İZMİR BAKIRÇAY ÜNİVERSİTESİ'NİN YENİLENEBİLİR ENERJİ ÜRETİMİNİN VE ENERJİ TÜKETİMİNİN TAHMİN EDİLMESİ

Ertuğrul ORMAN

YÜKSEK LİSANS TEZİ

Akıllı Sistemler Mühendisliği
Danışman: Dr. Öğr. Üyesi
Bayram KÖSE

İzmir
İzmir Bakırçay Üniversitesi
Lisansüstü Eğitim Enstitüsü
Temmuz 2022

JÜRİ VE ENSTİTÜ ONAYI

İzmir Bakırçay Üniversitesi Lisansüstü Eğitim Enstitüsü Akıllı Sistemler Mühendisliği Anabilim dalında öğrenim görmekte olan Ertuğrul Orman'ın " İzmir Bakırçay Üniversitesi'nin Yenilenebilir Enerji Üretiminin ve Enerji Tüketiminin Tahmin Edilmesi" başlıklı tezi .06/07/22 tarihinde aşağıdaki jüri tarafından değerlendirilerek "İzmir Bakırçay Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Akıllı Sistemler Mühendisliği Anabilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri	**Unvanı Adı Soyadı**	**İmza**
Üye (Tez Danışmanı)		
Üye		
Üye		
Üye		
Üye		

.....

(Unvanı, Adı ve SOYADI)

Lisansüstü Eğitim Enstitüsü Müdürü

ÖZET

İZMİR BAKIRÇAY ÜNİVERSİTESİ'NİN YENİLENEBİLİR ENERJİ ÜRETİMİNİN VE ENERJİ TÜKETİMİNİN TAHMİN EDİLMESİ

Ertuğrul ORMAN

Akıllı Sistemler Anabilirim Dalı Anabilim Dalı

İzmir Bakırçay Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2022

Danışman: Dr. Öğr. Üyesi Bayram KÖSE

İzmir Bakırçay Üniversitesi'nin ekolojik ve ekonomik olarak kendi kendine yetebilen bir üniversite olma hedefinin gerçekleşebilmesi için elektrik üretiminin ve tüketiminin doğru öngörülüp doğru tahmin edilmesi son derece önemlidir. İzmir Bakırçay Üniversitesi enerji ihtiyacını yenilenebilir enerji kaynakları ile karşılamayı hedeflemektedir. Yenilenebilir enerji kaynakları, fosil yakıt santrallerinin aksine üretimi kontrol edilebilen enerji kaynakları değildir. Bu durumdan dolayı üretimin tahmin edilmesi gerekir. Elektrik üretiminin ve tüketiminin doğru tahmin edilmesi yalnızca üniversite için değil ulusal çapta da büyük önem arz etmektedir. Üretimin ve tüketimin doğru tahmin edilebilmesi, şebekede bulunacak elektrik miktarının doğru şekilde ayarlanabilmesi ve kaybın azaltılabilmesine katkı sağlar. Bu tahminlemenin saatlik olarak yapılması şebekede bulunacak elektrik miktarının daha hassas ayarlanabilmesini sağlamanın yanı sıra akıllı bina, akıllı kampüs, akıllı şebeke gibi uygulamalar için büyük önem arz etmektedir. Halihazırda kurulu bulunan güneş enerji santraline ait 1 Temmuz 2019 tarihi ile 31 Ekim 2021 tarihleri arasındaki elektrik üretimi ve aynı tarihler arasındaki elektrik tüketimi farklı tahmin yöntemleri ile tahmin edilmiştir. Elektrik üretiminin tahmini için sıcaklık, küresel güneş radyasyonu, bulutluluk, yağış miktarı gibi meteorolojik parametreler kullanılmıştır. YSA'lar ile yapılan tahminleme için doğrusal olmayan otoregresif ağ ve dış girdili doğrusal olmayan otoregresif ağ modelleri kullanılmıştır. Kullanılan bu modellerde eğitim algoritması olarak bayes optimizasyon algoritması ve Levenberg-Marquardt algoritması kullanılmıştır. Yapılan denemelerin sonucunda dış girdili doğrusal olmayan ağ hem bayes optimizasyon algoritması ile hem Levenberg-Marquardt algoritması ile doğrusal olmayan ağa kıyasla daha başarılı tahminlerde bulunmuştur. Eğitim algoritması olarak kullanılan Bayes optimizasyon algoritması da hem dış girdili doğrusal olmayan ağ modelinde da hem de doğrusal olmayan ağ modelinde yapılan tüm tahminlerde Levenberg-Marquardt algoritmasından daha başarılı tahminlerde bulunmuştur. Güneş enerji santralinin üretimi 214,75 ortalama kare hatası değeri ile 10 nöronlu ağ ile tahmin edilmiştir. Üniversitenin elektrik tüketimi ise 435,82 ortalama kare hatası değeri ile 5 nöronlu ağ ile tahmin edilmiştir. Ayrıca elektrik üretimi ve tüketimi regresyon analizi ile de tahmin edilmeye çalışılmıştır. Regresyon analizi ile tahmin edilen elektrik üretiminin ortalama kare hatası değeri 831,3238 olarak bulunmuştur.

Anahtar Sözcükler: Enerji tahminleme; Yapay sinir ağı; Çoklu regresyon; NARX; Akıllı enerji yönetimi.

ABSTRACT

TITLE O ESTIMATE OF RENEWABLE ENERGY GENERATION AND ENERGY CONSUMPTION OF IZMIR BAKIRÇAY UNIVERSITY

Ertugrul ORMAN

Department of Smart Systems Engineering

İzmir Bakırçay University, Graduate Education Institute, July 2022

Supervisor: Dr. Bayram KOSE

For İzmir Bakırçay University to achieve its goal of being an ecologically and economically self-sufficient university, it is crucial that electricity production and consumption be accurately predicted and estimated. İzmir Bakırçay University aims to meet its energy needs with renewable energy sources. Unlike fossil fuel power plants, renewable energy sources are not energy sources whose production can be controlled. Because of this situation, the production must be estimated. Accurate estimation of electricity production and consumption is of great importance not only for the university but also at the national level. Predicting the production and consumption correctly contributes to correctly adjusting the amount of electricity to be found in the grid and reducing the loss. Making this estimation hourly is of great importance for applications such as smart buildings, smart campuses and smart grids, as well as enabling more precise adjustment of the amount of electricity to be found in the grid. The electricity generation of the currently installed solar power plant between July 1, 2019, and October 31, 2021, and the electricity consumption between the same dates were estimated using different estimation methods. Meteorological parameters such as temperature, global solar radiation, cloudiness, and precipitation were used to estimate electricity production. For the prediction made with artificial neural networks, nonlinear autoregressive network and nonlinear autoregressive network models with external input are used. These models used the Bayes optimization algorithm and Levenberg-Marquardt algorithm as training algorithms. As a result of the experiments, the nonlinear network with external inputs made more successful predictions with both the Bayes optimization algorithm and the Levenberg-Marquardt algorithm compared to the nonlinear network. The Bayes optimization algorithm, which is used as a training algorithm, also made better predictions than the Levenberg-Marquardt algorithm in all predictions made both in the nonlinear network model with external input and in the nonlinear network model. The generation of the solar power plant was estimated with a 10-neuron network with a mean square error value of 214.75. The university's electricity consumption was estimated with a 5-neuron network with a mean square error value of 435.82. In addition, electricity production and consumption were tried to be estimated by regression analysis. The mean square error value of the electricity production estimated by the regression analysis was found to be 831,3238

Keywords: Energy estimation; Artificial neural networks; Multiple regression; NARX; Intelligent energy management.

TEŞEKKÜR

Tez çalışması sürecinde yol gösterici olan, hiçbir konuda desteğini esirgemeyen, zorlandığım noktalarda bana verdiği motivasyon ile tekrar çalışmaya odaklanmamı sağlayan danışman hocam sayın Bayram Köse'ye teşekkürlerimi sunarım.

Eğitim hayatım boyunca desteğini esirgemeyen, ilkokul yıllarımdan itibaren daha iyi eğitim alabilmem için her türlü fırsatı sunan annem ve babama, hayatımın her alanında elinden geldiğince yanımda olmak için çaba sarf eden biricik kardeşime teşekkürlerimi sunarım.

.../.../20...

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın İzmir Bakırçay Üniversitesi tarafından kullanılan Turnitin bilimsel intihal tespit programıyla tarandığını ve hiçbir şekilde "intihal içermediğini" beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Ertuğrul ORMAN

.

.../.../20...

STATEMENT OF COMPLIANCE WITH ETHICAL PRINCIPLES AND RULES

I hereby truthfully declare that this thesis is an original work prepared by me; that I have behaved in accordance with the scientific ethical principles and rules throughout the stages of preparation, data collection, analysis and presentation of my work; that I have cited the sources of all the data and information that could be obtained within the scope of this study, and included these sources in the references section; and that this study has been scanned for plagiarism with Turnitin scientific plagiarism detection program used by İzmir Bakırçay University, and that "it does not have any plagiarism" whatsoever. I also declare that, if a case contrary to my declaration is detected in my work at any time, I hereby express my consent to all the ethical and legal consequences that are involved.

Ertugrul ORMAN

.

İÇİNDEKİLER

Başlık ..... *i*

JÜRİ VE ENSTİTÜ ONAYI ..... *ii*

ÖZET ..... *iii*

ABSTRACT ..... *iv*

TEŞEKKÜR ..... *v*

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ ..... *vi*

STATEMENT OF COMPLIANCE WITH ETHICAL PRINCIPLES AND RULES ... *vii*

TABLOLAR DİZİNİ ..... *x*

ŞEKİLLER DİZİNİ ..... *xii*

SİMGELER VE KISALTMALAR DİZİNİ ..... *xiv*

1.GİRİŞ *1*

1.1.Enerji Kullanımı 3

1.1.1.Türkiye'nin güneş enerjisi görünümü 7

1.1.2.Sürdürülebilirlik 9

1.1.3.Yeşil mutabakat 10

2.MATERYAL *12*

2.1.Bakırçay Üniversitesi Güneş Enerji Santrali 12

2.2.Girdiler 13

2.2.1.Saatlik küresel güneş radyasyonu 15

2.2.2.Saatlik bulutluluk verisi 16

2.2.3.Saatlik ortalama sıcaklık 17

2.2.4.Saatlik ortalama rüzgar hızı 17

2.2.5.Günlük toplam yağış miktarı 18

2.3.Çıktılar 19

2.4.Saat Aralığının Belirlenmesi 20

2.5.Eksik Girdilerin Tespiti 20

3.METOD *22*

3.1.YSA'larnın Tarihi 22

3.2.YSA'larnın Yapısı 24

3.3.YSA'larnın Elemanları 24

3.3.1.Girdi 25

3.3.2.Ağırlık 25

3.3.3.Toplama Fonksiyonu: 25

3.3.4.Aktivasyon Fonksiyonu 25

3.3.5.Çıktılar **27**
3.4.YSA'larnın Sınıflandırılması **27**
3.4.1.Besleme türüne göre YSA'lar **28**
3.4.2.Katman sayısına göre YSA'lar **29**
3.4.3.Öğrenme yöntemine göre YSA'lar **29**
3.4.4.Yapısına göre YSA'lar **30**
3.5.Zaman Serileri **30**
3.6.Kullanılacak Modelin Seçimi **33**
3.6.1.NAR **33**
3.6.2.NARX **34**
3.6.3.Bayes optimizasyon algoritması **35**
3.6.4.Regresyon analizi **37**
4.UYGULAMA VE BULGULAR ***38***
4.1.Kullanılan Programlar **38**
4.2.Elektrik Üretiminin Tahmini **38**
4.3.Elektrik Tüketiminin Tahmini **48**
5.SONUÇ ve ÖNERİLER ***56***

TABLOLAR DİZİNİ

Sayfa

Tablo 2.1.Güneş panellerinin teknik özellikleri 12

Tablo 2.2.Elektrik üretimi verisinin incelenmesi 20

Tablo 3.1.Biyolojik sinir sistemi ve YSA'ların benzer elemanları 24

Tablo 4.1. 1 saat önceki girdiler ile üretimin korelasyon analizi 38

Tablo 4.2. 2 saat önceki girdiler ile üretimin korelasyon analizi 39

Tablo 4.3.Elektrik üretiminin tahmini için regresyon analizi kullanılarak yapılan tahminlerin MSE değerleri.....40

Tablo 4.4.Elektrik üretiminin tahmini için NARX modeli ile bayes optimizasyon ve Levenberg-Marquardt algoritmalarının yılın 4 çeyreği için MSE ve R değerleri..40

Tablo 4.5. Elektrik üretiminin tahmini için NARX modeli ile bayes optimizasyonu kullanılarak yapılan tahminlerin MSE ve R değerleri.....41

Tablo 4.6. Elektrik üretiminin tahmini için NARX modeli ile Levenberg-Marquardt optimizasyonu kullanılarak yapılan tahminlerin MSE ve R değerleri 42

Tablo 4.7. Elektrik üretiminin tahmini için NARX modeli kullanılarak oluşturulmuş Bayes optimizasyon algoritması ile yapılan 5 deneme ve Levenberg-Marquardt algoritması ile yapılmış denemenin MSE değerleri 43

Tablo 4.8. Elektrik üretiminin tahmini için NARX modeli ve bayes optimizasyon kullanılarak yapılan tahminlerin MSE değerleri 44

