veri seti rastgele olarak %70'i eğitim, %15'i validasyon ve kalan %15'i test olacak şekilde üç bölüme ayrılmıştır. Daha verimli eğitim algoritmasını tespit edebilmek ve gizli katmandaki nöron sayısını optimize edebilmek için bir eğitim döngüsü oluşturulmuştur. Üç farklı eğitim algoritması olan LB, BRG ve SCG için “trainlm”, “trainbr” ve “trainscg” fonksiyonları kullanılarak 1’den başlayarak 30 nörona kadar modeller eğitilmiştir. Döngü sırasında her algoritmadaki her bir nöron sayısı için eğitim ve validasyon çıktılarının performans ölçümleri yapılmıştır. Böylece modelin hem eksik öğrenme sonucu yetersiz tahminler yapmaması hem de aşırı öğrenme sonucu yeni veriler için tahmin yeteneğini kaybetmemesi amaçlanmıştır. LB, BRG ve SCG için farklı nöron sayılarında eğitim ve validasyon performansı takip eden şekillerle sunulmuştur.



Şekil 3.6 LM algoritması için nöron sayısı ve hata miktarı ilişkisi.




Şekil 3.7 BR algoritması için nöron sayısı ve hata miktarı ilişkisi.



Şekil 3.8 SCG algoritması için nöron sayısı ve hata miktarı ilişkisi.

Şekil 3.6, Şekil 3.7 ve Şekil 3.8 incelendiğinde bu modelde SCG algoritmasının 30 nörona kadar yapılan eğitimlerde diğer iki eğitim algoritması olan LV ve BR'ye göre daha başarısız olduğu gözlemlenebilir. BR eğitim algoritması her ne kadar diğer ikisine göre daha yavaş olsa da karmaşık veri setlerini modellemedeki başarısı bu veri seti için 22 ve 30 nöron arasında görülmüştür. Tekrar edilen optimizasyon çalışmaları ve model eğitimleri sonucunda hata oranının en düşük olarak gözlemlendiği nokta olan 22 nörondan oluşan ve BR eğitim algoritmasını kullanan model bu çalışma için seçilmiştir.




Şekil 3.9 YSA modeli.

YSA modeli için optimum eğitim parametreleri belirlendikten sonra oluşan YSA modeli Şekil 3.9'da gösterilmiştir. Eğitim verilerine normalizasyon uygulanılarak tüm veriler 0 ve 1 değer aralığında oranlanmıştır. Denklem (3.1)'de uygulanan normalizasyon ifade edilmiştir.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

Burada x_{norm} normalize edilmiş değeri, x normalize edilecek verinin değerini, x_{min} veri setindeki x parametrelerinin en küçük değerini, x_{max} ise veri setindeki x parametrelerinin en büyük değerini ifade eder.


Ayrıca eğitimi tekrarlamak farklı başlangıç koşulları ve veri örneklemeleri nedeniyle tahmin başarısında farklılıklar yaratmaktadır. Bu nedenle eğitim birkaç kez tekrar edilerek başarı oranının yüksek olduğu model tespit edilmiştir. Eğitim sürecini açıklayan akış diyagramı Şekil 3.10'da görülmektedir. Ayrıca YSA tahmin modeline ait MATLAB kodları EK 2'de verilmiştir.



Şekil 3.10 YSA ile tahmin sürecinin akış diyagramı.

Modelin transfer fonksiyonu olarak YSA uygulamalarında sıklıkla kullanılan simetrik sigmoid kullanılmıştır. Lineer olmayan sigmoid fonksiyonu girdi ve çıktı arasındaki karmaşık ilişkileri modellemede başarılıdır. Sigmoid fonksiyonundan farklı çıktı

değerinin “0” ve “1” arasında değerler alması yerine “-1” ile “1” arasında değerler alması olan simetrik sigmoid fonksiyonu hiperbolik tanjant (tanh) fonksiyonu olarak ifade edilir. Şekil 3.11’te sigmoid ve tanh fonksiyonları bir grafik ile ifade edilmiştir.



Şekil 3.11 Sigmoid ve tanh fonksiyonları.

3.1.3 Performans Metrikleri

Yük tahminde yapılan tahminin başarısını belirleyebilmek adına performans metrikleri veya değerlendirme ölçütleri gibi adlandırmalara sahip istatistiksel hata ölçüleri kullanılır. Özellikle makine öğrenmesi uygulamalarında sıklıkla kullanılan hata ölçüleri ortalama kare hata (mean squared error - MSE), kök ortalama kare hata (root mean square error - RMSE), ortalama mutlak hata (mean absolute error - MAE) ve ortalama mutlak yüzde hatadır (mean absolute percentage error - MAPE). Bu ölçülerin ortak noktası tahmin verileri ve ölçüm verileri arasındaki farkı hata olarak kabul etmesidir. Ancak her biri kendi özelinde hatayı farklı olarak yorumlamaktadır. Bu nedenle farklı amaçlara hizmet ederler.

MSE, tahmin verileri ile ölçüm verileri arasındaki fark yani hataların karelerinin ortalamasının alınması ile hesaplanır. Hataların karesinin alınmasının nedeni negatif hatanın da pozitif ile birlikte değerlendirmeye alınabilmesidir. Regresyon modellerinde ise hata regresyon doğrusu ile sapma değeri arasındaki fark olarak kabul edilir ve sapma miktarlarının varyansını ölçer. MSE değeri sıfıra ne kadar yakınsa değerlendirilen tahmin verisinin başarılı olduğu söylenebilir. MSE formülü denklem (3.2)’de ifade edilmiştir.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.2)$$

Burada, y_t ölçüm verisini, $\hat{y}_t$ tahmin verisini ve n ise veri sayısını ifade eder. MSE hesaplanırken hataların karesi alındığı için büyük farklardan yani sapmalardan çok etkilenir. Bu durum MSE'nin kullanımını kısıtlayabilir.

RMSE, basitçe MSE'nin kareköküdür ve artıkların standart sapmasını ölçer. RMSE de sonuç birim cinsinden ifade edilir bu nedenle hata oranı veri setindeki birime paralel olacaktır. Benzer şekilde RMSE değeri küçüldükçe hata oranı azalmış demektir. Denklem (3.3)'de RMSE modeli ifade edilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (3.3)$$

Burada, y_t ölçüm verisini, $\hat{y}_t$ tahmin verisini ve n ise veri sayısını ifade eder.

MAE, ölçülen ve tahmin edilen değerlerin farkının mutlak ortalaması olarak ifade edilir. Bu ölçekte hatanın karesini almak yerine mutlak değeri alınarak negatif farklar modellenmiştir. Bu ölçekte hatanın karesi alınmadığı için büyük sapmalar MSE ve RMSE kadar etki göstermez. Bu nedenle MAE büyük sapmaların daha az önemli olduğu veri setleri için kullanılabilir. Denklem (3.4)'de MAE formülü ifade edilmiştir.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (3.4)$$

Burada, y_t ölçüm verisini, $\hat{y}_t$ tahmin verisini ve n ise veri sayısını ifade eder.

MAPE ise ölçüm ve tahmin değerlerinin mutlak farkının yüzdesel ortalamasıdır. MAPE diğerlerinden farklı olarak yüzdesel oranlama yaparak veri setinin ölçeğinden

bağımsızlaşır. Böylece tahmin yapılan verilerin biriminin tahmin sonucuna etkisi ortadan kaldırılabilir. Bu durum bir algoritmanın başarısını benzer veri setleri için gözlemlerken ölçek farkından kaynaklı sonuçlardaki standardize olmama durumunu gidermiş olur.

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (3.5)$$

Burada, y_t ölçüm verisini, $\hat{y}_t$ tahmin verisini ve n ise veri sayısını ifade eder.

3.2 Mikro Şebeke Ekonomik Analizi

MŞ'lerde ekonomik analizin amacı proje maliyeti ve proje getirileri arasındaki ilişkiyi incelemektir. Böylece MŞ planlaması ekonomik olarak en verimli modele dayanarak yapılabilir. Net bugünkü değer (net present value-NPV), iç kararlılık oranı (internal rate of return-IRR), öz sermaye kararlılığı (return on equity-ROI), geri ödeme periyodu (payback period-PBP) gibi belirleyiciler farklı modelleri çeşitli yönlerle ele alan ekonomik metriklerdir. NPV bir yatırımın belirli zaman periyodundaki tüm gider ve gelirlerinin uygun faiz oranı ile bugünkü seviyeye çevrilip net değerinin bulunmasıdır. IRR ise NPV değerini sıfıra eşitleyen iskonto oranıdır. ROI belirli bir süre boyunca net gelir ile yatırım arasındaki oranı ifade eder. ROI oransal değer verdiği için farklı yatırımların getirisini karşılaştırmak için idealdir. PBP ise yatırımın ne kadar sürede kendini amorti edeceğini gösteren orandır.

$$NPV = \sum_{t=0}^n \frac{R_t}{(1+r)^t} \quad (3.6)$$

$$ROI = \frac{\text{Yatırımın şuanaki değeri} - \text{Yatırım maliyeti}}{\text{Yatırım maliyeti}} \quad (3.7)$$


Burada R_t t periyodu boyunca net gelir gider farkını ifade eder, r alternatif yatırımlardan kazanılabilecek iskonto oranını, t ise zaman periyodunu ifade eder.

3.2.1 Dağıtık Üretim Kaynakları

MŞ'lerde yüklerin ihtiyaç duydukları güç çeşitli kaynaklardan temin edilebilir. Seviyelendirilmiş enerji maliyeti (levelized cost of energy-LCOE) olarak isimlendirilen teknikte farklı elektrik üretim yöntemleri için birim başına düşen enerji maliyeti ifade edilir. Bu yöntemle elektrik üretim sisteminin ilk kurulum, işletme ve bakım, yakıt gibi tek seferli ve kalıcı giderleri göz önünde bulundurularak enerji üretimi için maliyet analizi yapmak mümkündür. Böylece LCOE sayesinde farklı elektrik üretim tesislerinin birim elektrik üretim maliyetleri hesaplanarak aralarında karşılaştırma yapılabilir. LCOE basitçe yıllık olarak tüm santral giderlerinin o yıl boyunca üretilen toplam elektrik enerjisine bölünmesi ile hesaplanır. Ancak bu formül farklı üretim santrallerine göre detaylanabilir. Örneğin kömür veya petrol gibi bir yakıt kullanan bir santralde LCOE belirlenirken yakıt maliyeti hesaba katılacakken YEK'lerde bu durum söz konusu değildir. Denklem (3.8) ile basit LCOE formülü ifade edilmiştir.

$$LCOE = \frac{\sum_{t=1}^n \frac{(I_t + M_t + F_t)}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^t}} \quad (3.8)$$

Burada I_t t yılındaki yatırım harcamalarını, M_t t yılındaki bakım ve işletme harcamalarını, F_t t yılındaki yakıt harcamalarını (eğer varsa), E_t t yılındaki üretilen toplam elektrik enerjisini, r iskonto oranını ve son olarak n üretim tesisinin beklenen ömrünü ifade eder. İskonto oranı olarak belirtilen değer, yatırım sırasında harcanacak naktin yıllar içindeki değer değişimini ifade edebilmek adına eşitliğe eklenmiştir (İnt. Kyn. 5). Şekil 3.12'de yıllara göre farklı kaynaklar için ortalama LCOE değişimi ifade edilmiştir. LAZARD kaynaklarına göre 2009 ile 2021 yılları arasında FV sistem için ortalama LCOE değeri %90 civarında düşmüşken rüzgâr enerjisinde ise %72'lik bir düşüş söz konusudur. Böylece bu iki kaynak uzun vadede elektrik enerji üretmenin en karlı yolu konumuna gelmiştir (Lazard 2021).



Şekil 3.12 Yıllara göre farklı teknolojiler için \$/MWh cinsinden LCOE ortalamaları.

3.2.1.1 FV Sistem Ekonomik Modeli

FV sistemin verimliliğini etkileyen çeşitli faktörler vardır. İlk olarak panelin üretildiği malzeme sistemin verimliliğinde direkt olarak etki gösterir. Güneş hücresi üretiminde yaygın olarak kullanılan kristal silikon (c-Si) yarıiletken materyali güneş ışığını verimli bir şekilde elektriğe çevirme imkânı sunar. Buna alternatif olarak kadmiyum tellür (CdTe) ve bakır indiyum galyum selenid (CIGS) kullanan ince film olarak adlandırılan FV sistemler panel üretiminin maliyetini düşürse de bununla birlikte panellerin verimliliği düşmüştür.

Panel üretiminde kullanılan madde dışında sistem verimliliğini etkileyecek başka unsurlarda vardır. Güneş ışınlarının panel üzerinde dik bir şekilde düşmesi, panelin güç üretimini etkiler. Bu nedenle panellerin montajı maksimum güneşlenme için uygun konumlara ve uygun eğimlerle yapılmalıdır. Ayrıca yüksek sıcaklık ve panellerin üzerine düşen gölge veya tozlanma gibi durumlar panelin verimliliğini düşürür. Ayrıca panel

tarafından soğurulan enerjinin maksimum verimle şebekeye aktarılması için uygun özelliklere sahip eviriciler (inverter) kullanılmalıdır.

Güç üretimi birçok parametreden etkilenen FV sistemde yüklerin talep ettiği güce cevap verebilmek adına panel sayısını belirlemek önemlidir. FV sistemler kurulumları nedeniyle yüksek maliyete ve sürekli bakım giderlerine sahiptirler. Bu nedenle panel özelliklerine göre kurulum, evirici, işletme ve bakım (İ&B) maliyeti gibi giderlere karşılık elektrik üretimine bağlı gelir formülize edilerek yatırım ve gelir ilişkisi belirlenmelidir. Denklem (3.9) ile FV sisteme yapılan yatırımın ekonomik olarak geri dönüş süresi hesaplanabilir (Smestad 2008).

$$Amorti\ süresi = \frac{x\ \$/m^2}{\eta \cdot \frac{5kWh}{gün.m^2} \cdot \frac{365gün}{yıl} \cdot \frac{elektrik\ fiyatı(\$)}{kWh}} \quad (3.9)$$

Burada $x\ \$/m^2$ solar panelin metrekare fiyatını ve η ise solar panelin verimlilik katsayısını belirtir. Ayrıca piyasada panellerin satış fiyatı genellikle metrekare yerine watt başına düşen fiyat olarak ifade edildiğinden denklem (3.10) ile bu çevrimi yapmak mümkündür. Burada W_p maksimum güç üretim anında (pik) üretilen güç anlamına gelmektedir.

$$$/W_p = \frac{x\ \$/m^2}{\eta \cdot 1000W_p/m^2} \quad (3.10)$$

Solar panelin metrekare fiyatını, verimlilik katsayısı ve kurulu bölgedeki elektrik piyasaya satış fiyatı denklem (3.9)'a yerleştirildiğinde ve sadeleştirmeler yapıldığında yıl bazından amorti süresi hesaplanmış olur.

FV sistemdeki tek maliyet unsuru solar modül değildir. Bununla beraber sistem dengesi (balance of system) olarak adlandırılan kurulum yeri, metal konstrüksiyon sistemleri aküler, kablolar gibi ek masraflarda sistem gideri olarak bulunur. Ayrıca pik güneş ışıması üzerinden yapılan güç üretimi hesabı, ortalama ışıma üzerinden yapılarak sistem piyasa uygulamaları için uygun hale getirilebilir.

Bu unsurlar göz önünde bulundurularak FV sistem için elektrik maliyeti yani LCOE denklem (3.11)'deki gibi hesaplanabilir (Smestad 2008).

$$\frac{\text{Maliyet}}{kWh} = \frac{\text{Sistem maliyeti} \left(\frac{\$}{m^2} \right) \cdot \text{amortizasyon}}{\text{Yılda üretilen elektrik}(kWh)} + \text{İ\&B} \quad (3.11)$$

Amortizasyon oranı iskonto oranına bağlı olarak denklem (3.12)'deki gibi hesaplanır.

$$\text{amortizasyon} = \frac{r}{[1 - (1 + r)^{-N}]} \quad (3.12)$$

Burada r iskonto oranını, N ise panel ömrünü belirtmektedir. Sonrasında denklem (3.11)'deki ilgili terimler yerine konulduğunda denklem (3.13) elde edilir.

$$\frac{\$}{kWh} = \frac{\text{Modül} \left(\frac{\$}{m^2} \right) + \text{Montaj} \left(\frac{\$}{m^2} \right) + \text{Inverter} \left(\frac{\$}{kW} \right) \cdot \eta}{\eta \cdot \frac{5kWh}{gün \cdot m^2} \cdot \frac{365gün}{yıl}} \cdot \text{amortizasyon}(1 + \text{Indirekt}) + \text{İ\&B} \quad (3.13)$$

Sistem maliyetini oluşturan unsurlar modül montaj ve inverter maliyetleridir. Direkt giderler ekipman ve iş gücü maliyeti olurken indirekt giderlere ise mühendislik giderleri dahildir. Böylece farklı gider grupları göz önünde bulundurularak FV sistem için elektrik üretim maliyeti analiz edilmiş olur. Bu MŞ'ler için en ekonomik kaynakları belirlemekte önemlidir.

3.2.1.2 Rüzgâr Enerjisi Sistemi Ekonomik Modeli

Rüzgâr enerjisinde de FV sisteme benzer şekilde sistemin güç üretimini etkileyen belirli farklılıklar olsa da bu sistemlerin ekonomik analizleri benzer şekilde yapılır. Genellikle türbin dönme şeklinin farkından dolayı yatay veya dikey eksenli olarak sınıflandırılan rüzgâr enerji sistemleri, konumlandırıldığı yerin kara veya deniz oluşu ile de farklı sınıflara ayrılır. Farklı sınıflar sistemler arasında ekonomik anlamda farklar oluşturur. Örneğin dikey eksenli rüzgâr türbinleri daha düşük kurulum maliyetleri olmasına rağmen enerji üretimi konusunda yatay eksenli türbinlere göre yetersizdir. Başka bir örnek ise


deniz üstü rüzgâr enerjisinin çevre koşulları nedeniyle ilk kurulum maliyetleri kara üstüne göre oldukça yüksek olmasıdır (Liu vd. 2023).

$$LCOE = \frac{I - \sum_{t=1}^n \frac{d_t \cdot t_t}{(1+r)^n} + \sum_{t=1}^n \frac{M \cdot (1-t_t)}{(1+r)^n} - \frac{V}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^n} \cdot (1-t_t)} \quad (3.14)$$

Rüzgâr enerjisi için LCOE hesabı denklem (3.14)'de olduğu gibi yapılabilir. Burada I yatırım maliyetini, M bakım ve işletme maliyetini, E_t t yılındaki üretilen toplam elektrik enerjisini, d_t t yılındaki amortisman maliyetini, t_t t yılındaki vergi oranını, V sabit değer yatırımını ve r ise iskonto oranını ifade etmektedir.