Tablo 4.9. Elektrik üretiminin tahmini için NAR modeli ile bayes optimizasyon eğitim algoritması kullanarak farklı nöron sayıları ile yapılmış tahminlerin MSE değerleri.....46

Tablo 4.10. Denemelerin MSE değerleri 47

Tablo 4.11. Elektrik üretiminin tahmini için NAR modeli ve Levenberg- Marquardt algoritması ile yapılan tahminlerin MSE değerleri 47

Tablo 4.12. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak yapılan denemelere ait MSE ve R değerleri.....48

Tablo 4.13. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak yapılan tahminlere ait aylık MSE değerleri.....49

Tablo 4.14. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt algoritması kullanılarak yapılan denemelere ait MSE ve R değerleri.....50

Tablo 4.15. Elektrik tüketiminin tahmini için NAR modeli ve Bayes optimizasyon algoritması kullanılarak yapılan tahminlere ait aylık MSE değerleri.....51

Tablo 4.16. Elektrik tüketiminin tahmini için NARX modeli ve bayes optimizasyon kullanılarak yapılan tahminlerin MSE değerleri 52

Tablo 4.17. Elektrik tüketiminin tahmini için NARX modeli ve Levenberg-Marquardt algoritması kullanılarak yapılan tahminlerin MSE değerleri 53

ŞEKİLLER DİZİNİ

Şekil 1.1. En çok enerji ithal eden ülkeler 4

Şekil 1.2.Türkiye'nin Enerji İthalatı 5

Şekil 1.3.Türkiye'nin yerli üretim enerji kaynakları ve enerji ithalatı 5

Şekil 1.4.Türkiye'nin yenilenebilir enerji kaynaklarından elektrik üretimi 6

Şekil 1.5. Hidroelektrik santrallerinin elektrik üretimi 7

Şekil 1.6.Güneş enerjisi potansiyeli atlası 8

Şekil 1.7.Güneş enerjisi potansiyeli atlasında İzmir ili 8

Şekil 1.8. Türkiye'nin güneş enerjisiyle elektrik üretimi.....9

Şekil 2.1.Güneş panellerinin yerleşimi ve okula göre konumu.....13

Şekil 2.2. Menemen istasyonu ve İzmir Bakırçay Üniversitesi'nin konumu.....14

Şekil 2.3.Çiğli havalimanı istasyonu ve İzmir Bakırçay Üniversitesi'nin konumu.....14

Şekil 2.4. Güneş radyasyonu 15

Şekil 2.5.Güneş radyasyonu verisi ile elektrik üretim verisi arasındaki ilişki.....16

Şekil 2.6. Bulutluluk dağılımı.....16

Şekil 2.7.Sıcaklık.....17

Şekil 2.8.Rüzgar hızı.....18

Şekil 2.9.Günlük yağış miktarı.....19

Şekil 2.10.İzmir Bakırçay Üniversitesi güneş enerji santralinin elektrik üretimi.....19

Şekil 3.1.YSA elemanlarının ağ içerisindeki yerleşimi.....25

Şekil 3.2. Hiperbolik tanjant fonksiyonunun grafiği 26

Şekil 3.3. Sigmoid fonksiyonunun grafiği 27

Şekil 3.4. Basamak fonksiyonunun grafiği.....27

Şekil 3.5.İleri beslemeli YSA'nın yapısı 28

Şekil 3.6. Tek katmanlı algılayıcı modeli.....29

Şekil 3.7.Günlük maksimum nispi nem.....31

Şekil 3.8. Bir otobüs firmasının yolcu sayısı 31

Şekil 3.9. Trendlerin türleri 32

Şekil 3.10.NARX Ağının Mimarisi 35

Şekil 4.1. Elektrik üretim ile tahmin arasındaki farkın yüzdelik dağılımı.....54

Şekil 4.2. Elektrik tüketiminin tahmini ile gerçekleşen tüketim arasındaki farkın yüzdesel dağılımı 55

SİMGELER VE KISALTMALAR DİZİNİ

AB	: Avrupa Birliği
u(t)	: Çıktının Önceki Değerleri
UTC	: Eşgüdümlü Evrensel Zaman
ϕ	: Eşik Değeri
x_i	: Girdiler
CO_2	: Karbondioksit
kW	: Kilowatt
kWp	: Kilowatt Peak
kWh	: Kilowatt Saat
MW	: Megawatt
M	: Metre
m^2	: Metrekare
Mtoe	: Milyon Ton Eşdeğer Petrol
MSE	: Ortalama Kare Hatası
OAPEC	: Petrol İhraç Eden Arap Ülkeleri
Sn	: Saniye
C^o	: Santigrat Derece
SKDM	: Sınırda Karbon Düzenleme Mekanizması
twh	: Terawatt Saat
g(.)	: Toplama Fonksiyonu
f(.)	: Transfer Fonksiyonu
YSA	: Yapay Sinir Ağı
W_i	: YSA'nın Ağırlıkları

1. GİRİŞ

Dünyanın enerji ihtiyacı günden güne hızla artmaktadır. Dünya 2011 yılında 520,90 exajoule enerji tüketirken 2021 yılına gelindiğinde bu tüketim 595,15 exajoule seviyelerine kadar çıkmıştır(BP, 2022) . 2019 yılında yaşanan covid 19 pandemisinin etkisiyle 2020 yılında elektrik tüketiminin azalmasına rağmen 2021 yılına gelindiğinde 2011'e kıyasla 10 yıllık süreçte %14,25'lik bir artış yaşanmıştır. Yapılan tahminlerde bu artışın süreceği öngörülmektedir. 2030 yılına gelindiğinde enerji tüketiminin 671 exajoule 2040 yılında 714,8 exajoule ve 2050 yılında 743,9 exajoule olması öngörülmektedir(World Energy Outlook 2021, 2021).

Günümüzdeki hayat standartlarımızdan vazgeçmeden ve konfor alanlarımızdan ayrılmadan enerji tüketimimizi azaltmamız mümkün değildir. Diğer yandan enerji elde etmek için kullandığımız birincil kaynaklardan olan fosil yakıtların bir gün tükeneceği aşikardır. Enerji kaynaklarının tükenecek olması ile ilgili endişeler bir yana, dünyanın geleceği ile ilgili endişeler de günümüzde sıkça dillendirilmektedir. Sera gazı emisyonu bugün dünya düzenini tehdit etmektedir(Pata, 2019). Sera gazlarının %58,8'ini oluşturan CO_2 gazı birincil sera gazı olarak da adlandırılmaktadır. Özellikle kömür santralleri ve petrol santralleri ciddi karbon emisyonuna neden olmaktadır(Güllü, 2015).

Fosil yakıtların tükenecek olması, fosil yakıtların neden olduğu çevre kirliliği ve karbon emisyonu düşünüldüğünde sürdürülebilirlik hedeflerine ulaşabilmek, çevreye geri dönüşü olmayan zararlar verilmesinin önüne geçmek için yenilenebilir enerji kaynaklarına yapılan yatırımları arttırmalı ve enerji ihtiyacımızı daha temiz kaynaklardan karşılamalıyız. Daha temiz ve yenilenebilir enerji kaynakları denildiğinde öncelikle akla 3 kaynak gelmektedir. Bu kaynaklar güneş enerjisi, rüzgar enerjisi ve hidroelektrik enerjisidir.

İnsanlar, uzun yıllardır Güneş'i çeşitli amaçlar için kullanmışlardır. Isınma ve aydınlanmadan tutun gıdaların uzun süre dayanabilmesi için kurutulması da Güneş sayesinde yapılmaktadır. Yaşanan teknolojik gelişmeler ile 1970'lerde yaşanan petrol krizinin de etkisiyle alternatif enerji arayışları hızlanmış ve güneş enerjisine olan ilgi artmıştır. Günümüzde maliyetlerin de düşmesiyle birlikte güneş enerjisinin kullanımı artmış ve kullanım alanı çeşitlenmiştir. Güneş enerjisinin sıklıkla kullanıldığı alanlardan

bazıları şunlardır: Tarımsal alanların ve seraların sulanması, sıcak su temini, konutların ısıtılması ve elektrik elde edilmesi(M. Koç, 2021).

Rüzgar enerjisi de tıpkı güneş enerjisi gibi uzun yıllardır insanlığın hizmetindedir. Milattan önceki yıllarda kullanılmaya başlayan rüzgar enerjisi karada yel değirmenlerine güç verirken denizde ise yelkenler vasıtasıyla gemilerin ilerlemesinde kullanılmıştır(Elibüyük ve Üçgül, 2014). Günümüzde rüzgar türbinleri ağırlıklı olarak elektrik elde etmek için kullanılsa da tarımsal sulama gibi farklı alanlarda da kullanılmaktadır(Özkan ve Yurtseven, 2019). Rüzgar türbinlerinin sınıflandırılmasında türbinin dönme ekseni, kanat sayısı, kurulum yeri, rüzgarı alış şekli gibi özelliklerinden yararlanılmaktadır. Dönme eksenine göre sınıflandırılan rüzgar türbinleri dikey eksenli, yatay eksenli veya eğik eksenli olarak adlandırılır. Kanat sayısına göre rüzgar türbinleri tek kanatlı, çift kanatlı, üç kanatlı veya çok kanatlı diye isimlendirilir. Kurulum yerine göre rüzgar türbinleri kara üstü ve deniz üstü olarak isimlendirilir. Rüzgarı alış şekline göre ise rüzgarı önden alan türbinler ve arkadan alan türbinler olarak sınıflandırılırlar(M. Koç, 2021).

Hidroelektrik santralleri Türkiye'nin en çok enerji elde ettiği santrallerdendir. Yenilenebilir enerji kaynaklarından olması, uzun yaşam süreleri ve giderlerinin düşük olması hidroelektrik santrallerini iyi birer enerji kaynağı haline getirmektedir. Türkiye aynı zamanda iyi bir hidroelektrik potansiyeline sahiptir ve Avrupa'nın hidroelektrik potansiyelinin %16'sına ev sahipliği yapmaktadır(M. Koç, 2021). Hidroelektrik santralleri baraj tipi hidroelektrik santrali ve akarsu tipi hidroelektrik santrali olmak üzere 2'ye ayrılmaktadır (Yaman ve Haşıl, 2018).

Yenilenebilir enerji santralleri sürdürülebilirlik ve temiz çevre hedefleri için yararlı olmasına rağmen yenilenebilir enerji santrallerinden enerji elde etmeninde bazı zorlukları vardır. Fosil yakıt santrallerinde elektrik üretimi santralin limitlerine göre yeterli ham madde bulunduğu müddetçe arttırılabilir veya azaltılabilir. Yenilenebilir enerji kaynaklarında ise üretilen elektriğin arttırılabilmesi veya azaltılabilmesi mümkün değildir. Bu nedenle enerji arz güvenliğini sağlamak ve şebekede gereğinden fazla elektrik bulunmasını engelleyebilmek için yenilenebilir enerji kaynaklarının elektrik üretiminin doğru tahmin edilebilmesi önem arz etmektedir.

Türkiye elektrik piyasasında gün içi, gün öncesi ve dengeleme güç olmak üzere üç sistem bulunmaktadır. Bu piyasanın katılımcıları elektrik üretim ve tüketim tahminlerini gün öncesinde bildirmek zorundadır. Yapılan bu bildirimler arz ve talebin dengelenmesine katkı sağlamaktadır. Gün öncesinde bildirilen elektrik üretimi ve tüketimi tahminlerinin değişkenlik gösterebileceği göz önüne alınarak piyasa katılımcılarına gün içerisinde de portföy dengeleme imkanı tanınmıştır. Gün öncesinde ve gün içinde dengelenemeyen arz ve talep tedarik şirketleri ve elektrik üreticilerine dengeleme güç piyasasında zarar olarak dönmektedir(Oruç, 2021). Elektrik üretiminin ve tüketiminin doğru tahmin edilmesi oluşan bu zararın azaltılması enerji maliyetlerinin düşmesinin yanı sıra yeraltı kaynaklarının daha az kullanılmasına ve bununla beraber çevrenin daha az kirlenmesine ve sürdürülebilirlik hedeflerine katkı sağlamaktadır.

1.1. Enerji Kullanımı

Elektriğin hayatımızın her alanına girdiği günümüzde, enerji arzının enerji talebini karşılaması ülkeler için bir zorunluluk haline gelmiştir. Enerji talebinin hayatımızdaki önemini bazı kesimlerce ülkelerin gelişmişlik düzeyini enerji tüketimlerine doğrudan bağlanmaktadır(İsmiç, 2015). Bu nedenle enerjiyi yönetmek de oldukça önemlidir.