3.2.1.3 Dizel Jeneratör Ekonomik Modeli

Dizel jeneratörler için LCOE hesaplanırken FV ve rüzgâr sistemlerinden farklı olarak yakıt giderleri hesaba katılmaktadır. FV ve rüzgâr sistemlerinde yatırımın büyük kısmı sistemin kurulumu sırasında yapıp işletme sırasında çok daha az maliyetler harcanırken dizel jeneratörler ile elektrik üretimi sırasında yakıt maliyeti ana maliyet unsuru konumundadır. Bu nedenle dizel jeneratörler uzun vadede elektrik üretimi açısından ekonomik olmaktan uzaktır. Ancak şebeke yüklerinin acil ve devamlı enerji talebine cevap verebilmesi ve enerji üretimi sırasında yenilenebilir kaynaklarda olduğu gibi kesintisiz kaynak davranışı olmaması nedeniyle MŞ'lerin önemli enerji sağlayıcılarındandır. Şekil 3.13 dizel jeneratörlerin kurulum, işletme ve yakıt maliyetinin dağılımını ifade etmektedir (Oviroh ve Jen 2018).



Şekil 3.13 Dizel jeneratör LCOE unsurlarının dağılım grafiği.

3.3 Sanal Mikro Şebeke Tasarlanması

Bu bölümde bir MŞ'deki yükleri ve enerji kaynaklarını simüle etmek için HOMER Pro yazılımından faydalanılmıştır. HOMER yazılımı kullanıcıların enerji maliyetini belirlemek için şebeke içerisinde çeşitli kaynaklar ve yük profilleri oluşturularak analiz ve planlama yapma olanağı sunmaktadır. Böylece DÜK'ler farklı senaryolar üzerinden değerlendirilerek MŞ kaynakları en verimli ve en kısa amortisman süresine sahip olacak şekilde seçilebilir. Kaynakların ilk kurulum maliyetleri ve yıllar içerisindeki işletme bakım ve yakıt gibi giderleri de maliyet hesabına dahil edilir. Ayrıca MŞ'nin ana şebekeye bağlı olarak işletilme ve şebekeye geri enerji satışından kaynaklı mali getiriler de analize dahil edilebilir. Bu çalışmada DÜK olarak güneş enerjisi, rüzgâr enerjisi ve dizel jeneratörler seçilmiştir. Simülasyon yazılımı MŞ'deki enerji kaynaklarının ömrü boyunca saatlik performansını modelleyerek maliyet hesabını yapabilmektedir. Bununla birlikte yük profili için ise yapılan tahmin sonucu elde edilen veri seti tanımlanmıştır. Ayrıca enerji depolama birimleri olan bataryalar ve AC/DC ve DC/AC enerji dönüşümü sağlayacak güç elektroniği elemanları simülasyonda belirtilmiştir. MŞ'nin ana şebeke ile senkron bir şekilde güç alışverişi yapabilmesi için şebeke özellikleri belirlenmiştir. Çizelge 3.4'de sanal MŞ'de bulunan enerji kaynakları, bataryalar ve güç çeviricileri için birim bazında maliyet unsurları belirtilmiştir.

Çizelge 3.4 MŞ elemanlarının maliyet unsurları.

MŞ Unsurları (1kW)	Kurulum Maliyeti (\$)	Yenileme Maliyeti (\$)	İ&B (\$/Yıl)	Yakıt (\$/Litre)
Jeneratör	600	600	0.1(saat)	1.18
FV	1333.3	1333.3	10	0
Rüzgâr türbini	2000	2000	360	0
Kurşun asit akü 12V	200	200	10	0
Güç çevirici	300	300	0	0

Çizelge 3.4'de tanımlanan unsurlar her bir eleman için 1kW'lık birim kapasitesi içindir. Örneğin MŞ için 1.5MW'lık güneş santrali inşası için belirlenen maliyetlere göre 2

milyon dolar, yenileme maliyeti 2 milyon dolar ve yıllık işletme ve bakım giderleri 15 bin dolar olacaktır. Bu kaynakların tam kapasitesi yüklerin ihtiyacı doğrultusunda analiz sonucu belirlenecektir. Böylece her bir MŞ unsuru için belirlenen kapasiteye göre kurulum, yenileme, İ&B ve yakıt giderleri gözlemlenecektir.

Son olarak MŞ enterkonnekte şebekeye bağlı işletilebilecek şekilde tasarlanmıştır. Bunun nedeni MŞ bünyesinde YEK'lere bağlı düzensiz üretimden kaynaklı enerji talebine karşılık verilemediği anlarda yüklere elektrik sağlayabilmektir. Ayrıca bunun tersi olarak kaynak tüketmeden elektrik üretebilen YEK'lerin talep fazlası ürettiği artık konumdaki enerjinin enterkonnekte şebekeye satılmasıyla MŞ ekonomik gelir elde edebilir. Bu nedenle MŞ ve enterkonnekte şebeke arasındaki çift taraflı güç alışverişi için bir tarife belirlenmiştir. PJM açık kaynak verilerine göre MŞ'nin tasarlandığı bölge olan ABD'nin Pensilvanya eyaleti için güncel ortalama elektrik fiyatı kW başına 18.3 Cent olarak belirlenmiştir. Bu fiyat elektrik satışına dayalı gerçek zamanlı fiyatlandırma durumu ihmal edilerek enterkonnekte şebekeden alınan elektrik için sabit değer haline getirilmiştir. Enerji satış fiyatı ise ülkeden ülkeye değişmekle birlikte genellikle satın alınanın %10'u ila %20'si arasında belirlenmektedir. Ancak bu tasarımın temiz enerjiyi teşvik edilebileceği düşünülerek bu oran bir olarak belirlenmiştir. Yani şebekeden enerji satın almanın veya şebekeye enerji satmanın kW bazında fiyatı aynıdır (İnt. Kyn. 8).

4. BULGULAR

Bu tez çalışması ile elde edilen bulgular iki ana başlık altında toplanmıştır. Bunlardan ilki çeşitli algoritmalar kullanılarak yapılan elektriksel yük tahminlerinin performans metrikleri ve eğitim hızları üzerinden karşılaştırılmasıdır. İkincisi ise bilgisayar ortamında analiz edilen bir sanal MŞ'nin farklı senaryolar üzerinden elektrik üretim maliyetinin karşılaştırılmasıdır. Böylece DÜK'lere yapılan yatırım enerji üretim maliyetinin en düşük olduğu senaryoya göre belirlenebilir. MŞ için yatırım maliyeti ve bu yatırım sayesinde zamana yayılarak azalan elektrik üretim maliyeti analiz edilerek yapılan yatırımın kârlılığı ifade edilebilir. Bu analiz hem projenin kârlılığı açısından hayata geçirilip geçirilmemesi için önemli bir anlam taşırken hem de projenin mali açıdan amorti süresi hakkında yorum yapmaktadır.

4.1 Elektriksel Yük Tahmini

Bu çalışmada elektriksel yük tahmini LR, RA, DVR ve GSR algoritmaları için MATLAB 2020b yazılımına ait “Regresion Learner” aracı kullanılarak yapılmıştır. Veri setinin tamamı vektör dizisi olarak tahmin aracına aktarıldıktan sonra geniş veri setlerinde kullanılması tavsiye edilen uzatma validasyonu seçeneği aktif edilmiştir. Her bir algoritma kernel fonksiyonları ile farklılaşan tipteki modeller için eğitilmiştir. LR için lineer, intereactions, robust ve stepwise tipleri, RA için fine, medium ve coarse tipleri DVR için lineer, kuadratik, kübik, fine gaussian, medium gaussian, coarse gaussian tipleri ve GSR için kare, matern 5/2, üstel ve rasyonel kuadratik tipleri kullanılmıştır. Farklı modellerin eğitim başarısı MAE, MSE, RMSE ve R^2 ölçütlerine göre değerlendirilerek Çizelge 4.1 ile sunulmuştur. Buna ek olarak her bir modelin eğitim süreside çizelgede gösterilmiştir.


Çizelge 4.1 Farklı tahmin modellerinin performans metriklerine göre değerlendirilmesi.

Algoritma	MAE	MSE	RMSE	R^2	Eğitim Süresi
Lineer Regresyon					
LR	185.45	57161	239.08	0.34	6.61s
Interactions LR	92.21	14003	118.33	0.84	11.64s


Çizelge 4.1 (Devam) Farklı tahmin modellerinin performans metriklerine göre değerlendirilmesi.

Robust LR	180.73	60098	245.15	0.31	10.91s
Stepwise LR	92.27	14011	118.37	0.84	1811.5s
Regresyon Ağacı					
Fine RA	51.85	5447	73.80	0.94	22.07s
Medium RA	53.78	5612.4	74.92	0.94	9.81s
Coarse RA	60.43	6885.5	82.98	0.92	8.90s
Destek Vektör Regresyonu					
Lineer DVR	180.56	60649	246.27	0.30	492.15s
Kuadratik DVR	84.647	12858	113.39	0.85	852.24s
Kübik DVR	56.059	5847.7	76.47	0.93	1930.4s
Fine Gaussian DVR	35.851	2944.4	54.262	0.97	1541.1s
Medium Gaussian DVR	48.935	4708.3	68.617	0.95	633.49s
Coarse Gaussian DVR	95.331	14992	122.44	0.83	1004.9s
Gauss Süreç Regresyonu					
Kare GSR	47.536	4289.8	65.497	0.95	42571.s
Matern 5/2 GSR	44.904	3863.4	62.156	0.96	5251.8s
Üstel GSR	26.6	1601.6	40.02	0.98	6569.8s
Rasyonel kuadratik GSR	46.963	4200	64.808	0.95	6187.2s


Değerlendirme yapılan performans metrikleri göz önünde bulundurularak Çizelge 4.1 incelendiğinde LR tipleri arasında interactions LR'nin en düşük hata oranına sahip olduğu görülmüştür, benzer şekilde RA tipleri arasında fine RA, DVR tipleri arasında fine gaussian DVR ve GSR tipleri arasında da üstel GSR kendi kategorileri arasında en başarılı eğitim modeli olmuştur. Bu dört modele ait cevap grafiği Şekil 4.1'de sunulmuştur. Cevap grafiğindeki mavi noktalar verisindeki gerçek çıktıları ifade ederken sarı noktalar ise eğitim sonucu tahminlere karşılık gelen değerlerdir. Şekil 4.1(a)'da görülen interactions LR modeline ait olan cevap grafiği olup grafiğin yüksek ve düşük değerleri yakalamakta oldukça zorlanarak hata miktarının fazla olduğu görülmektedir. Diğer üç model için gerçek ve tahmin değerlerini ifade eden mavi ve sarı noktaların daha iyi örtüştüğü görülmüştür.