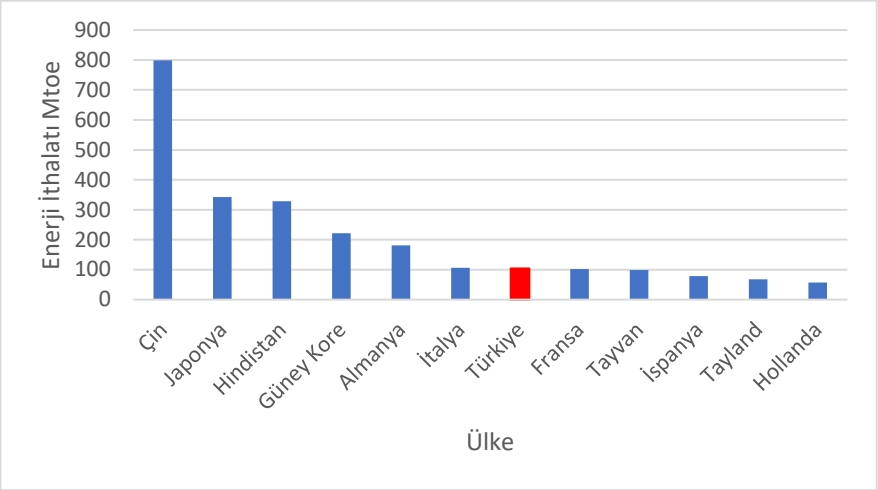
Türkiye, enerjide ithalatçı konumundadır. Özellikle 1990'dan sonra artan enerji ithalatı, Türkiye'nin toplam ithalatının %20'sine ulaşmıştır. Enerji ithalatı cari açıkla kıyaslandığında da benzer bir artış ortaya çıkmaktadır. Türkiye'nin enerji ithalatının cari açığa oranı 2005 yılında %99'lar seviyesine gelmişken 2017 yılında bu oran %78'lere gerilemiş 2018 yılında ise %159'lara kadar çıkmıştır(Ağıralioğlu ve Ağıralioğlu, 2020). Enerji ithalatının ekonomi için önemi göz önüne alındığında Türkiye'nin yerli ve yenilenebilir enerji kaynaklarına yaptığı yatırımlar büyük önem arz etmektedir.

1973 petrol krizi ülkelere enerji arz güvenliğinin önemini göstermiştir. Arap – İsrail Savaşı'nda Petrol İhraç Eden Arap Ülkeleri (OAPEC) batının İsrail yanlısı tutumu sebebiyle petrol fiyatlarını arttırmışlardır. Ardından 1979 yılında İran'da yaşanan İslam Devrimi petrol üretiminde yalnızca %4'lük bir düşüş yaşanmasına rağmen oluşan panik ile 1 yıllık süreçte varil petrol fiyatları 2 katına çıkmıştır. 2008 yılında yaşanan son ekonomik krizde ise petrol fiyatları tarihin en üst seviyesine çıkmıştır(Pekmezci, 2020).

1974 yılında ham petrolün fiyatı 4,5 kattan fazla bir artış göstererek 2,5 dolardan 11,6 dolara kadar çıkmıştır. Petrol ithalatçısı konumunda bulunan Türkiye'nin petrol

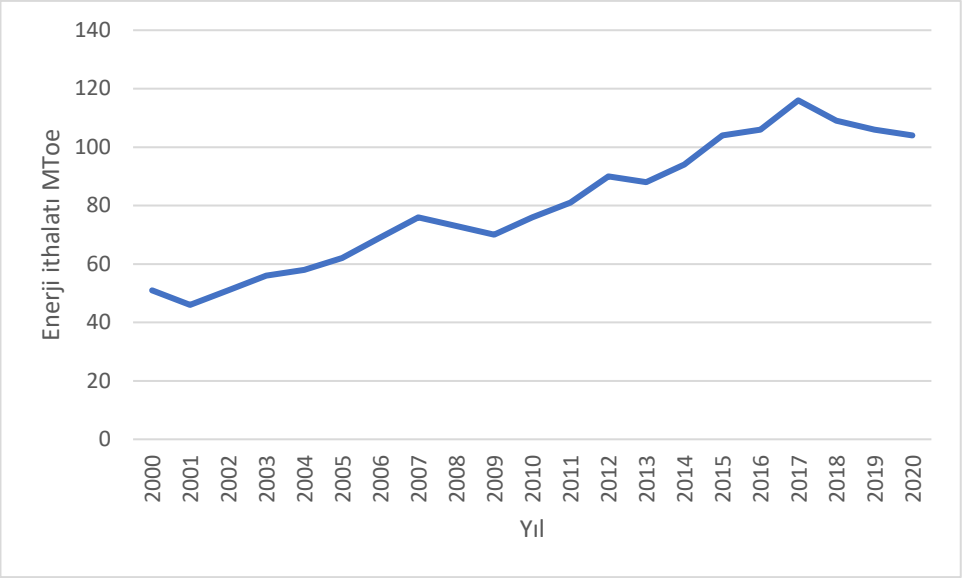
fiyatlarında yaşanan bu artışın da etkisiyle o dönemde dış ticaret açığı 2,3 milyar dolara kadar yükselmiş ve bütçe açığının 303 milyon dolara çıkmıştır(Öztürk ve Saygın, 2017).

Günümüzde enerji hala Türkiye için çok büyük bir ithalat kalemi konumundadır. Öyle ki Türkiye enerji ithalatında Dünya'da 7. Sırada bulunmaktadır(http-1). Enerji ithalatçısı konumunda bulunan ilk 11 ülke Şekil 1.1'de görülmektedir.



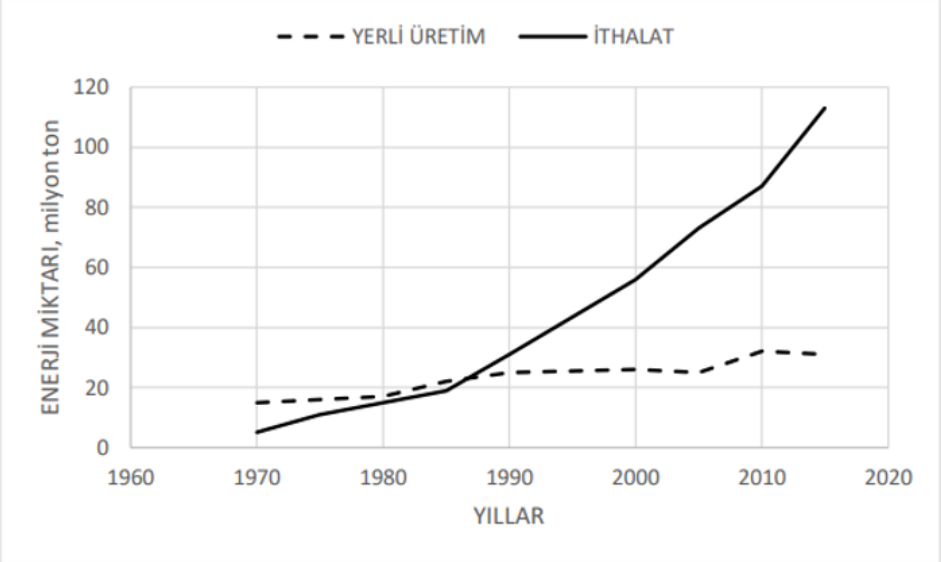
Şekil 1.1. En çok enerji ithal eden ülkeler (http-1)

Türkiye'nin enerji ithalatı 2000 yılında 51 milyon ton eşdeğer petrol (Mtoe) iken 2020 yılına gelindiğinde bu değer 2 katından fazla artmış ve 104 Mtoe seviyelerine ulaşmıştır. 2017 yılında 116 Mtoe ile tüm zamanların en yüksek değerine ulaşan enerji ithalatı, 2018, 2019 ve 2020 yıllarında azalmıştır. 2000 ile 2020 yılları arasında enerji ithalatının değişimi Şekil 1.2'de görülmektedir.



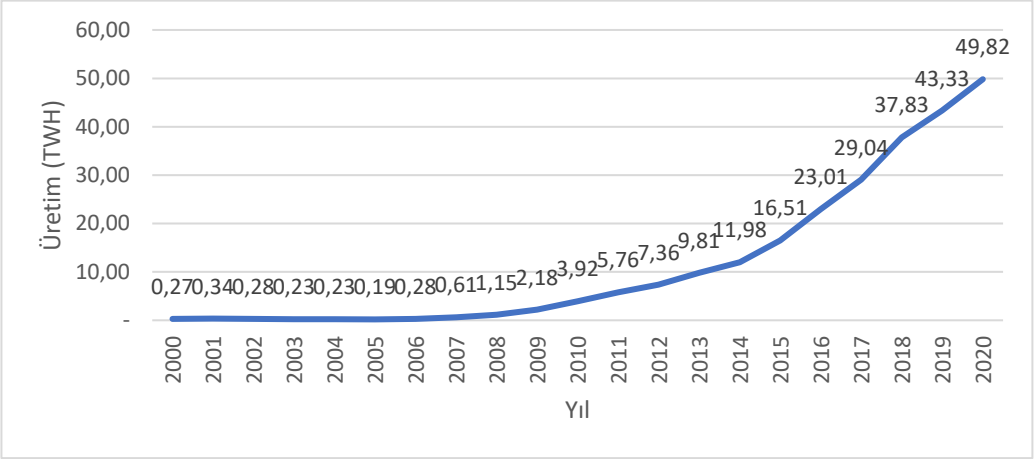
Şekil 1.2.Türkiye'nin Enerji İthalatı(BP, 2020)

Türkiye'de enerji ithalatının geçmişine gidildiğinde ise çok daha farklı bir grafik ortaya çıkmaktadır. 1970'li yıllara kadar Türkiye'nin enerji ithalatı yerli üretiminin altındayken enerjinin Dünya'da daha önemini iyice arttırdığı 1970 petrol krizinden sonra Şekil 1.3'te görülebileceği üzere Türkiye'nin yerli üretim enerji kaynakları ile enerji ithalatı arasındaki makas giderek daralmış ve 1980'lerin sonundan itibaren enerji ithalatı yıldan yıla artan bir eğilim gösterirken yerli üretim enerji kaynakları ise bu ithalata karşın nispeten yatay bir grafik sergilemiştir(Ağıralioğlu ve Ağıralioğlu, 2020).



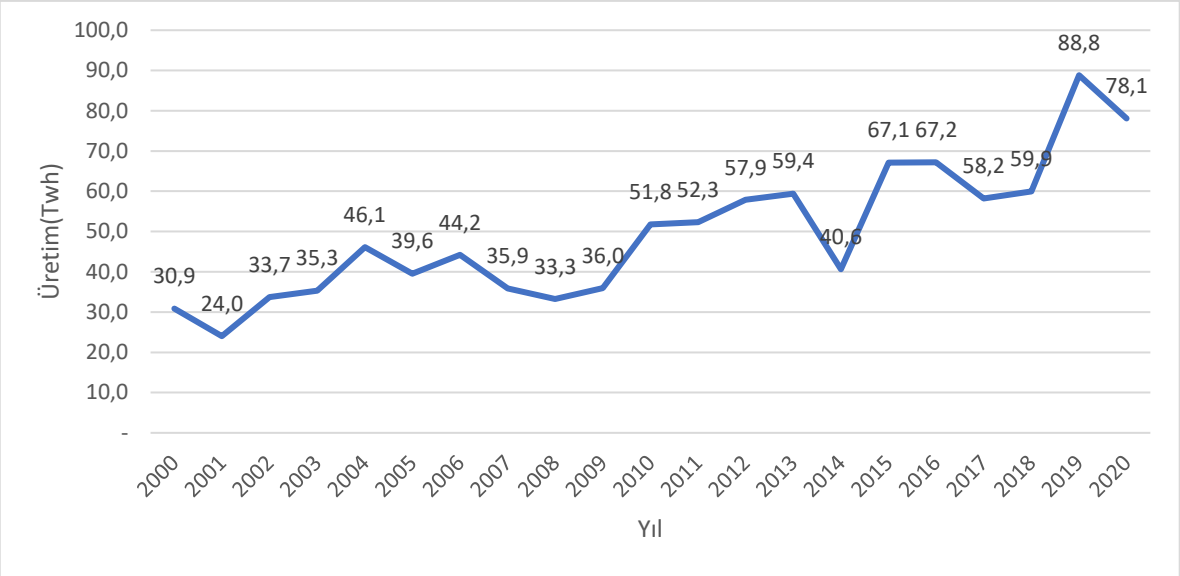
Şekil 1.3.Türkiye'nin yerli üretim enerji kaynakları ve enerji ithalatı

Enerji ithalatının bu kadar önemli bir gider kalemi olması elektrik üretimi başta olmak üzere yerli kaynakların kullanımını ön plana çıkarmaktadır. Türkiye bir yandan petrol, doğalgaz ve kömür gibi fosil yakıt kullanan santrallerinin iyileştirme ve modernizasyon çalışmalarını yaparken diğer yandan güneş, rüzgar ve hidroelektrik gibi yenilenebilir enerji kaynaklarına yaptığı yatırımları da arttırmıştır(Türkyilmaz, 2017). Rüzgar, jeotermal, güneş, biokütle ve atıklardan elde edilen elektriğin ele alındığı yenilenebilir enerji kaynakları ile yapılan üretimde Türkiye'nin 2000 yılında yalnızca 0,27 TWh iken aradan geçen 10 yılda 14,5 kat artarak 3,92 TWh'e 2010 yılından 2020 yılına kadar geçen 10 yılda ise 12,7 kat artarak 49,8 TWh'e yükselmiştir(http-2). Türkiye'nin yenilenebilir enerji kaynaklarını kullanarak elde ettiği elektriğin değişimi Şekil 1.4'te görülebilmektedir.



Şekil 1.4.Türkiye'nin yenilenebilir enerji kaynaklarından elektrik üretimi (http-2)

Hidroelektrik santralleri ise diğer yenilenebilir enerji kaynaklarının aksine Türkiye'de çok uzun yıllardır yatırım yapılan yenilenebilir enerji kaynaklarındandır. Şekil 1.5'de görülebileceği üzere üretilen elektriğin doğrudan yağış rejimine bağlı olması nedeniyle hidroelektrik santrallerinin elektrik üretimini inişli çıkışlı bir grafiğine sahiptir.