(a) interactions LR



(b) fine RA



(c) fine gaussian DVR




(d) üstel GSR

Şekil 4.1 (a) Interactions LR için cevap grafiği, (b) fine RA için cevap grafiği, (c) fine gaussian DVR için cevap grafiği, (d) üstel GSR için cevap grafiği.

Şekil 4.2’de ise bu dört model ile yapılan tahmin için regresyon grafiği sunulmuştur. Grafikte yatay eksen gerçek cevap değerlerini ifade ederken dikey eksen tahmin değerlerini ifade etmektedir. Tahmin değeri ve gerçek değerin birbirine eşit olması durumunda yani mükemmel tahminde mavi noktalarla ifade edilen gözlem noktalarının $y=x$ doğrusu üzerinde olması gerekir. Böylece siyah doğru ile gösterilen mükemmel tahmin doğrusu oluşmaktadır. Gözlem noktalarının bu doğruya yakınlığı o değer için tahminin ne kadar başarılı olduğunu ifade etmektedir. Grafikten yorumlandığı üzere performans metriklerine paralel şekilde Şekil 4.2(d)’de görülen üstel GSR modelinde gözlem noktaları regresyon çizgisi etrafında diğer üç modele göre daha az yayılmıştır. Bu durumda karşılaştırılan dört model arasında tahminlerin en az gerçek değerinden saptığı model üstel GSR olmuştur. Üstel GSR için MAE değeri 26,6, MSE 1601,6, RMSE 40,02

ve R^2 0,98 olarak hesaplanmıştır. Karşılaştırılan 17 model arasında üstel GSR en başarılı performansı sunuyor olmasına rağmen 110 dakika civarı eğitim süresi ile tüm modeller arasındaki en yavaş eğitim sürecine sahiptir.




Şekil 4.2 (a) Interactions LR için regresyon grafiği, (b) fine RA için regresyon grafiği, (c) fine gaussian DVR için regresyon grafiği, (d) üstel GSR için regresyon grafiği.

Diğer bir tahmin yöntemi olan YSA için MATLAB yazılımının “Neural Net Fitting” aracından yararlanılmıştır. 12 giriş parametresi ve bir hedef parametresi sütun vektörü şeklinde eğitim için modele aktarılmıştır. Gizli katmandaki nöron sayısı 22 ve eğitim algoritması BR olarak seçildikten sonra YSA modeli eğitilmiştir.

Çizelge 4.2 YSA modeli eğitim, validasyon ve test verileri için performans değerlendirmesi.


Algoritma	Örnekleme sayısı	MSE	R
Eğitim	49846	57161	0.97761
Validasyon	10681	14003	0.97662
Test	10681	60098	0.97828

YSA modeli için eğitim, validasyon ve test verisi olarak sınıflandırılan toplam 71208 veri örneğine ait eğitim performansı değerlendirmesi Çizelge 4.2’de sunulmuştur. YSA modelinin eğitimi 214 iterasyonda tamamlanmış olup tamamlanması 59 saniye sürmüştür. Şekil 4.3’de YSA modeline ait performans grafiği verilmiştir. MSE değeri 20. iterasyonla beraber kabul edilebilir seviyelere düşmüş olmasına rağmen 214 iterasyon yapılarak MSE’nin minimum değerine ulaştığı görülmüştür.



Şekil 4.3 YSA modeli eğitim, validasyon ve test verileri performans grafiği.

Şekil 4.4’de eğitim, validasyon ve test veri setleri için regresyon doğruları görülürken ortalama korelasyon katsayısı 0,97756 olarak hesaplanmıştır.




Şekil 4.4 YSA modeli eğitim, validasyon ve test verileri için regresyon grafiği.

Eğitim sonundaki performans değerlendirmelerinde en başarılı iki model olan üstel GSR ve YSA modelleri ile tahmin yapabilmek amacı ile tahmin fonksiyonları oluşturulmuştur. Veri setinin son iki haftasına karşılık gelen 336 saatlik veri fonksiyonlara girdi olarak aktarıldıktan sonra cevap değişkenleri elde edilmiştir. Tahmin yapılan zaman aralığı için yük verisinin ölçülen ve tahmin edilen değerleri karşılaştırılmıştır. Çizelge 4.3’de tahmin sonrası gerçek ve tahmin edilen değerler arası hata farklı performans metrikleri ile değerlendirilmiştir. Tahmin verilerinin bir kısmı EK 3.’de sunulmuştur. Ayrıca Ek 4.’de modellere ait tahmin çıktıları ile gerçek veriler grafik halinde sunulmuştur.


Çizelge 4.3 Üstel GSR ve YSA modelleri ile tahmin sonuçlarının değerlendirilmesi.

Algoritma	MAE	MSE	RMSE	MAPE	R2
Üstel GSR	49.2188	3785	61.5277	3.6035	0.8727
YSA	32.1582	1707	41.3271	2.3326	0.9025


YSA modelinin tüm performans metriklerinde daha başarılı olduğu görülmektedir. Aynı zamanda YSA modelinin eğitim süreci üstel GSR modeline göre çok daha hızlı tamamlanmıştır. Modellere ait regresyon katsayıları ve doğruları Şekil 4.5’de ifade edilmiştir. Şekil 4.6’de üstel GSR modeli tahmin verileri ile ölçüm verileri tek bir grafik ile gösterilmiştir. Şekil 4.7 ise benzer biçimde YSA modeli tahmin verileri ile ölçüm verileri görsel olarak ifade edilmiştir. Grafiklerden gözlemlendiği üzere her iki modelde genel olarak günleri yakalamada başarılı olmasına rağmen tüketimin maksimum veya minimum olduğu tepe noktalarını yakalamada zorlanmıştır. Regresyon modellerinin hata ölçümünde sıklıkla kullanılan RMSE metriğinde hatanın karesi alındığı için verilerdeki büyük sapmaların ağırlığı daha fazladır. Tepe noktalarındaki sapmaların daha az olduğu grafiklerden ve benzer şekilde RMSE değerinden görüldüğü üzere YSA modelinin bu çalışmanın geri kalan kısmı için tahmin modeli olarak kullanılmasına karar verilmiştir. Çalışmanın ikinci kısmında YSA modeli aracılığı ile elde edilen tahmin verileri sanal mikro şebekenin yük profilini oluşturmaktadır. Bu yük tahmini üzerinden MŞ için ekonomik analiz yapılarak yatırım ve kazanç ilişkisi yıllara yayılarak gözlemlenmiştir.



Şekil 4.5 Gerçek değerler ile YSA ve üstel GSR model çıktılarının karşılaştırılması




Şekil 4.6 Gerçek değerler ve üstel GSR tahmin değerlerinin karşılaştırma grafiği.



Şekil 4.7 Gerçek değerler ve YSA tahmin değerlerinin karşılaştırma grafiği.

4.2 Elektrik Üretim Maliyeti Karşılaştırılması

Çalışmanın bu bölümünde 25 sene üzerinden projelendirilen sanal MŞ'nin ekonomik analizi yapılmıştır. DÜK'lerin farklı kombinasyonları ile oluşturulan senaryolar baz durum ile karşılaştırılarak IRR, ROI ve amorti süreleri hakkında yorum yapılmıştır. Herhangi bir yatırım yapılmadan önceki durum yani yüklerin elektrik ihtiyacını enterkonnekte şebeke vasıtasıyla karşıması baz durum olarak adlandırılmıştır. FV, rüzgâr gücü, dizel jeneratör ve bataryalar üzerinden ise diğer senaryolar oluşturulmuştur. Şekil 4.8'de tasarlanan MŞ görülmektedir. Dizel jeneratör, şebeke bağlantısı ve rüzgâr türbini AC baraya yapılırken FV ve batarya bağlantısı DC bara üzerinden sağlanmıştır. DC ve AC güç baraları arasına güç dönüşümünü sağlayan güç elektroniği ekipmanları yerleştirilmiştir.



Şekil 4.8 Tasarlanan sanal MŞ.


Homer Pro yazılımının altyapısı ile MŞ kaynaklarının farklı oranlarında kullanımından doğan kombinasyonlar kategorize edilerek 8 yeni senaryo oluşturulmuştur. Çizelge 4.4'de her bir senaryo için NPV, kurulum maliyeti, işletme bakım maliyetleri ve LCOE değeri ifade edilmiştir. Çizelgede kaynakları daha rahat belirtebilmek için dizel jeneratör D, FV sistem FV, rüzgâr türbini R ana şebeke Ş ve batarya B olarak ifade edilmiştir. Senaryolar Çizelge 4.4'de NPV değerine göre küçükten büyüğe sıralanmış olup tabloda karışıklığı engellemek adına milyon M harfi ile milyar ise B harfi ile gösterilmiştir. Analizler sonucunda en düşük enerji üretim maliyeti olan senaryo FV, rüzgâr gücü ve ana şebekenin enerji kaynağı olarak kullanıldığı durum olarak saptanmıştır.

Çizelge 4.4 MŞ senaryoları için ekonomik analiz.

Senaryo	NPV	Kurulum Maliyeti	İşletme Maliyeti	LCOE
FV+R+Ş	23.9B\$	11.2B\$	981M\$/Y	0.122\$/kWh
R+Ş	25.0B\$	8.14M\$	1.3B\$/Y	0.131\$/kWh
FV+R+B+Ş	25.0B\$	8.12B\$	1.31B\$/Y	0.132\$/kWh
FV+R+D+Ş	25.3\$	13.2B\$	940M\$/Y	0.129\$/kWh
FV+R+D+B+Ş	26.4B\$	9.92B\$	1.28B\$/Y	0.139\$/kWh
FV+B	27.5B\$	7.80B\$	1.52B\$/Y	0.148\$/kWh
Ş	31.4B\$	0\$	2.43B\$/Y	0.183\$/kWh
D+Ş	32.8B\$	1.80B\$	2.39B\$/Y	0.191\$/kWh


En düşük maliyetli senaryoda (FV+R+Ş) toplam 3 369MW güce sahip FV santral ile beraber 3 057 MW güce sahip rüzgâr santrali kurulması önerilmiştir. Ayrıca DC kaynak kullanımından kaynaklı 2 129 MW’lık konverter kullanılmıştır. Ayrıca bu senaryoda MŞ ihtiyaç durumunda enterkonnekte şebeke ile güç alışverişi yapabilmektedir. Baz durumda yani sadece ana şebeke üzerinden elektrik ihtiyacının karşılandığı durumda LCOE olarak ifade edilen birim elektrik enerjisi maliyeti 0.183\$/kWh iken önerilen en düşük maliyetli senaryoda LCOE 0.122\$/kWh olarak görülmüştür. Bu durum önerilen senaryo ile birim başına düşen elektrik maliyetini %33,3 oranında düşürmüştür.

Şekil 4.9’da önerilen senaryo ve baz durum için yirmi beş senelik nakit akışı ifade edilmiştir. Baz durumda MŞ’nin yüklere enerji sağlayabilmesi için enterkonnekte şebekeden yıllık yaklaşık 2,5 milyar dolar değerinde elektrik alması gerektiği görülürken önerilen senaryoda proje başlangıcında yapılan 11,2 milyar dolar değerindeki yatırımdan sonra yıllık 1 milyar doların altında bir işletme maliyeti oluşmaktadır. Yirminci yılda rüzgâr türbinlerinin ömrünün dolması nedeniyle yenileme maliyeti olarak 5 milyar doların üzerinde bir nakit akışı olmuştur. FV panellerin ömrü proje ömrü olarak belirlenen sürenin ardında tamamlandığı için bu durum FV panellerde söz konusu değildir. Yirmi beş yıllık proje sonunda yapılan yatırım değerleri projenin net değerini görebilmek adına nakte çevrilmiştir. Bunun sonucu olarak 4 milyar civarı bir naktin içe aktarıldığı görülür.



Şekil 4.9 Sunulan ve baz durum için 25 yıllık nakit akış grafiği.

Şekil 4.10'da bir yıllık sürede FV, şebeke ve rüzgâr kaynakları için aylık elektrik üretimi MW cinsinden ifade edilmiştir. Yaz aylarında hava şartlarının etkisiyle FV sistemden üretilen elektriğin paydasının diğer aylara göre daha fazla olduğu görülmektedir. Bunun tersine kışın artan rüzgâr hızları ile rüzgâr türbinlerinin ürettiği güç dolayısı ile şebekedeki üretim oranı artmıştır. Yazın ise düşen rüzgâr hızına bağlı azalan rüzgâr enerjisinin üretim açığı ana şebekeden satın alınan elektrik enerjisi ile kapatılmıştır.



Şekil 4.10 Farklı kaynaklar için aylık elektrik üretimi.


Bu durumda yıl boyunca üretilen toplam enerjinin %24,9'u FV sistem tarafından ve %37,1'i rüzgâr santrallerince üretilirken kalan %38'lik kısım ana şebekeden satın alınmıştır. Yıl boyunca karşılanamayan yük talebi olmazken MŞ'de üretilen elektriğin %7,13'ü talep fazlası olarak ana şebekeye satılmıştır. Ayrıca şebeke yüklerinin kullandıkları enerjinin %67,4'ünün yenilenebilir kaynaklı üretim olduğu görülürken MŞ ve enterkonnekte şebekede üretilen toplam enerjinin %62'sinin yenilenebilir kaynaklı enerji olduğu gözlemlenmiştir. Bu durum sunulan şebekenin yalnızca ekonomik oluşu değil aynı zamanda yeşil enerji üreten bir tasarım olduğunu göstermektedir.

Çizelge 4.5 MŞ ve enterkonnekte şebeke arasındaki ay bazında enerji alışverişi.

Senaryo	Satın Alınan Enerji (MWh)	Satılan Enerji (MWh)	Net Enerji (MWh)	Toplam Maliyet (\$)
Ocak	497168.4	226569.5	270598.9	49.5M
Şubat	395818.1	215557	180261.2	33.0M
Mart	369313.2	243102.3	126210.9	23.1M
Nisan	387727.9	220034.3	167693.6	30.7M
Mayıs	446474.7	146923.4	299551.3	54.8M
Haziran	609882.8	94436.64	515446.2	94.3M
Temmuz	749465.4	51638.84	697826.6	128M
Ağustos	763614	74536.84	689077.1	126M
Eylül	612157.1	115243.1	496914	90.9M
Ekim	440717.2	157726.3	282990.9	51.8M
Kasım	484007.8	160870.8	323137	59.1M
Aralık	507002.3	165407.1	341595.3	62.5M
Toplam	6263349	1872046	4391303	804M

Çizelge 4.5 bir yıllık süre boyunca aylık olarak MŞ ve ana şebeke arasındaki enerji akışını göstermektedir. Birinci sütunda MŞ'nin satın aldığı enerji görülürken ikinci sütunda ise sattığı enerji görülmektedir. Bu ikisinin farkı olan net enerji miktarı üçüncü sütunda ve bu net enerjiden doğan maliyet ise dördüncü sütunda ifade edilmiştir. Şekil 4.11 ile


şebekeden satın alınan ve şebekeye satılan enerjiyi miktarı görsel olarak sunulmuştur. Şekil 4.10, Şekil 4.11 ve Çizelge 4.5’den benzer şekilde yorumlandığı üzere yaz aylarında verimliliği düşen rüzgâr santrallerinin sonucu olarak şebekeden satın alınan enerji miktarı bu dönemde oldukça artmıştır. Yılın ilk yarısı ise şebekeye satılan enerji miktarı oldukça yüksektir. Yıl boyunca toplamda satın alınan enerji satılanın üç katından fazla olup bu enerjinin toplam maliyeti MŞ için 804 milyar dolardır.



Şekil 4.11 Yıllık şebekeden satın alınan ve satılan enerji grafiği.

Yirmi beş yıl için yapılandırılan proje için yatırım iç getiri oranı olarak ifade edilen IRR %12,4 olarak hesaplanırken yatırım getirisi ifade eden ROI %8,9 olarak hesaplanmıştır. Şekil 4.12’de yirmi beş sene için en düşük maliyetli senaryo ve baz durum için nakit akış grafiği gösterilmektedir. Grafikte mavi çizgi en düşük maliyetli senaryoyu ifade ederken gri çizgi ise baz durumdur. Projenin başında mavi çizgi ile 0\$ arasındaki fark yatırım maliyetini gösterir. Baz durumunda ise herhangi bir yatırım yapılmadığı için gri çizgi sıfır değerinden başlar. Fakat önerilen senaryodaki daha düşük elektrik üretim ve işletme maliyetleri nakit akış farkını yıllar içerisinde git gide azaltırken 7,36 yıllık süre sonrası yatırım kendini amorti etmektedir. Sonraki yirmi beş yıllık süre boyunca senaryolar arasındaki nakit akışı makasının en düşük maliyetli sistem lehine git gide açıldığı

görülürken projede yirmi beş senelik süre sonrasında 25 milyar dolara yakın kar edilmesi beklenmektedir.



Şekil 4.12 25 senelik süre periyodu için baz ve en düşük maliyetli senaryolar için kümülatif nominal nakit akışı eğrisi.

5. TARTIŞMA ve SONUÇ

Son yıllarda elektrik ihtiyacına olan talebin giderek artması ve ülkeler arası politikaların sonucu enerji krizleri yaşanması enerjide bağımsızlığın önemini ortaya koymuştur. Bu nedenle hem güneş ve rüzgâr enerjisi gibi YEK'lerin kolay entegrasyon sağladığı hem de bünyesinde bulunan diğer DÜK ve EDS'ler ile kapsadığı konumdaki tüketicilerin elektrik ihtiyacını dış kaynaklara minimum gereksinim ile karşılayabilen MŞ'lerin yaygınlaşması bağımsız ve temiz enerjinin yolu olabilir. MŞ'ler enterkonnekte şebekeden bağımsız bir şekilde işletilebileceği gibi ana şebekeye bağlı olarak da işletilebilir. Böylece MŞ kullanıcılarının enerji talebine bünyesindeki enerji üretim kaynakları ile cevap veremediğinde ana şebekeden enerji aktarımı yapılabilir. Benzer şekilde özellikle YEK'ler tarafından üretilen elektrik enerjisi talep edileni aşarsa bu artık enerji belirlenen tarifeler üzerinden ana şebekeye satılarak MŞ için ek gelir oluşturulabilir. Bu durumlar göz önünde bulundurulduğunda hem elektrik üretiminde yüksek yenilenebilir enerji penetrasyonuna sahip oluşu hem de kesintisiz, güvenilir ve dış kaynaklara minimum bağımlı yapısı ile MŞ enerji sektörünün geleceği için önemlidir.