Şekil 1.5. Hidroelektrik santrallerinin elektrik üretimi (http-2)

Elektrik arz güvenliğini korumak, elektrik arz güvenliğini korurken de dış ticaret açığının artmasını engellemek için elektrik üretiminin ve tüketiminin doğru tahmin edilmesi ve bu tahminler ışığında doğru aksiyonların alınması gerekmektedir.

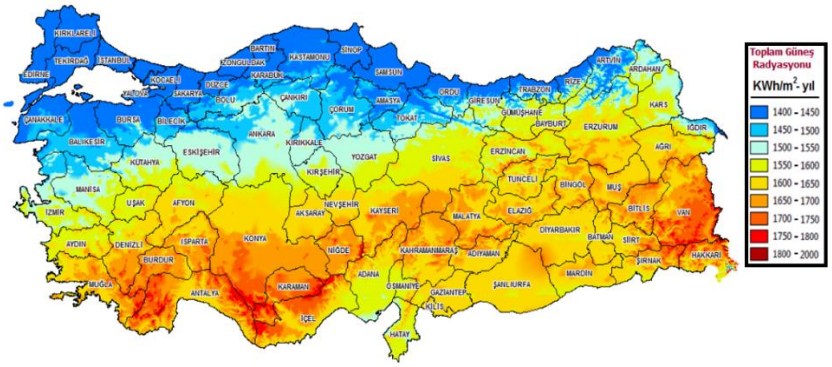
1.1.1. Türkiye'nin güneş enerjisi görünümü

Türkiye coğrafyası ve konumu itibariyle güneş enerjisi potansiyeli yüksek bir ülkedir. Türkiye'de şebekeye bağlanan ilk güneş enerji santrali (GES) 2012 yılında şebekeye bağlanmıştır. IBC solar tarafından kurulumu yapılan Konya MEDAŞ tesislerindeki bu GES 200 kW gücünde olup 25 yıl üretim taahhüt etmiştir(Soylu, 2019).

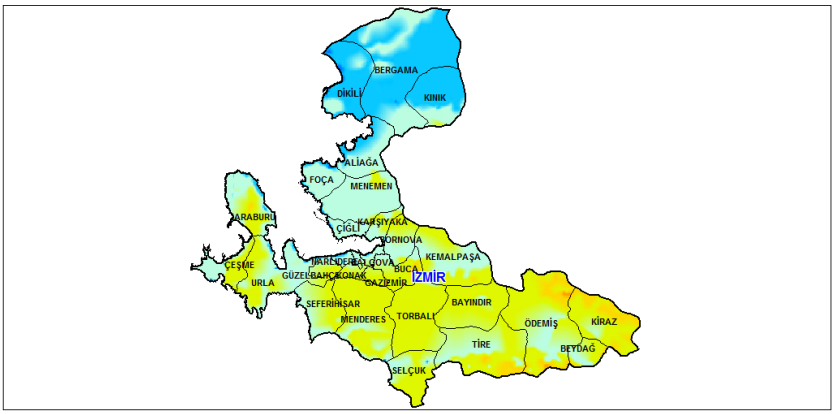
GES'lerin yatırım maliyeti iki bölümde incelenebilir. Bunlar ilk yatırım maliyeti ve işletim ve bakım maliyetidir. İlk yatırım maliyeti, güneş paneli, montaj seri, arazi, inşaat, inverterler ve diğer ekipman maliyetlerini kapsamaktadır. Bu giderlerin içerisinde büyük bölümü güneş paneli giderleri oluşturmaktadır. İşletim ve bakım maliyetleri ise ekipmanların yenilenmesi, panellerin temizliği gibi giderleri kapsamaktadır(Soylu, 2019).

Enerji ve Tabii Kaynaklar Bakanlığı'nca hazırlanan Türkiye Güneş Enerjisi Potansiyeli Atlası (TGEPA) Türkiye'nin yıllık güneşlenme süresinin 2741,07 saat olduğunu göstermiştir.m^2'ye düşen toplam ışınım iste 1527,46 kWh/m^2 olarak bulunmuştur. Şekil 1.6 da TGEPA gözükmektedir. Bu tez çalışmasına konu olan İzmir

Bakırçay Üniversitesi Güneş Enerji Santrali'nin(İBÜGES) de yer aldığı İzmir iline ait m^2 ye düşen toplam güneş radyasyonu değerleri Şekil 1.7'de gösterilmiştir(http-3).

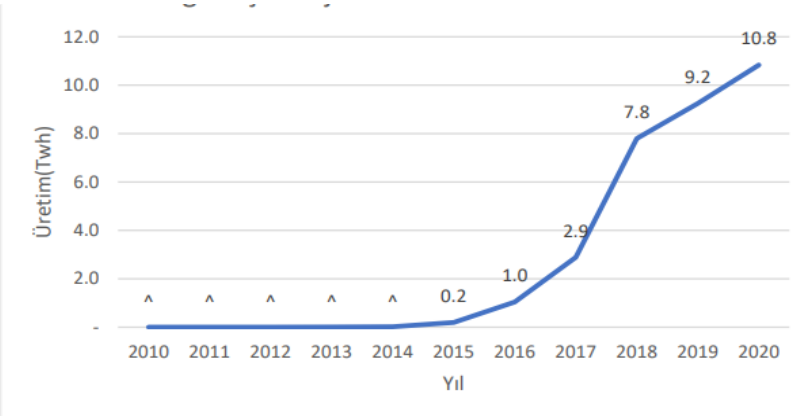


Şekil 1.6.Güneş enerjisi potansiyeli atlası (http-3)



Şekil 1.7.Güneş enerjisi potansiyeli atlasında İzmir ili(http-3)

Yapılan çalışmalar ve yatırımlar ile Türkiye'de özellikle 2014 yılından sonra güneş enerjisi kurulu gücünde artış yaşanmaya başlanmıştır. En büyük artış ise 2018 yılına gelindiğinde yaşanmıştır. Şekil 1.8. 'de Türkiye'nin 2010-2020 yılları arasında güneş enerjisinden elde ettiği elektrik gösterilmektedir (http-2).



Şekil 1.8. Türkiye'nin güneş enerjisiyle elektrik üretimi(http-2)

Yaşanan artış ile beraber güneş enerjisinin toplam elektrik üretimi içerisindeki payı da yıldan yıla artmıştır. 2014 yılında 40MW'lık kurulu güç ile üretilen toplam elektriğin yalnızca %0,01'ini oluşturan GES'ler 2018 yılında ilk defa 5063 MW'lık kurulu güç ile %1'in üzerinde bir pay elde ederek toplam elektrik üretiminin %2,56'sını oluşturmuştur. 2020 yılına gelindiğinde ise kurulu güç 6667 MW'a, elektrik üretimi içerisindeki payı ise %3,66'ya çıkmıştır. Bu kurulu gücün yanı sıra Türkiye önümüzdeki 10 yıl içerisinde bina çatı ve cephelerine toplam 2000 – 4000 MW'lık güneş modülü sistemlerinin kurulabileceğini tahmin etmektedir(http-3).

1.1.2. Sürdürülebilirlik

Sürdürülebilirlik en genel haliyle bugünün ihtiyaçlarını karşılarken geleceğin ihtiyaçlarını görmezden gelmemek, geleceğe de yaşanabilir bir Dünya bırakmaktır(Şardağı, 2021). Ortaya çıkışında sürdürülebilirlik kavramı, doğal kaynakların kullanımını kapsarken ilerleyen süreçte kapsamı genişlemiştir. 19. Yüzyılın başlarında literatüre girmeye başlayan sürdürülebilirlik kavramı tarım, orman ve balıkçılık gibi yenilenebilir alanlarla ilgilenmiştir(Özgün, 2021). Bugün sürdürülebilir tarımdan sürdürülebilir turizme ve sürdürülebilir enerjiye kadar pek çok kavram hayatımıza girmiştir(Yıldız, 2021).

Sürdürülebilir enerji, yerelden küresele enerji sisteminin geleceğine yardımcı olmak ve insanların ihtiyacını karşılarken doğayı da korumayı hedefleyen uzun vadeli bir kavramdır(Özgün, 2021). Enerji ihtiyacı karşılanırken doğaya geri dönüşü mümkün olmayan zararlar vermemeyi, kuşaklar arası adalet anlayışı ile enerji ihtiyacının giderilmesini hedefler. Enerjinin çevreye zararlı ve kısıtlı fosil yakıtlar yerine çevre dostu

ve sonsuz yenilenebilir enerji kaynaklarından elde dilmesi gerektiğini savunur(Demircioğlu, 2003). Sürdürülebilir enerji kavramı ile verimliliğin arttırılması, karbon emisyonunun azaltılması ve eşit enerji hizmetinin sunulması hedeflenmektedir. Enerji krizi, özellikle gelişmekte olan ülkelerde iklim değişikliği ve bununla bağlantılı birçok etkiden daha büyük bir tehlike arz etmektedir. (Özgün, 2021). 1992 yılında Brezilya'nın Rio de Janeiro kentindeki konferans ile imzaya açılan İklim Değişikliği Çerçeve Sözleşmesi ve 1997 yılında Japonya'nın Kyoto kentindeki toplantıda oluşturulan Kyoto Protokolü sera gazı emisyonunu azaltma girişimlerinin en önemlilerindendir(Demircioğlu, 2003).

1.1.3. Yeşil mutabakat

Ticaret bakanlığının 2021 Yeşil Mutabakat Eylem Planı incelendiğinde, Türkiye'nin de üyesi olduğu Birleşmiş Milletler 193 üye ülke ile 2015 yılında "2030 Sürdürülebilir Kalkınma" gündeminin güçlendirilmesine ne kadar ihtiyaç duyulduğunu gözler önüne sermektedir.

Avrupa Yeşil Mutabakatı ile karbon emisyonu azalttırılırken üretim ve yatırımların emisyon azaltma hedefi daha az olan ülkelere kaymasını engellemek adın "Sınırda Karbon Düzenleme Mekanizması (SKDM)" nın hayata geçirilmesi hedeflenmektedir.14 Temmuz 2021 tarihinde amacı, belirlenen sektörlerde ithalat fiyatının karbon içeriğine göre belirlemek olan SKDM ilişkin teklif yayımlanmıştır. AB Emisyon Ticaret sistemi ile aynı doğrultudan kurgulanan SKDM'ye tabi olan sektörler şunlardır: Demir-çelik, çimento, alüminyum, elektrik ve gübre. Türkiye SKDM'nin Avrupa Birliği ile olan ticareti üzerindeki etkilerinin azaltılması için çalışmalar yürütmektedir. Bu konuda planlanan eylemler SKDM'nin enerji yoğun ve kaynak yoğun sektörlere etkilerinin çalışılması da bulunmaktadır(Ticaret Bakanlığı, 2021).

Yine Türkiye'nin yeşil mutabakatı sürdürülebilir tarımı da hedeflemektedir. AB'nin pestisit ve anti mikrobiyallerin azaltılması hedefi ile paralel bir şekilde Türkiye'de pestisit ve anti mikrobiyallerin azaltılması için çalışmalar yürütmeyi hedeflemektedir. Bu hedef doğrultusunda biyolojik ve biyoteknik mücadeleye yöntemlerinin yaygınlaştırılması planlanmaktadır. Yine aynı AB hedefleri ile paralel şekilde kimyasal gübre kullanımının azaltılması, organik tarımın geliştirilmesi, yenilenebilir enerji kullanan sera ve üretim tesislerinin desteklenmesi gibi planlar

Türkiye'nin sürdürülebilir tarım hedeflerine ulaşmak için yapmayı planladığı çalışmalardan bazılarıdır(Ticaret Bakanlığı, 2021).

Yeşil mutabakat eylem planının en önemli ayaklarından biri de şüphesiz ki iklim değişikliği ile mücadeledir. Dünya genelinde iklim değişikliği ile mücadele kapsamında sera gazı emisyonlarının azaltılması hedefine verilen önemin artması ve karbon yoğunluğu azaltılmış küresel ekonominin sağlanması, küresel enerji politikalarının gözden geçirilmesine neden olmuştur. Bu doğrultuda Türkiye de yenilenebilir enerji kaynaklarının arttırılmasıyla sera gazı emisyonunun azaltılmasını hedeflemektedir. 11. Kalkınma Planında da enerji arz güvenliğinin sağlanması, sürdürülebilir, kaliteli ve güvenli enerjinin katlanılabilir maliyetlerle elde edilmesi temel amaç olarak belirlenmiştir. Bu amaç doğrultusunda enerji verimliliğinin ve yenilenebilir enerji kaynaklarından yapılan üretiminin artırılması için çeşitli kararlar ve tedbirler alınmıştır. Alınan bu tedbirler ve atılan adımlar neticesinde Türkiye Dünya'da yenilenebilir enerji kurulu gücünde 12. sırada Avrupa'da ise 5. sıradadır. Yenilenebilir enerji kaynaklarından olan rüzgar ve güneş enerjilerinde Avrupa'da 7. sıradadır. Isıtma amaçlı olarak kullanılan güneş enerjisinde ise Amerika Birleşik Devletleri ve Çin'in ardından Dünyada 3. sıradadır(Ticaret Bakanlığı, 2021).

Yeşil Tarife uygulamasını 1 Ağustos 2020 itibariyle hayata geçiren Türkiye, yenilenebilir kaynaklardan elde edilmiş elektriği kullanmak isteyen tüketicilerine "Yenilenebilir Enerji Kaynak Garanti" belgesi adını verdiği YEK-G belgesi ile güvence altına alınmış elektriği ulaştırmaktadır(Ticaret Bakanlığı, 2021).

2. MATERYAL

2.1. Bakırçay Üniversitesi Güneş Enerji Santrali

İBÜGES, İzmir Bakırçay Üniversitesi'nin personel otoparkında bulunmaktadır. İBÜGES'de bulunan paneller Perlight Solar tarafından üretilmiştir. Her bir panelin boyutu 1650x992x40 mm^3 'tür. Birim ağırlığı 19,6 kg'dır. Sistemde bulunan hücrelerin tipi polikristaldir. Panellerin detaylı özellikleri Tablo 2.1 'de verilmiştir.

Tablo 2.1.Güneş panellerinin teknik özellikleri (PerlightSolar, n.d.)

Üretici	: Perlight
Hücre Tipi	: Polikristal
Maksimum Güç (Pm)	:250W
Maksimum Voltaj (Vmp)	:31,73V
Maksimum Akım (Imp)	:7,88A
Açık Devre Gerilimi	:37,58V
Kısa Devre Akımı (Isc)	:8,49A
Maksimum Sistem Voltajı	:1000V
Hücre Boyutu(mm)	:156X156
Modül Boyutu(mm)	:1650X992X40
Ağırlık (Kg)	:19,6
Hata Payı	:0/+3%
Çalışma Sıcaklığı	: -40°C~+85°C
Standart Test Koşulları	:1000W/m², AM1,5 , 25°C

Panellerin bulunduğu alan yaklaşık 5000 m^2'dir. Santralde toplam 1600 adet güneş paneli bulunmaktadır. Santralin güç çıkışı 400 kWp 'ye eşittir. Çelik konstrüksiyonlar üzerine yerleştirilmiş olan güneş panelleri elektrik üretiminin yanında otoparkta bulunan araçlara gölge de yapmaktadır. Güneş panellerinin yerleşimi ve okula göre konumu Şekil 2.1'de verilmiştir.



Şekil 2.1.Güneş panellerinin yerleşimi ve okula göre konumu

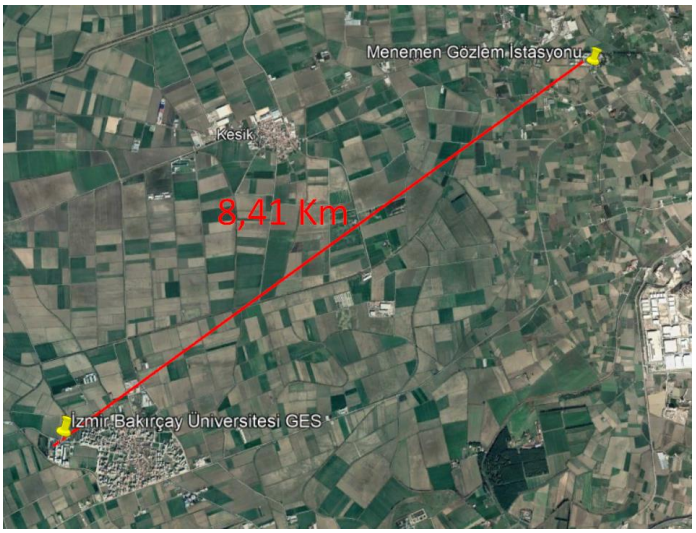
2.2. Girdiler

Girdiler İBÜGES'in yakınında bulunan 2 meteorolojik gözlem istasyonundan alınmıştır. Bu istasyonlar 17789 MENM kodlu Menemen istasyonu ve 17218 LTBL kodlu Çiğli Havaalanı istasyonudur.

Menemen istasyonu bir otomatik meteorolojik gözlem istasyonudur. Otomatik meteorolojik gözlem istasyonları 2000'li yıllarda kurulmaya başlanmıştır. İlk otomatik meteorolojik gözlem istasyonları büyük klima istasyonlarının ölçüm alanlarına kurulmuş ve manuel istasyonlar ile beraber çalışmışlardır. Ardından farklı sahalara da otomatik meteorolojik gözlem istasyonları kurulmaya başlanmıştır. Yeni kurulan istasyonlar daha önce kapatılan yağış ve küçük klimatoloji istasyonlarının bulunduğu sahalara kurulmuştur. Bu sahalar dışında daha önce ölçüm istasyonu olmayan sahalara da Otomatik meteorolojik gözlem istasyonları kurulmuştur(E. Yılmaz ve Darende, 2021).

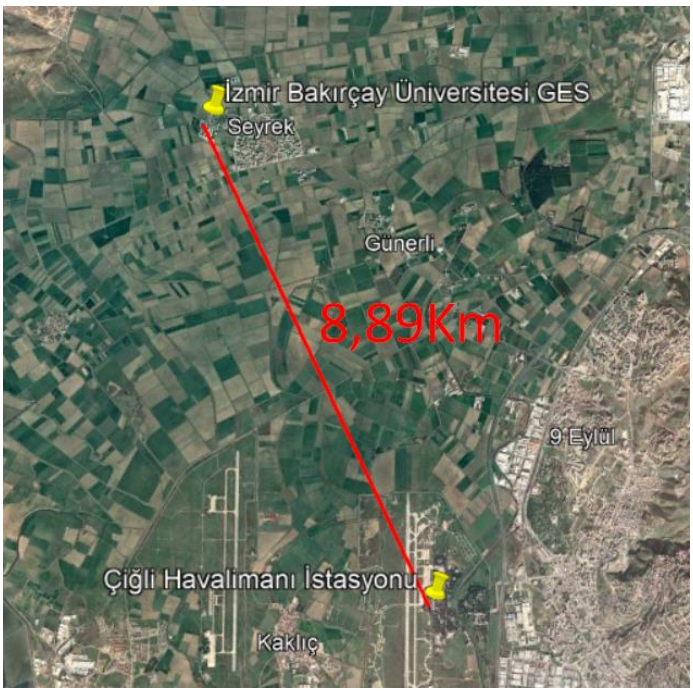
Menemen istasyonu gibi otomatik meteorolojik gözlem istasyonlarının kurulmasıyla beraber manuel istasyonlar ile hassasiyet farkları oluşmuştur. Örneğin manuel ölçüm istasyonlarından alınan günlük ortalama sıcaklık verisi 3 veya 24 ölçüm ile hesaplanırken Otomatik gözlem istasyonlarında bu sayı 24 ile 1440 arasındadır.

Yaşanan bu farklılık özellikle uzun zaman serilerinde tutarsızlığa neden olmaktadır(E. Yılmaz ve Darende, 2021). Menemen istasyonu ve İBÜGES'in konumu Şekil 2.2'de gösterilmiştir.



Şekil 2.2. Menemen istasyonu ve İzmir Bakırçay Üniversitesi'nin konumu

Çiğli havalimanı istasyonu insanlı ölçümlerin yapıldığı bir istasyondur. Çiğli havalimanı istasyonu ve İBÜGES'in konumu Şekil 2.3'de gösterilmiştir.

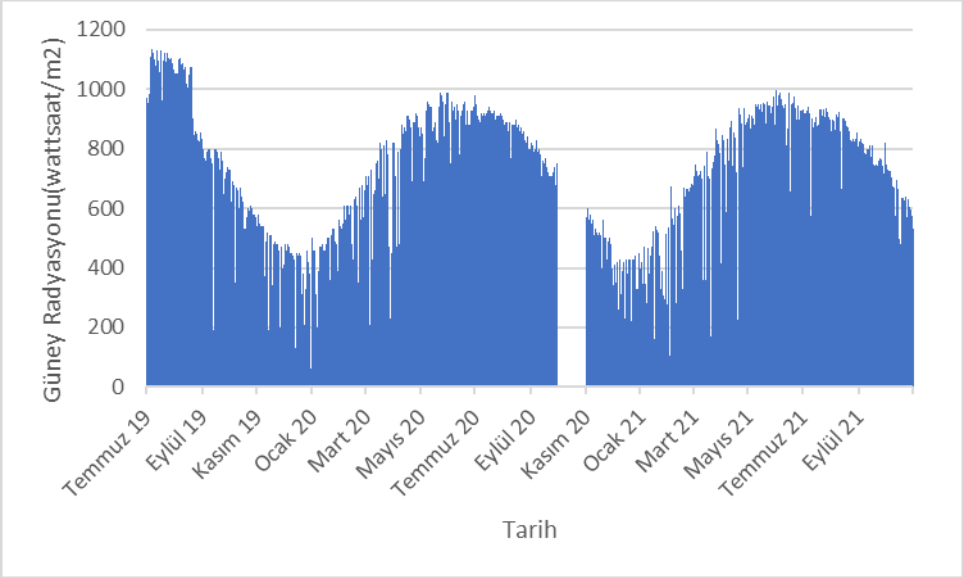


Şekil 2.3.Çiğli havalimanı istasyonu ve İzmir Bakırçay Üniversitesi'nin konumu

Bu çalışmada, GES'in üretimini tahmin edebilmek için çeşitli meteorolojik veriler kullanılmıştır.

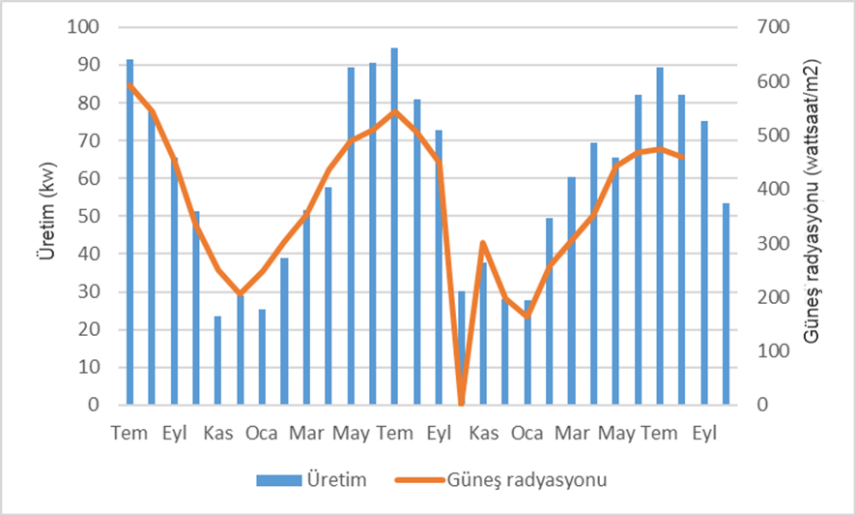
2.2.1. Saatlik küresel güneş radyasyonu

Saatlik küresel güneş radyasyonu verisi Menemen istasyonundan alınmış olup birimi wattsaat/m2'dir. Saatlik tahminler 1 Temmuz 2019 ile 31 Ekim 2021 tarihleri arasında 0'a çok yakın olan üretimler dahil 10317 adet veri bulunmaktadır.2020 yılı ekim ayına ait güneş radyasyonu verileri eksiktir. Güneş radyasyonunun değişimi Şekil 2.4 te gösterilmektedir.



Şekil 2.4. Güneş radyasyonu

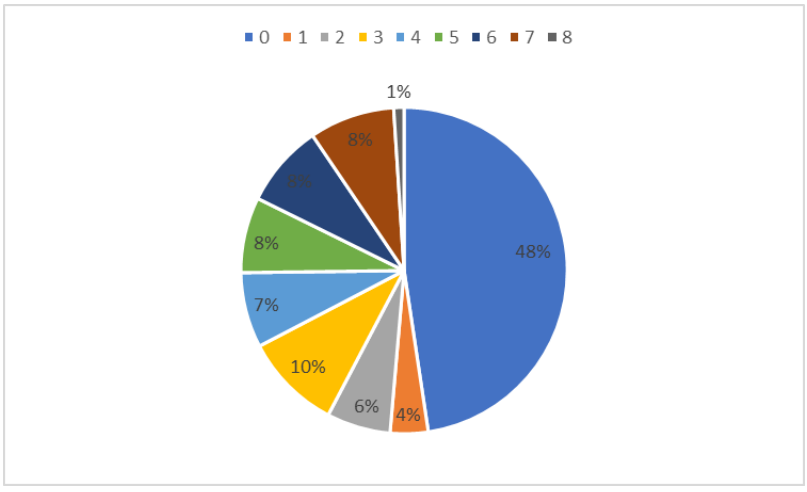
Aylık ortalama Güneş radyasyonu ve aylık ortalama elektrik üretimi arasındaki ilişki Şekil 2.5'de görülmektedir. Grafik incelendiğinde beklenildiği üzere Güneş radyasyonu ile elektrik üretiminin aynı mevsimsellikte hareket ettiği ve aralarında gözle görülür bir ilişkinin bulunduğu görülmektedir.