Bu çalışma ile Amerika Birleşik Devletleri'nde bölgesel bir elektrik sağlayıcısı olarak hizmet veren PJM Interconnection bünyesinde var olan Duqense bölgesi için bir MŞ tasarımı yapılmıştır. Bölgenin yük profili geçmiş dönem yük ve hava durumu verileri incelenerek istatistiksel ve makine öğrenmesine dayalı yöntemler ile incelenmiştir. Yedi yıllık veri seti üzerinden eğitilen LR, RA, SVR, GSR ve YSA modelleri için performans değerlendirmeleri yapılmıştır. Modellerin eğitim performansı R^2 parametresi ile değerlendirilerek LR için 0,84, RA için 0,94, DVR için 0,97, GSR için 0,98 ve YSA için 0,98 olarak hesaplanmıştır. Eğitim performansı en başarılı iki model olan YSA ve GSR yöntemleri için tahmin modeli oluşturularak yapılan tahmin gerçek değer ile karşılaştırılmıştır. Bunun sonucunda ortalama mutlak yüzde hata (MAPE) değeri YSA için %2,3326 ve GSR için ise %3,6035 olarak hesaplanmıştır. YSA yöntemi hem uygulanan diğer yöntemler arasında en başarılı tahmin modelini oluşturması hem de performansına yakın diğer metotlara göre çok daha hızlı eğitim süresi sunması nedeniyle bu çalışmanın geri kalan kısmında yük tahmin metodu olarak kullanılmıştır.

Tezin son aşamasında Duqense bölgesi için tasarlanan MŞ'nin ekonomik analizi HOMER Pro yazılımı kullanılarak yapılmıştır. Analizler sonucu MŞ yüklerine en düşük maliyetle enerji sağlayabilmek için FV, rüzgâr, dizel jeneratör, batarya ve ana şebeke kaynakları optimum şekilde kapasitelendirilmiştir. Bunun sonucunda MŞ yıllık enerji ihtiyacının %24,9'unu 3 696 MW güce sahip FV santral tarafından, %37,1'ini 3 057 MW güce sahip rüzgâr santrali tarafından ve kalan %38'lik kısmını da enterkonnekte şebekeden karşılamaktadır. Duqense bölgesinin yer aldığı Pensilvanya eyaleti için birim şebeke elektrik fiyatı bir önceki yıla oranla %26,3'lik yüksek bir artışla 18.29 ¢/kWh olmuştur. Bu tez ile sunulan MŞ 11,2 milyar dolar yatırım bedeli karşılığında birim elektrik üretim değerini 12,2 ¢/kWh'a düşürmüştür. Ekonomik analizler sonucu projenin kârlılığını bildiren sermaye bütçe ölçüsü olan IRR %12 olarak hesaplanırken yatırımın genel getirisi hakkında bilgi veren ROI %8,9 olarak hesaplanmıştır. Ayrıca projenin yatırım maliyetini yaklaşık olarak 7,4 yılda amorti ederek kâr etmeye başlayacağı öngörülmektedir. Proje süresi olan yirmi beş yılın sonunda ise 25 milyar dolar civarı kâr beklenmektedir. Bu çalışma ile bir MŞ yatırımı ekonomik açıdan ele alınarak proje kârlılığı ortaya konulmaya çalışılmıştır. Böylece devletlerin ve yatırımcıların MŞ'leri diğer projeler ile birlikte yatırım aracı olarak değerlendirebileceği düşünülmektedir.

6. KAYNAKLAR

- Akman T, Yılmaz C, Sönmez Y, 2018, Elektrik Yüğü Tahmin Yöntemlerinin Analizi, Gazi Mühendislik Bilimleri Dergisi, 4, 168-175.
- Almogrbı A N M, 2017, Modelling and Simulation of Microgrid Using Wind and Battery Based Power Generation, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 75, Karabük, Türkiye.
- Altın N, Eyimaya S E, 2021, A Review of Microgrid Control Strategies, 2021 10th International Conference on Renewable Energy Research and Application (ICRERA), 26-29 Eylül 2021, İstanbul, Türkiye, 412-417.
- Anonim, 2021, Levelized Cost of Energy, Levelized Cost of Storage, and Levelized Cost of Hydrogen 2021, Lazard, London, United Kingdom.
- Anonim, 2022, Electricity Market Report-January 2022, IEA, Paris, France.
- Anonim, 2022, Real-Time Electricity Tracker, IEA, Paris, France.
- Anonim, 2023, 2023 Yılı Aylık Elektrik Üretim-Tüketim Raporları, TEİAŞ, Ankara.
- Anonim, 2023, Real-Time Electricity Tracker, IEA, Paris, France.
- Aslan Y, Yaşar C, Nalbant A, 2006, Electrical Peak Load Forecasting in Kütahya With Artificial Neural Networks, Journal of Science and Technology of Dumlupınar University, 11, 63-74.
- Basak P, Chowdhury S, Dey S H, Chowdhury S P, 2012, A Literature Review on Integration of Distributed Energy Resources in The Perspective of Control, Protection and Stability of Microgrid, Renewable and Sustainable Energy Reviews, 16, 5545-5556.
- Başaran Filik Ü, Filik T, 2017, Kısa-Dönem Rüzgâr Hızının Tahmininde Otoresresif ve Yapay SinirAğları Tabanlı Yeni Bir Hibrit Yaklaşım, Karaelmas Fen ve Mühendislik Dergisi, 7, 419-427.
- Bataineh A A, Kaur D, 2018, A Comparative Study of Different Curve Fitting Algorithms in Artificial Neural Network Using Housing Dataset, NAECON 2018 - IEEE National Aerospace and Electronics Conference, 23-26 July 2018, Dayton, OH,

USA, 174-178.

Bejani M M, Ghatee M, 2021, A Systematic Review on Overfitting Control in Shallow and Deep Neural Networks, *Artificial Intelligence Review*, 54, 6391–6438.

Bircanoğlu C, Arıca N, 2018, A Comparison of Activation Functions in Artificial Neural Networks, 2018 26th Signal Processing and Communications Applications Conference (SIU), 02-05 Mayıs 2018, Izmir, Turkey, 1-4.

Breiman L, 1984, *Classification and Regression Trees* (1. Cilt), Routledge, 368, New York.

Cevik H H, Harmancı H, Çunkaş M, 2016, Short-term Load Forecasting based on ABC and ANN For Smart Grids, *International Journal of Intelligent Systems and Applications in Engineering*, 4, 38-43.

Demirel Ö, Kakilli A, Tektaş M, 2013, Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25, 601-610.

Demirel Ş, Yakut Z G, 2019, Karar Ağacı Algoritmaları ve Çocuk İşçiliği Üzerine Bir Uygulama, *Sosyal Bilimler Araştırma Dergisi*, 8, 52-65.

Demirtaş M, Akkoyun N, Akkoyun E, Çetinbaş İ, 2019, Akıllı Şebekelerde Güneş Enerjisi Üretiminin Zamana Bağlı Olasılıksal Tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7, 411-424.

Dhiman H S, Deb D, 2020, A Review of Wind Speed and Wind Power Forecasting Techniques, *arXiv preprint*, Article number 2009.02279.

Dupré A, Drobinski P, Alonzo B, Badosa J, Briard C, Plougonven R, 2020, Sub-hourly Forecasting of Wind Speed and Wind Energy, *Renewable Energy*, 145, 2373-2379.

Fahad M U, Arbab N, 2014, Factor Affecting Short Term Load Forecasting, *Journal of Clean Energy Technologies*, 2, 305-309.

Gardner M V, Dorling S R, 1998, Artificial neural networks (the multilayer perceptron)- a review of applications in the atmospheric sciences, *Atmospheric Environment*, 32, 2627-2636.

Gökgöz F, Filiz F, 2020, Electricity Load Forecasting via ANN Approach in Turkish

- Electricity Markets, Bilgi Yönetimi, 3, 170-184.
- GroB A, Lenders A, Schwenker F, Braun D A, Fischer D, 2021, Comparison Of Short-Term Electrical Load Forecasting Methods For Different Building Types, Energy Informatics, 4, Article Number 13.
- Haliloğlu E Y, Tutu B E, 2018, Forecasting Daily Electricity Demand For Turkey, Turkish Journal of Energy Policy, 3, 40-49.
- Hatziargyriou N D, Meliopoulos A P S, 2022, Distributed Energy Resources: Technical Challenges, 2022 IEEE Power Engineering Society Winter Meeting Conference Proceedings, 27-31 January 2022, New York, USA, 1017-1022.
- Hooshyar A, Iravani R, 2017, Microgrid Protection, Proceedings of the IEEE, 105, 1332-1353.
- Ibrahim B, Rabelo L, Gutierrez-Franco E, Clavijo-Buritica N, 2022, Machine Learning for Short-Term Load Forecasting in Smart Grids, Energies, 15, Article Number 8079.
- Juan D R O, Vargas I G, 2022, Observational Cosmology with Artificial Neural Networks, Universe, 8, Article number 120.
- Kamber E, Körpüz S, Can M, Yumurtacı Aydoğmuş H, Gümüş M, 2021, Yapay Sinir Ağlarına Dayalı Kısa Dönemli Elektrik Yüğü Tahmini, Endüstri Mühendisliği, 32, 364-379.
- Karlıtepe M, 2021, Dağıtık Üretim Kaynaklarına Sahip Bir Mikro Şebekeye Rüzgâr Enerji Kaynaklarının Optimum Yerleşimi ve Kararlılık Analizi, Nevşehir Bilim ve Teknoloji Dergisi, 10, 14-29.
- Kocaman B, 2013, Akıllı Şebekeler ve Mikro Şebekelerde Enerji Depolama Teknolojileri, Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 2, 119-127.
- Kocaman B, 2014, Mikro Şebekeler için Örnek Bir Enerji Yönetimi Uygulaması, Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 3, 35-52.
- Kotsiantis S B, 2013, Decision Trees: A Recent Overview, Artificial Intelligence Review, 39, 261–283.
- Kowsari K, Meimandi K J, Heidarfa M, Mendu S, Barnes L, Brown D E, 2019, Text