Şekil 2.5.Güneş radyasyonu verisi ile elektrik üretim verisi arasındaki ilişki

2.2.2. Saatlik bulutluluk verisi

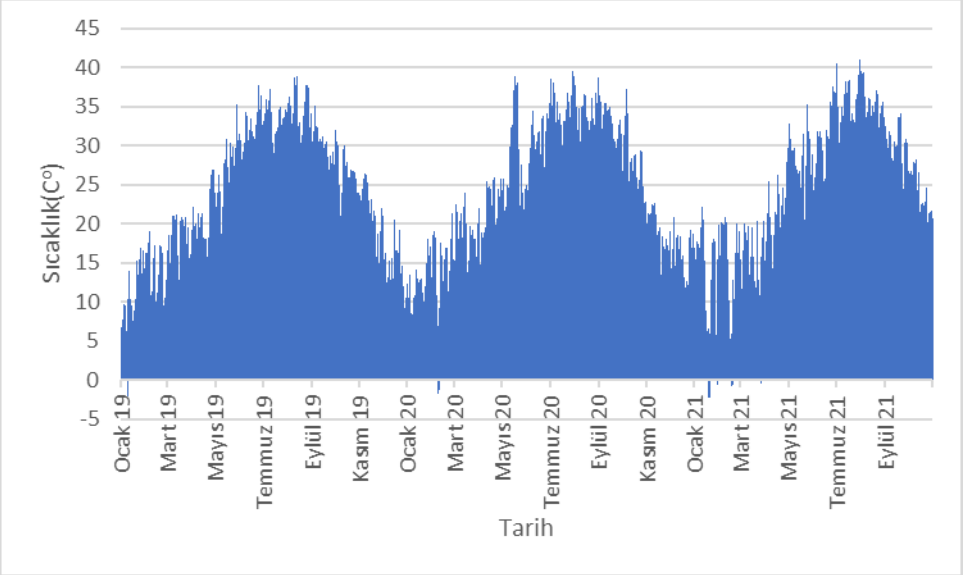
Saatlik bulutluluk verisi Çiğli havaalanı istasyonundan alınmıştır. Saatlik bulutluluk ölçümleri otomatik meteoroloji gözlem istasyonlarınca yapılamamaktadır. Saatlik bulutluluk ölçümü klima sinoptik ve metar rasatlarının yapıldığı istasyonlarca yapılmaktadır. Saatlik bulutluluk verisi ölçümü 8 OKTA olarak yapılmaktadır. 8 üzerinden 1 ve 2 az bulutlu, 3 ve 4 parçalı bulutlu, 5,6, 7 çok bulutlu 8 ise gökyüzü bulutla kaplı anlamındadır. 1 Temmuz 2019 ile 31 Ekim 2021 tarihleri arasında 19496 adet saatlik bulutluluk verisi bulunmaktadır. Bulutluluk verisinin dağılımı Şekil 2.6' da gösterilmiştir.



Şekil 2.6. Bulutluluk dağılımı

2.2.3. Saatlik ortalama sıcaklık

Saatlik ortalama sıcaklık verisi Menemen istasyonundan alınmıştır. Birimi C$^{o'}$ dir. Saatlik ortalama sıcaklık ölçümleri gölgede ve yer seviyesinden 2 metre yükseklikte yapılmaktadır. 1 Temmuz 2019 ile 31 Ekim 2021 tarihleri arasında 20408 adet saatlik ortalama sıcaklık verisi bulunmaktadır. Bu dönemde kaydedilen en yüksek sıcaklık 41,1 C^{o} ile 31 Temmuz 2021 tarihinde kaydedilmiştir. En düşük sıcaklık ise -2,2 C^{o} ile 19 Ocak 2021 tarihinde kaydedilmiştir. Verilerin dağılımı Şekil 2.7'de gösterilmektedir.

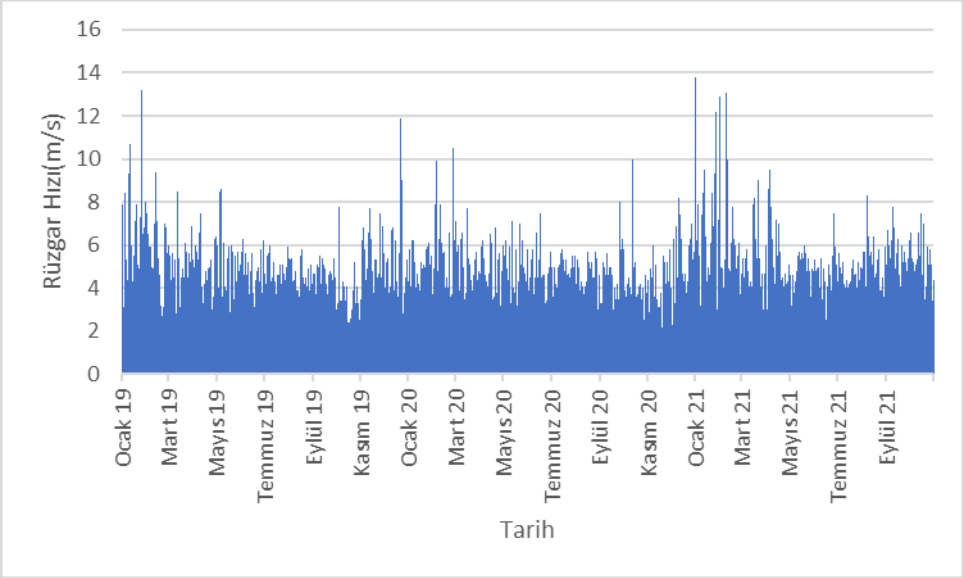


Şekil 2.7.Sıcaklık

2.2.4. Saatlik ortalama rüzgar hızı

Saatlik ortalama rüzgar hızı verisi Menemen istasyonundan alınmıştır. Saatlik ortalama rüzgar hızının birimi m/s'dir. 1 Temmuz 2019 ile 31 Ekim 2021' tarihleri arasında 20424 adet saatlik ortalama rüzgar hızı verisi bulunmaktadır. Rüzgar hızı 0,0-0,2 m/sn arasındaysa sakin 0,3-1,5 m/sn arasındaysa esinti, 1,6-3,3 m/sn arasındaysa hafif rüzgar 3,4-5,4 m/sn arasındaysa tatlı rüzgar, 5,5-7,9 m/sn arasındaysa orta rüzgar, 8,0-10,7 m/sn arasındaysa sert rüzgar, 10,8-13,8 m/sn arasındaysa kuvvetli rüzgar 13,9-17,1 m/sn arasındaysa fırtınamsı rüzgar, 17,2-20,7 m/sn arasındaysa fırtına, 20,8-24,4 m/sn arasındaysa kuvvetli fırtına, 24,5-28,4 m/sn arasındaysa tam fırtına, 28,5-32,6 m/sn arasındaysa çok şiddetli fırtına, 32,7 m/sn'den daha fazlaysa harikeyn olarak adlandırılır.

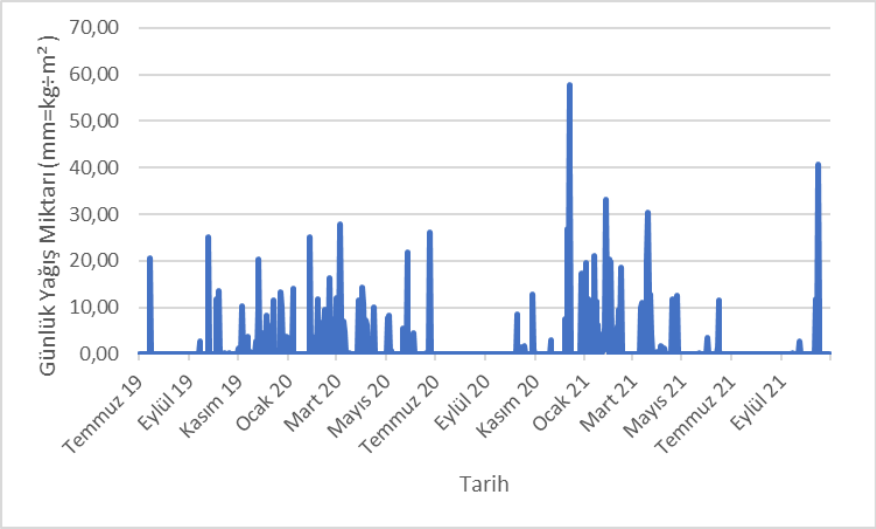
En yüksek rüzgar hızı 1 Ocak 2021'de 13,8 m/s en düşük rüzgar hızı ise 0 m/s ile birden fazla günde ölçülmüştür. 1 Temmuz 2019 ile 31 Ekim 2021 tarihleri arasındaki ölçümlerin %0,064'ünde kuvvetli rüzgar, %0,428'inde sert rüzgar %3,719'unda orta rüzgar, %22,623'ünde tatlı rüzgar, %42,746'sında hafif rüzgar, %30,025'inde esinti, %0,391'inde ise sakin rüzgar gözlemlenmiştir. Fırtınamsı rüzgar, fırtına, kuvvetli fırtına, tam fırtına, çok şiddetli fırtına ve harikeny gözlemlenmemiştir. Ölçümlerin dağılımı Şekil 2.8'de ki gibidir.



Şekil 2.8.Rüzgar hızı

2.2.5. Günlük toplam yağış miktarı

Günlük toplam yağış miktarı verisi Menemen istasyonundan alınmıştır. Birimi Günlük toplam yağış miktarı ölçümleri içinde bulunan günün 06:00 UTC saati ile bir önceki günün 06:00 UTC saatleri arasında yapılmaktadır. Temmuz 2019 ile Ekim 2021 tarihleri arasında 854 adet veri bulunmaktadır. Yağış miktarının birimi mm=kg÷m² dir. Günlük yağış miktarı grafiği Şekil 2.9'deki gibidir.

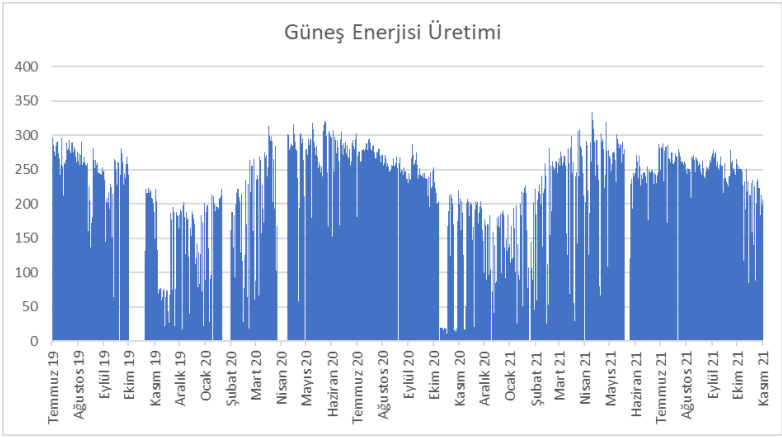


Şekil 2.9.Günlük yağış miktarı

Girdiler incelendiğinde, güneş radyasyonu ve sıcaklık mevsimlere göre oldukça ön görülebilir frekanslarda hareket ederken rüzgar hızı çok daha kaotik davranış sergilemektedir. Günlük yağmur verisi de tıpkı rüzgar hızı verisi gibi daha kaotik bir yapıdadır. Tıpkı rüzgar hızı gibi kış aylarında yağış miktarında da artış yaşanmaktadır ancak bu artışları ön görmek hayli zordur.

2.3. Çıktılar

Oluşturulan yapay sinir ağı (YSA) modelinin tek çıktısı İBÜGES'in elektrik üretimidir. Bu veriler İzmir Bakırçay Üniversitesi yapı işleri ve teknik daire başkanlığı tarafından Gediz Elektrik'in online portalı üzerinden alınmıştır. Üretimin sıfır olduğu saatler dahil toplam 20055 adet veri bulunmaktadır. Çıktıların dağılımı Şekil 2.10'da gösterilmektedir.



Şekil 2.10.İzmir Bakırçay Üniversitesi güneş enerji santralinin elektrik üretimi

Santralde üretilen güneş enerjisi de tıpkı sıcaklık ve güneş radyasyonu verisinde olduğu gibi daha öngörülebilir hareket etmektedir. 01 Ekim 2019 saat 00:00 ile 19 Ekim 2019 saat 22:00 arasındaki elektrik üretim verileri eksiktir. 18 Mayıs 2021 20:00 ile 25 Mayıs 2021 saat 15:00 arasında elektrik üretim verileri sıfır olarak kaydedilmiştir.

2.4. Saat Aralığının Belirlenmesi

Bu çalışmada tahmin edilecek saat aralığının seçilebilmesi için bir dizi çalışmalar yapılmıştır. Türkiye saati ile saat 22:00 ile saat 05:00 arasında üretim önemsiz miktarlarda olduğundan değerlendirmeye alınmamıştır. Tablo 2.2'de 06:00 ile 21:00 saatleri arasındaki veriler gösterilmektedir.

Tablo 2.2.Elektrik üretimi verisinin incelenmesi

Saat	Toplam veri sayısı	Üretim Olmayan Veri	5kw'dan az üretim	10kw'dan az üretim	En küçük üretim	En büyük üretim
06:00	835	570	812	834	0	19,32
07:00	835	241	389	480	0	54,51
08:00	835	85	165	197	0	140,07
09:00	835	45	65	88	0	218,04
10:00	835	39	45	53	0	292,56
11:00	835	42	46	48	0	304,94
12:00	835	38	42	49	0	320,85
13:00	835	36	41	46	0	333,96
14:00	835	36	39	49	0	316,02
15:00	835	41	48	55	0	291,87
16:00	835	43	82	124	0	240,81
17:00	835	129	186	222	0	192,51
18:00	835	285	351	369	0	97,29
19:00	835	439	543	606	0	34,5
20:00	835	713	835	835	0	2,07
21:00	835	831	835	835	0	0,19

Yapılan bu incelemenin sonucunda üretim değerlerinin çok küçük olduğu 06:00, 07:00, 19:00, 20:00, 21:00 saatleri tahmin modelinden çıkarılmıştır.

2.5. Eksik Girdilerin Tespiti

Elektrik üretiminin tahmin edilmesi işlemine geçilmeden önce verilerin değerlendirilmesi ve eksik verilerin tamamlanması için çalışmalar yapılmıştır. 2020 ekim ayına ait eksik güneş radyasyonu verilerinin haricinde eksik diğer veriler tespiti için

çalışmalar yapılmıştır. Saat 8:00 ile 18:00 arasında 8255 adet veride eksik bulunmamaktadır. En az 1 girdisi eksik olan 1128 saat bulunmaktadır. Bu 1128 saat eksik girdinin 341 adedi 2020 ekim ayına ait güneş radyasyonu verisinin eksikliğinden kaynaklanmaktadır. 219 eksik girdi Ekim 2020 hariç diğer kış aylarında güneş radyasyonunun 0 olduğu 8.00 saatine 143 eksik girdi yine 2020 ekim hariç diğer kış aylarında güneş radyasyonunun 0 olduğu 18.00 saatine aittir. Bu veriler çıkarıldığında 425 saatlik girdide eksik bulunmaktadır. Girdilerin eksikliğinin giderilmesi için aynı saate ait bir önceki gün ile bir sonraki günün ortalaması alınarak eksiklik giderilmiştir. 2020 Ekim ayına ait eksiklikler ise giderilmemiştir. Ekim ayının da içinde bulunduğu 4. çeyrek verileri bu eksiklik ile tahmin edilmiştir.

3. METOD

YSA, Öztemel'e göre insan beynine özgü öğrenme ile bilgi edinme, bilgi oluşturma ve keşfetme gibi özellikleri yardım olmaksızın yapabilen bilgisayar sistemleridir(Öztemel, 2006). Öztürk ve Şahin, YSA'ları insan beyninin öğrenme şeklini taklip eden öğrenme, hatırlama ve genellemeyi kullanarak elindeki verilerden yeni veriler üretme yeteneğine sahip bilgisayar yazılımları olarak tanımlamıştır(Özturk ve Şahin, 2018). Keskenler ve Keskenler YSA'ları, insan beyninin sahip olduğu biyolojik sinirleri taklit ederek algılayıcılar vasıtasıyla öğrenilmiş veya sınıflandırılmış bilgileri kullanıp yeni bilgiler oluşturabilen, kararlar verebilen bilgisayar programları olarak tanımlamıştır(Keskenler ve Keskenler, 2017). Grossi ve Buscema'ya göre YSA, insan beyninin işleyiş süreçlerinden ilham alan uyarlanabilir yapay sistemlerdir. Fonksiyonun iç yapısına göre değiştirilebilen bu sistemler özellikle lineer olmayan türdeki problemleri çözmek için uygundur diyerek tanımlamıştır(Grossi ve Buscema, 2007).

Yapılan bu tanımlar doğrultusunda YSA'ların insan beyninin çalışmasına benzer çalışması beklenen, dışarıdan yardım almasına gerek olmadan elinde bulunan verileri kullanarak öğrenebilen ve bu öğrenme işleminden sonra genelleme yapabilen, tahmin edebilen, yeni bilgiler oluşturabilen sistemlerdir.

3.1. YSA'larnın Tarihi

1943 yılında nöro fizyolog Warren McCulloch ve matematikçi Walter Pitts, nöronların çalışması üzerine bir makale yazdı. İnsan beynindeki nöronların nasıl çalıştığını tanımlamak için elektrik devrelerini kullanarak basit bir sinir ağı modeli oluşturdular(http-4). McCulloch ve Pitts'in oluşturduğu model biyolojik nöronların temel özelliklerini modelleyerek YSA'ların gelişimine önemli bir katkı sağlamıştır(http-5).

McCulloch ve Pitts'in bu YSA için oluşturduğu matematiksel ifade denklem (3.1)'de gösterilmektedir.

$$y_i = f\big(g(x)\big) = f\left(\sum_{J=0}^{n} w_{ij}x_j - \phi\right); x_i = (x_1, x_2, \dots, x_n)\varepsilon R \qquad (3.1)$$

X_i girdiyi y_i çıktığı w_{ij} ağırlığı ϕ eşik değerini temsil etmektedir. Fonksiyonun genelinde f(.) transfer fonksiyonu g(.) ise toplama fonksiyonudur. Transfer fonksiyonu denklem (3.2) eşitliğiyle hesaplanmaktadır (Oruç, 2021).

$$f(\cdot) = \begin{cases} 1; g(\cdot) \geq 0 \\ 0; g(\cdot) < 0 \end{cases} \quad (3.2)$$

1950'lere gelindiğinde Nathaniel Rochester ve Claude Shannon "Yapay zekanın iki aylık ve on kişilik araştırması" sunumu ile yapay zeka kavramını ilk defa ortaya atmıştır (Kara Kılıçarslan, 2019).

1960'ların başında Windrow ve Hoff ADALINE ağını kullanarak en küçük kareler algoritması olarak isimlendirilmiş öğrenme kuralını geliştirdi. Adaptif lineer nöron olarak isimlendirilen ADALINE sinir hücresi yapısal açıdan algılayıcılardan farklı olmamasına algılayıcılar aktivasyon fonksiyonu olarak eşik fonksiyonu kullanırken ADALINE doğrusal fonksiyon kullanmaktadır (Arı ve Berberler, 2017).

1982 yılında John Hopfield bir ağ mimarisi geliştirdi. Geliştirdiği bu ağ mimarisi ile hafıza ilişkilerini anlamak istedi. Bu gelişme YSA çalışmalarını hızlandıran önemli gelişmelerden biridir(Doğmuş, Onat, Yılmaz ve Ergün, 2005). Rummelhart'ın paralel programlama çalışmaları YSA'ların gelişmesinde önemli bir mihenk taşı olan çok katmanlı algılayıcıların ortaya çıkmasında oldukça etkili olmuştur (Keskenler ve Keskenler, 2017).

1990'lı yıllara gelindiğinde IBM yeni bir süper bilgisayar geliştirmiştir. Deep Blue adı verilen bu süper bilgisayar döneminin satranç Dünya şampiyonu günümüzde ise tüm zamanların 2 numarası olan Garry Kasparov'u yenmesiyle insan makine rekabeti yeni bir boyuta geçiyor. Deep Blue dönemin dünya şampiyonunu yenmiş olmasına rağmen YSA'lar gibi bir öğrenme becerisine sahip değildir. Deep Blue yalnızca çok iyi paralel işlem yeteneğine sahip bir bilgisayardır (Ege, 2011).

1995 yılına gelindiğinde S&P 500 endeksinin yön değişimi başarıyla tahmin edilmiştir. Türkiye'de benzer kullanımı Dünya'nın geri kalanı kadar yaygın olmayıp finansal başarısızlığın öngörülmesinde kullanılmıştır (Kutlu ve Badur, 2009).

2010'lara gelindiğinde Hinton ve Salakhutdinas yayınladıkları makale ile derin öğrenme fikrini ortaya atmıştır. Derin öğrenme algoritmalarında çok katmanlı bir YSA bulunmaktadır. Oluşturulan bu çok katmanlı ağ görüntüye ait özellik çıkarımları YSA'nın katmalarında oluşturmaktadır. Konvolüsyon ile görüntünün kenar ve özellikleri belirlenir ve YSA'nın katmanları bu bilgiyi alt katmanlara iletir (Ferdi. ve Türkoğlu, 2018).

1990'lardan günümüze YSA'lar ile ilgili çalışmalar günlük hayatta kullanılan sistemler olmaya ve insan hayatına dokunmaya başlamışlardır. 1990'ların öncesinde ise çalışmalar teorik ve laboratuvar çalışmaları düzeyinde kalmıştır(Öztemel, 2006).

3.2. YSA'larnın Yapısı

YSA'lar daha önce de belirtildiği gibi biyolojik sinir ağlarından ilham alarak oluşturulmuştur. Bu nedenle YSA'ların yapısı biyolojik sinir ağları ile benzerlik gösterir. Bir biyolojik sinir hücresinde hücre gövdesi, hücre gövdesinin çevresinde bulunan telimsi dendrit, gövdeye bağlı kuyruğumsu akson bulunmaktadır. Dendritler aracılığıyla alınan girdiler hücre gövdesi tarafından girişler doğrusal olmayan bir şekilde işlenir. Biyolojik sinir hücresinde bulunan aksonlar ise işlenen girdileri çıkışa aktarır. Aksonlar ile dentritlerin birbirine bağlanmasını sağlayan birim ise sinap,slardır. Sinapslar elektrokimyasal bağlantıyı sağlarlar (Baş, 2006).

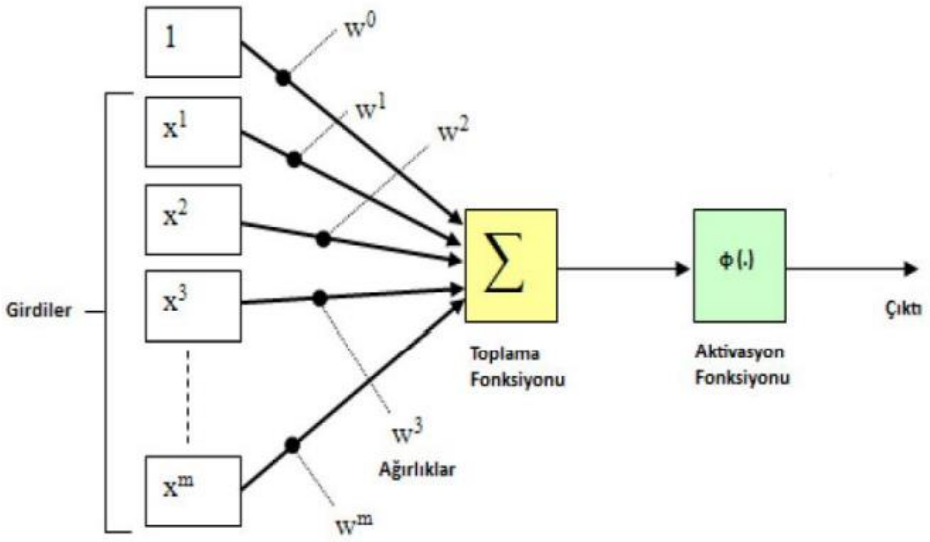
Biyolojik sinir ağlarındaki kavramlar ile YSA'larda bu kavramlara karşılık gelen kavramlar Tablo 3.1'de gösterilmektedir.

Tablo 3.1.Biyolojik sinir sistemi ve YSA'larn benzer elemanları (Baş, 2006)

Biyolojik Sinir Sistemi	**Sinirsel Hesaplama Sistemi**
Nöron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre Gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıktısı
Sinapslar	Ağırlıklar

3.3. YSA'larnın Elemanları

Yapay sinir hücreleri 5 elemandan oluşmaktadır. Bu elemanlar: Girdi(x), ağırlık(w), toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır. Ağ içerisindeki yerleşimleri Şekil 3.1'deki gibidir.



Şekil 3.1.YSA elemanlarının ağ içerisindeki yerleşimi (M. Sarı, 2016)

3.3.1. Girdi

Girdiler $x_1,x_2,x_3,\ldots,x_n$ şeklinde gösterilmektedir. Bu girdiler dış dünyadan gelebileceği gibi bir önceki sinir hücresinden de gelebilir.

3.3.2. Ağırlık

Ağırlıklar $w_1,w_2,w_3,\ldots,w_n$ şeklinde gösterilmektedir. Ağırlıklar sinir hücresine gelen girdilerin etkisini belli eden katsayılardır. Her girdi kendi ağırlığına sahiptir. Ağırlığın büyük olması girdinin önemli olduğu anlamına gelmeyeceği gibi küçük olması da önemsiz olduğunu anlamına gelmez. Ağırlık artı veya eksi olabilir. Ağırlığın işareti girdinin etkisinin yönünü göstermektedir (Öztemel, 2006).

3.3.3. Toplama Fonksiyonu:

Toplama fonksiyonu hücreye gelen net girdiyi hesaplamaktadır. Bu hesaplama için çeşitli fonksiyonlar kullanılabilmektedir. Bu fonksiyonların en yaygın olanlarından biri ağırlıklı toplam fonksiyonudur. Ağırlıklı toplam fonksiyonunda tüm girdiler ağırlıkları ile çarpılıp toplanır. Bu işlemin sonunda net girdi bulunur (Öztemel, 2006).

3.3.4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, toplama fonksiyonundan aldığı girdiyi işleyip yapay sinir hücresinin çıktısını belirler. Aktivasyon fonksiyonu çeşitlidir ancak genellikle doğrusal

olmayan fonksiyonlar aktivasyon fonksiyonudur. Doğrusal fonksiyonlarda girdi ile çıktı doğru orantılıdır. Bu durum YSA'larda başarısızlığa neden olmaktadır (Atasoy, 2012).