- Classification Algorithms: A Survey, Information, 10, Article Number 150.
- Krishnan N, Kumar K R, Inda C S, 2023, How Solar Radiation Forecasting Impacts the Utilization of Solar Energy: A Critical Review, Journal of Cleaner Production, 388, Article Number 135860.
- Kumar D S, Yagli G M, Kashyap M, Srinivasan D, 2020, Solar Irradiance Resource and Forecasting: A Comprehensive Review. IET Renewable Power Generation, 14, 1641-1656.
- Lasseeter R H, Paigi P, 2004, Microgrid: A Conceptual Solution, 2004 IEEE 35th Annual Power Electronics Specialists Conference, 20-25 June 2004, Aachen, Germany, 4285-4290.
- Liu J, Song D, Li Q, Yang J, Hu Y, Fang F, vd., 2023, Life Cycle Cost Modelling and Economic Analysis of Wind Power: A State of Art Review, Energy Conversion and Management, 277, Article Number 116628.
- Maham F E, Akarslan E, 2022, Güneş Işınım Tahmini için Farklı Güneşlenme Durumlarından Faydalanan Hibrit Bir Yöntem Tasarımı, Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 22, 588-596.
- McCulloch W S, Pitts W, 1943, A Logical Calculus of the Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, 5, 115–133.
- Melo J, 2022, Gaussian Processes For Regression: A Tutorial, Rapor No:4200-465, 7s.
- Montgomery D C, Peck E A, Vining G G, 2013, Introduction to Linear Regression Analysis, 5. Edition, Wiley, 872, Canada.
- Nalbant A, Aslan A, Yaşar C, 2005, Kütahya İli Elektrik Puant Yük Tahmini, Elektrik-Elektronik-Bilgisayar Mühendisliği 11. Ulusal Kongresi ve Fuar Bildirileri, 22-25 Eylül 2005, Kütahya, Türkiye.
- Oviroh P O, Jen T C, 2018, The Energy Cost Analysis of Hybrid Systems and Diesel Generators in Powering Selected Base Transceiver Station Locations in Nigeria, Energies, 11 Article Number 687.
- Özkan K, 2012, Sınıflandırma ve Regresyon Ağacı Tekniği (srat) ile Ekolojik Verinin Modellenmesi, Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi Seri: A,

13, 1- 4.

Qiuyu L, Qiuna C, Sijie L, Yun. Y, Binjie Y, Yang W, vd., 2017, Short-term Load Forecasting Based on Load Decomposition and Numerical Weather Forecast, 2017 IEEE Conference on Energy Internet and Energy System Integration (EI2), 20-28 November 2017, Beijing, China, 1-5.

Querini L, P, Ulises M, Erica F, Omar C, 2021, Sustainable Energy, Grids and Networks, 26, Article Number 100459

Rasmussen C.E., Williams C.K.I., 2006, Gaussian Processes for Machine Learning, The MIT Press, 272p, Tübingen, Germany.

Reka S S, Ramesh V, 2016, Demand Response Scheme With Electricity Market Prices For Residential Sector Using Stochastic Dynamic Optimization, 2016 Biennial International Conference on Power and Energy Systems: Towards Sustainable Energy (PESTSE), January 21-23, Bengaluru, India, 1-6.

Ren G, Wang Y, Ning J, Zhang Z, 2020, Using Near-infrared Hyperspectral Imaging With Multiple Decision Tree Methods to Delineate Black Tea Quality, Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 237, Article Number 118407.

Ren Y, Hu F, Miao H, 2016, The Optimization of Kernel Function and its Parameters for SVM in Well-logging, 2016 13th International Conference on Service Systems and Service Management (ICSSSM), June 24-26 2016, Kunming, China, 1-5.

Rodríguez F, Fleetwood A, Galarza A, Fontán L, 2018, Predicting Solar Energy Generation Through Artificial Neural Networks Using Weather Forecasts for Microgrid Control, Renewable Energy, 126, 855-864.

Rumelhart D, Hinton G, Williams R, 1986, Learning Representations by Back-propagating Errors, Nature, 323, 533–536.

Sarı A, Aktaş M, Yönetken A, Doğan R, 2021, Güneş Işınım Tahmininde NARX Modelinin Uygulanması, Afyon Kocatepe Üniversitesi Uluslararası Mühendislik Teknolojileri ve Uygulamalı Bilimler Dergisi, 4, 1-6.

Sarraf Shirazi A, Frigaar I, 2021, Slurry Net: Predicting Critical Velocities and Frictional

- Pressure Drops in Oilfield Suspension Flows, *Energies*, 14, Article Number 1263.
- Shuai Z, Sun Y, Shen Z J, Tian W, Tu C, Li Y, vd., 2016, Microgrid Stability: Classification and a Review, *Renewable and Sustainable Energy Reviews*, 58, 167-179.
- Singh G, Chauhan D S, Chandel A, Parashar D, Sharma G, 2014, Factor Affecting Elements and Short Term Load Forecasting Based on Multiple Linear Regression Method, *International Journal of Engineering Research & Technology (IJERT)*, 3, 736-740.
- Smestad G P, 2008, The Basic Economics Of Photovoltaics, *Solar Energy Materials and Solar Cells*.
- Smola A J, Schölkopf B, 2004, A Tutorial on Support Vector Regression, *Statistics and Computing*, 14, 199–222.
- Tarmanini C, Sarma N, Gezegin C, Ozgonenel O, 2023, Short-term Load Forecasting Based on ARIMA and ANN Approaches, *Energy Reports*, 9, 550-557.
- Umar M, Riaz Y, Yousaf I, 2022, Impact of Russian-Ukraine War on Clean Energy, Conventional Energy, and Metal Markets: Evidence From Event Study Approach, *Resources Policy*, 79, Article Number102966.
- Unes F, Kasal D, Taşar B, 2019, Meteorolojik Ölçüm Verilerini Kullanarak Mamdani-Bulanık Mantık Yöntemi ile Rüzgar Hızının Tahmini, *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2, 97-104.
- Var H, Türkay B E, 2014, Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yüğü Tahmini, *Eleco 2014 Elektrik–Elektronik–Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 27–29 Kasım 2014, Bursa.
- Wan Z Y, Sapsis T P, 2017, Reduced-space Gaussian Process Regression for Data-Driven Probabilistic Forecast of Chaotic Dynamical Systems, *Physica D: Nonlinear Phenomena*, 345, 40-55.
- Wu T, Bao G, Chen Y, Shang J, 2018, A Review for Control Strategies in Microgrid, 2018 37th Chinese Control Conference (CCC), July 5-27, Wuhan, China, 30-35.
- Yılmaz, F, Kasapbaşı, M C, 2021, EEG Sinyalleri ile Epilepsi Krizinin

Tahminlenmesinde Rassal Orman Algoritması ile Hiper Parametre Optimizasyonun Uygulanması, İstanbul Ticaret Üniversitesi Teknoloji ve Uygulamalı Bilimler Dergisi, 3, 189-203.

Zhang N, Xiong J, Zhong J, Leatham K, 2018, Gaussian Process Regression Method for Classification for High-Dimensional Data with Limited Samples, 2018 Eighth International Conference on Information Science and Technology (ICIST), June 30-July 6, Cordoba, Spain, 358-363.

Zhang P, Wu X, Wang X, Bi S, 2015, Short-term Load Forecasting Based on Big Data Technologies, CSEE Journal of Power and Energy Systems, 1, 59-67.

İnternet Kaynakları

- 1- <https://yearbook.enerdata.net/co2/emissions-co2-data-from-fuel-combustion.html>, 07.05.2023
- 2- <https://www.nationalgrid.com/stories/grid-at-work/christmas-energy-effect-revealed>, 07.05.2023
- 3- <https://ourworldindata.org/energy>, 07.05.2023
- 4- <https://ourworldindata.org/energy-key-charts>, 07.05.2023
- 5- https://en.wikipedia.org/wiki/Levelized_cost_of_electricity, 07.05.2023
- 6- https://en.wikipedia.org/wiki/Duquesne,_Pennsylvania, 07.05.2023
- 7- <https://medium.datadriveninvestor.com/how-do-regression-trees-work-94999c5105d>, 07.05.2023
- 8- https://www.eia.gov/electricity/monthly/epm_table_grapher.php?t=epmt_5_6_a, 07.05.2023

EKLER

EK 1. Tahmin için kullanılan veri seti

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	datetime_beginning_utc	load_area	load	temp	humidity	mouth	day	year	hour	dst_index	temp_ind	hour_ind	weekend_ind	dayofweek	day_name	hour_ind2
2	1/1/2015 0:00	DUQ	1915	-4.43	37	1	1	2015	0	0	0	0	0	4	Thursday	0
3	1/1/2015 1:00	DUQ	1847	-4.62	41	1	1	2015	1	0	0	0	0	4	Thursday	0
4	1/1/2015 2:00	DUQ	1825	-5	42	1	1	2015	2	0	0	0	0	4	Thursday	0
5	1/1/2015 3:00	DUQ	1709	-5.16	39	1	1	2015	3	0	0	0	0	4	Thursday	0
6	1/1/2015 4:00	DUQ	1656	-5.27	37	1	1	2015	4	0	0	0	0	4	Thursday	0
7	1/1/2015 5:00	DUQ	1560	-5.46	38	1	1	2015	5	0	0	0	0	4	Thursday	0
8	1/1/2015 6:00	DUQ	1543	-5.71	38	1	1	2015	6	0	0	0	0	4	Thursday	1
9	1/1/2015 7:00	DUQ	1494	-5.91	38	1	1	2015	7	0	0	1	0	4	Thursday	1
10	1/1/2015 8:00	DUQ	1482	-5.93	38	1	1	2015	8	0	0	1	0	4	Thursday	1
11	1/1/2015 9:00	DUQ	1498	-6.14	38	1	1	2015	9	0	0	1	0	4	Thursday	1
12	1/1/2015 10:00	DUQ	1517	-6.1	40	1	1	2015	10	0	0	1	0	4	Thursday	2
13	1/1/2015 11:00	DUQ	1550	-6.3	42	1	1	2015	11	0	0	1	0	4	Thursday	2
14	1/1/2015 12:00	DUQ	1563	-6.31	44	1	1	2015	12	0	0	1	0	4	Thursday	2
15	1/1/2015 13:00	DUQ	1557	-6.28	44	1	1	2015	13	0	0	1	0	4	Thursday	2
16	1/1/2015 14:00	DUQ	1551	-5.14	42	1	1	2015	14	0	0	1	0	4	Thursday	2
17	1/1/2015 15:00	DUQ	1609	-2.69	39	1	1	2015	15	0	0	1	0	4	Thursday	3
18	1/1/2015 16:00	DUQ	1632	-1.49	39	1	1	2015	16	0	0	1	0	4	Thursday	3
19	1/1/2015 17:00	DUQ	1619	0.17	37	1	1	2015	17	0	0	1	0	4	Thursday	3
20	1/1/2015 18:00	DUQ	1607	1.08	37	1	1	2015	18	0	0	1	0	4	Thursday	3
21	1/1/2015 19:00	DUQ	1587	1.85	37	1	1	2015	19	0	0	1	0	4	Thursday	3
22	1/1/2015 20:00	DUQ	1591	2.31	39	1	1	2015	20	0	0	1	0	4	Thursday	4
23	1/1/2015 21:00	DUQ	1631	2.68	39	1	1	2015	21	0	0	1	0	4	Thursday	4
24	1/1/2015 22:00	DUQ	1736	1.74	41	1	1	2015	22	0	0	1	0	4	Thursday	4
25	1/1/2015 23:00	DUQ	1732	1.45	40	1	1	2015	23	0	0	0	0	4	Thursday	4
26	1/2/2015 0:00	DUQ	1735	1.22	42	1	2	2015	0	0	0	0	0	5	Friday	0
27	1/2/2015 1:00	DUQ	1733	1.1	40	1	2	2015	1	0	0	0	0	5	Friday	0
28	1/2/2015 2:00	DUQ	1672	1.12	40	1	2	2015	2	0	0	0	0	5	Friday	0
29	1/2/2015 3:00	DUQ	1599	0.98	40	1	2	2015	3	0	0	0	0	5	Friday	0
30	1/2/2015 4:00	DUQ	1528	0.62	42	1	2	2015	4	0	0	0	0	5	Friday	0
31	1/2/2015 5:00	DUQ	1486	0.47	44	1	2	2015	5	0	0	0	0	5	Friday	0
32	1/2/2015 6:00	DUQ	1447	-0.02	46	1	2	2015	6	0	0	0	0	5	Friday	1
33	1/2/2015 7:00	DUQ	1426	-0.1	50	1	2	2015	7	0	0	1	0	5	Friday	1
34	1/2/2015 8:00	DUQ	1438	-0.33	53	1	2	2015	8	0	0	1	0	5	Friday	1
35	1/2/2015 9:00	DUQ	1472	-0.81	55	1	2	2015	9	0	0	1	0	5	Friday	1
36	1/2/2015 10:00	DUQ	1532	-0.89	57	1	2	2015	10	0	0	1	0	5	Friday	2

EK 2. YSA MATLAB tahmin kodu

```
1 - trainx = readmatrix('train_x');
2 - trainy = readmatrix('train_y');
3 - predictx = readmatrix('predict_x');
4 - observedy = readmatrix('observed_y');
5
6 - x = trainx';
7 - t = trainy';
8
9 - trainFcn = 'trainbr'; % Bayesian Regularization backpropagation.
10
11 - hiddenLayerSize = 22;
12 - net = fitnet(hiddenLayerSize,trainFcn);
13
14 - net.input.processFcns = {'removeconstantrows','mapminmax'};
15 - net.output.processFcns = {'removeconstantrows','mapminmax'};
16
17 - net.divideFcn = 'dividerand'; % Divide data randomly
18 - net.divideMode = 'sample'; % Divide up every sample
19 - net.divideParam.trainRatio = 70/100;
20 - net.divideParam.valRatio = 15/100;
21 - net.divideParam.testRatio = 15/100;
22
23 - net.performFcn = 'mse'; % Mean Squared Error
24
25 - net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
26                 'plotregression','plotfit'};
27
28 - [net,tr] = train(net,x,t);
29
30 - y = net(x);
31 - e = gsubtract(t,y);
32 - performance = perform(net,t,y)
33
34
35 - trainTargets = t .* tr.trainMask{1};
36 - valTargets = t .* tr.valMask{1};
37 - testTargets = t .* tr.testMask{1};
38 - trainPerformance = perform(net,trainTargets,y)
39 - valPerformance = perform(net,valTargets,y)
40 - testPerformance = perform(net,testTargets,y)
41
```

EK 2. (Devam) YSA MATLAB tahmin kodu

```
42 - view(net)
43 -
44 - figure, plotregression(t,y)
45 -
46 - if (false)
47 -
48 -     genFunction(net,'myNeuralNetworkFunction');
49 -     y = myNeuralNetworkFunction(x);
50 - end
51 - if (true)
52 -
53 -     genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
54 -     y1 = myNeuralNetworkFunction(predictx');
55 -     y1 = y1';
56 -
57 -     MSE = mean((observedy - y1).^2)
58 -     RMSE = sqrt(mean((observedy - y1).^2))
59 -     MAE = mean(abs(observedy - y1))
60 -     MAPE = mean(abs((observedy - y1) ./ observedy)) * 100
61 -     r2 = 1 - (sum((observedy - y1).^2) / sum((observedy - mean(observedy)).^2)
62 - end
63 - if (false)
64 -
65 -     gensim(net);
66 - end
```

EK 3. YSA, GSR, DVR, RA ve LR algoritmaları ile oluşturulan tahmin değerlerinin bir kısmı

Ölçüm	YSA	üsteIGPR	FG DVR	KA	interLR
1513	1540.461	1527.703	1492.405	1549.5	1445.412
1461	1503.934	1485.418	1481.317	1549.5	1403.95
1418	1452.001	1441.592	1464.7	1469.667	1370.473
1354	1381.561	1390.08	1448.672	1333	1326.372
1284	1308.897	1337.317	1437.877	1279.25	1280.504
1232	1246.659	1285.673	1437.907	1227.571	1229.606
1197	1209.275	1239.772	1402.943	1200.286	1374.235
1199	1197.487	1224.201	1403.106	1200.286	1131.106
1202	1198.982	1239.013	1401.309	1200.286	1141.879
1206	1224.442	1255.175	1397.002	1200.286	1149.5
1273	1275.987	1341.966	1428.157	1254.6	1174.59
1368	1340.995	1377.504	1450.128	1350.571	1179.261
1443	1395.701	1404.524	1467.75	1461.125	1176.03
1468	1435.524	1434.237	1482.576	1461.125	1191.363
1480	1445.844	1398.931	1497.125	1500	1111.359
1472	1472.765	1447.492	1495.67	1500	1181.791
1450	1460.286	1456.772	1493.337	1500	1248.07
1453	1450.918	1460.078	1490.052	1500	1332.29
1442	1450.261	1459.088	1486.363	1466.375	1389.253
1434	1462.297	1456.727	1483.442	1365.9	1454.065
1416	1456.467	1458.305	1484.94	1365.9	1462.976
1426	1462.917	1465.65	1487.859	1410.5	1500.67
1428	1459.974	1473.444	1488.528	1500	1515.979
1467	1501.069	1482.99	1496.567	1500	1379.588
1452	1479.103	1416.462	1446.112	1460.375	1456.825
1405	1463.747	1377.206	1431.412	1460.375	1400.049
1351	1431.698	1324.563	1433.821	1345	1238.204
1289	1361.896	1374.635	1437.3	1287.571	1240.256
1219	1293.143	1320.9	1408.257	1279.25	1203.825
1173	1235.934	1264.937	1364.961	1227.571	1181.853
1152	1198.554	1221.699	1313.05	1200.286	1358.458
1138	1196.118	1218.733	1290.52	1200.286	1151.862
1140	1205.404	1239.838	1281.354	1200.286	1187.27
1154	1242.254	1264.197	1292.302	1200.286	1222.774
1228	1299.522	1344.763	1354.56	1254.6	1264.161
1333	1381.142	1412.234	1417.151	1381.125	1302.238
1422	1445.675	1473.184	1476.01	1459.5	1322.624
1456	1490.42	1525.106	1529.345	1524.444	1344.163
1503	1504.066	1556.667	1562.131	1524.444	1349.268
1527	1513.772	1560.67	1577.817	1562	1367.078
1519	1508.984	1570.493	1585.067	1562	1386.853
1485	1510.110	1566.576	1573.038	1562	1431.077

EK 4. YSA, GSR, DVR, RA ve LR algoritmaları ile oluşturulan tahmin değerlerinin grafik haline getirilmiş hali