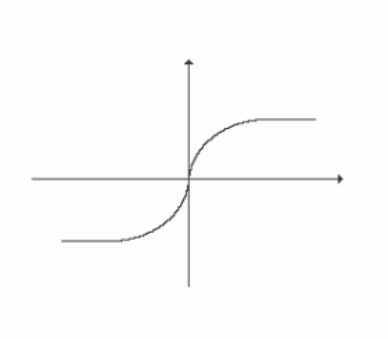
Doğrusal aktivasyon fonksiyonunda girdiler hücrenin çıktısıdır. Denklem (3.3)'de verilen formül ile hesaplanır.

$$f(s) = s \tag{3.3}$$

Hiperbolik tanjant fonksiyonu: Girdi değeri tanjant fonksiyonundan geçirilerek çıktı hesaplanır. Aralığı [-1,1] dir. Çoğunlukla çok katmanlı ağlarda kullanılır. Denklem (3.4) ile hesaplanır (Atasoy, 2012):

$$y = F(s) = \frac{e^{s} + e^{-s}}{e^{s} - e^{-s}} \tag{3.4}$$

Hiperbolik tanjant fonksiyonunun gösterimi Şekil 3.2'deki gibidir.

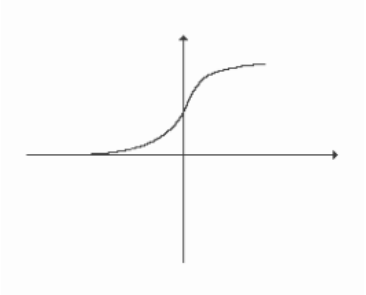


Şekil 3.2. Hiperbolik tanjant fonksiyonunun grafiği (Atasoy, 2012)

Sigmoid aktivasyon fonksiyonu: YSA'larda en yoğun kullanılan aktivasyon fonksiyonlarındandır. Sürekli artan bir fonksiyondur. Doğrusal olsun olmasın dengeyi kurabilmektedir (M. Sarı, 2016). Denklem (3.5) ile hesaplanır:

$$y = F(s) = \frac{1}{1 + e^{-s}} \tag{3.5}$$

Sigmoid aktivasyon fonksiyonunun gösterimi Şekil 3.3'teki gibidir.

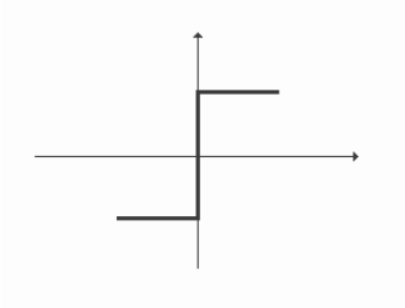


Şekil 3.3. Sigmoid fonksiyonunun grafiği (Atasoy, 2012)

Basamak aktivasyon fonksiyonu: Genellikle tek katmanlı ağlarda kullanılır. Çıktı değeri 0 veya 1'dir. Net girdinin belirlenen eşik değerinin altında olması durumunda çıktı 0, üstünde olması durumunda ise 1 olur. Denklem (3.6) ile hesaplanır.

$$y = F(s) = \begin{cases} 1 & s \geq 0 \\ 0 & s < 0 \end{cases} \tag{3.6}$$

Basamak fonksiyonunun gösterimi **Hata! Başvuru kaynağı bulunamadı.**'te gösterildiği gibidir.



Şekil 3.4. Basamak fonksiyonunun grafiği (Atasoy, 2012)

3.3.5. Çıktılar

Aktivasyon fonksiyonunun belirlediği değere çıktı denir. Bu çıktılar YSA'nın çıktısı olabileceği gibi başka bir sinir hücresinin girdisi de olabilir.

3.4. YSA'larnın Sınıflandırılması

YSA'lar dört farklı kategoride sınıflandırılabilir. Bu kategoriler şunlardır (Biçer, 2018):

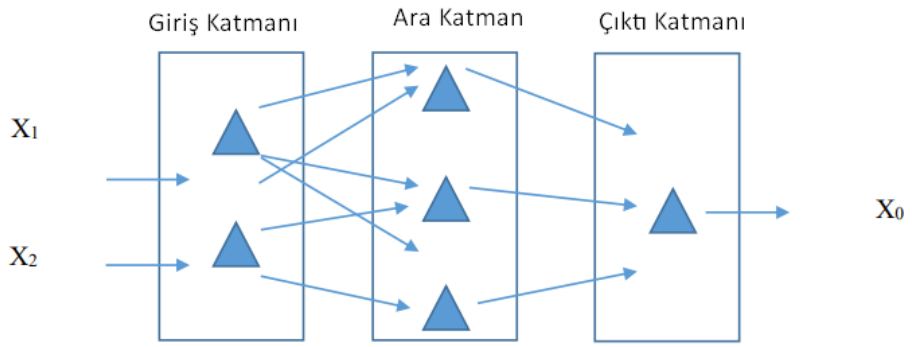
- Besleme türüne göre
- Katman sayısına göre
- Öğrenme yöntemine göre

- Yapısına göre

3.4.1. Besleme türüne göre YSA'lar

YSA'lar besleme türlerine göre ikiye ayrılmaktadır. Bu türler ileri beslemeli YSA'lar ve geri beslemeli YSA'lardır.

İleri beslemeli YSA'larda hücreler girdiden çıktıya doğru bağlıdır. Giriş katmanı ara katman ve çıktı katmanı bulunan ağlarda girdiler her zaman önce giriş katmanına oradan ara katmana oradan da çıkış katmanına doğru ilerler. Hareket her zaman tek yönlüdür. Girdiler ara katmanda işlenirler ve ağırlıkları belirlenir. Ağırlıkları ile işlenen girdiler bir sonraki katmana çıktı olarak geçerler. Ara katmanda bulunan nöronlar işledikleri bu girdileri bir sonraki ara katman üyesine veya doğrudan çıktı katmanına iletebilir. Çıktı katmanına ulaşan veri, belirlenen karar verme fonksiyonu ile işlendikten sonra sistem çıktısı elde edilir. İleri beslemeli YSA'larnın yapısı Şekil 3.5'te verilmektedir (Aydın, 2019).



Şekil 3.5.İleri beslemeli YSA'nın yapısı (Aydın, 2019)

Geri beslemeli YSA'larda ise iletim iki yönlüdür. Nöronlar tarafından işlenen veriler bir sonraki katmana iletilebileceği gibi bir önceki katmana da iletilebilir. Bu özellikleri nedeniyle geri beslemeli YSA'lar dinamik bir yapıya sahiptir (H'meinde Maham, 2022). Geri beslemeli ağlarda iletim hızı ileri beslemeli ağlarla kıyaslandığında daha yavaştır. Anlık veri, önceki dönem verisi ve çıktının ilişkilerinden kaynaklanan döngü, ağda gecikmeye neden olmaktadır. Geri beslemeli ağlarda iletim katmanlar arasında olabileceği gibi aynı katmanda bulunan hücreler arasında da gerçekleşebilir. İletim giriş katmanından çıktı katmanına doğruyken bu iletim ileri iletimdir ve çıkış hesaplama yönüdür. Çıktı katmanından giriş katmanına doğru olan hareket ise geri harekettir. Bu hareket hatayı yayma yönüdür (Aydın, 2019).

3.4.2. Katman sayısına göre YSA'lar

Katman sayısına göre YSA'lar tıpkı besleme türüne göre olanlar gibi ikiye ayrılır. Bunlar tek katmanlı YSA'lar ve çok katmanlı YSA'lardır.

Tek katmanlı YSA'lar genellikle doğrusal problemlerin çözümünde kullanılır. Giriş katmanı ve çıktı katmanından oluşur. Tek katmanlı YSA'larda aktivasyon fonksiyonuna göre çıktı [-1,1] aralığında olabilir. Eşik değeri ϕ, çıktının 0 olmasını engeller (Karaçal, 2022). Katmanların bir veya birden fazla nöronu bulunabilir (Arı ve Berberler, 2017). Tek katmanlı algılayıcı modeli Şekil 3.6'de görüldüğü gibidir.



Şekil 3.6. Tek katmanlı algılayıcı modeli (Arı ve Berberler, 2017)

Çok katmanlı YSA'larda tek katmanlı YSA'nın aksine gizli katman (ara katman) da bulunur. Çok katmanlı YSA'larnın girdiler ve çıktılar verildikten sonra ağın çıktıları öğrenip ağırlık değerlerini belirleyerek tahminler yapması istenir (Çağlayan, 2022).

Çok katmanlı YSA gizli katmanı sayesinde karmaşık veriler arasındaki bağlantıyı çok daha kolay çözüme kavuşturur (Doğan, 2019).Öyle ki XOR problemini ele alan Minsky tek katmanlı algılayıcıların bu problemin çözümünde yetersiz kaldığını tespit etmiştir. 1960 ile 1970 yılları arasında bu problemin çözülememesi bir durgunluğa neden olmuştur. XOR problemine çözüm üretmek isteyen araştırmacılar bu problemi çözebilmek için çok katmanlı ağları geliştirmişlerdir (Aydın, 2019).

3.4.3. Öğrenme yöntemine göre YSA'lar

Öğrenme, YSA'lar için büyük önem arz etmektedir. Girdilerin ağırlığını belirleyen şey ağın öğrenme durumudur. İlk denemede rasgele belirlenen ağırlıklar daha sonraki adımlarla eğitim işlemine göre belirlenir. Öğrenme işlemi danışmanlı veya danışmansız yapılabilir. Danışmanlı eğitimde ağa doğru çıktının bulunması için girdi-çıktı bağlantısı

verilirken danışmansız eğitimde dışarıdan herhangi bir müdahale olmadan ağın bağlantıları ortaya çıkarması beklenir. Danışmanlı öğrenmede girdiler ve çıktılar kullanılmaktadır. İlk adımda ağ ağırlıkları atadıktan sonra çıktığı kıyaslayabilir. Kıyaslama işleminden sonra görülen hatalar sisteme geri gönderilir. Geri gönderilen bu hatalar vasıtasıyla ağırlıklar yenilenir. Bu yenileme işlemi doğru ağırlık bulununcaya dek devam eder (Tabanoğlu, 2019).

Danışmansız öğrenmede çıktıların değerleri ağa tanıtılmaz. Bu öğrenme yöntemiyle veri kümelerinin içinde bulunan istatistiki bilgilerin ortaya çıkarılması istenir. Danışmansız öğrenmede girdiler çıktı görevini de üstlenirler. Hem girdi hem çıktı olan bu verilerin kural ile aralarındaki ilişkilerin araştırılması ve en idealinin bulunması ağın eğitildiğinin göstergesidir (Tabanoğlu, 2019).

3.4.4. Yapısına göre YSA'lar

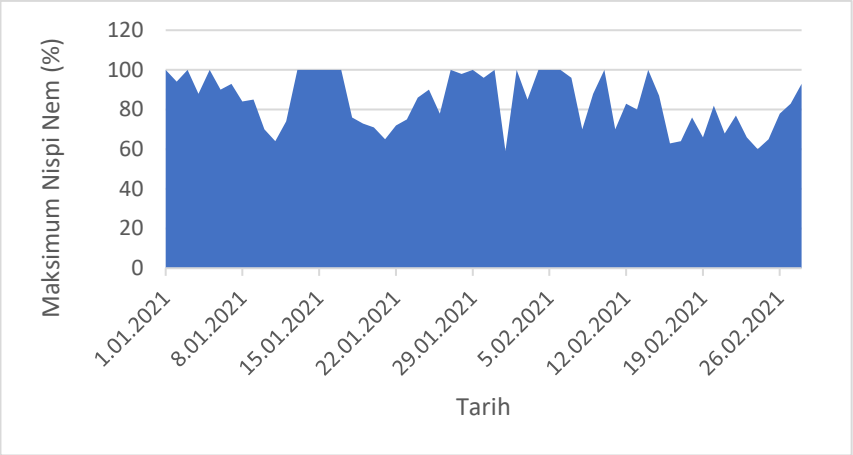
YSA'lar yapısına göre otoasosyatif ve heteroasosyatif olmak üzere ikiye ayrılır. Otoasosyatif ağlar, girdi nöronlarının çıktı nöronları olarak görev yaptığı ağlar iken heteroasosyatif ağlar girdi de çıktı nöronlarının birbirlerinden farklı olduğu ağlardır(Güngör, 2015).

3.5. Zaman Serileri

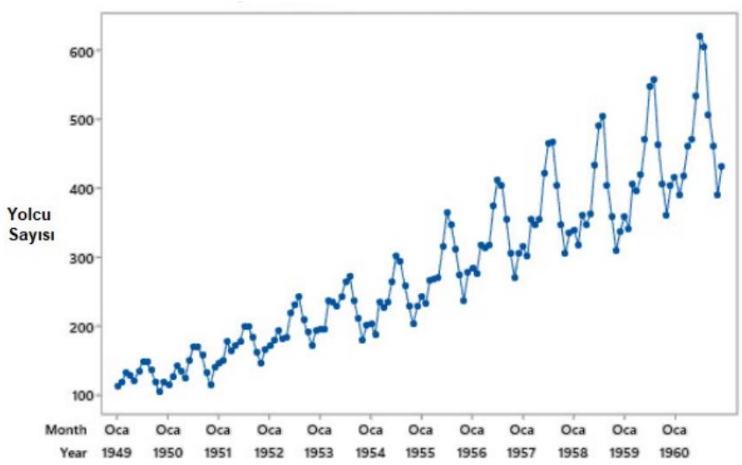
Zaman serisi modelleri gelecek enerji gereksinimlerini tahmin etmek için kullanılan en basit modellerdir (Suganthi ve Samuel, 2012) . Bir değişkenin zamana göre değişimini inceleyen, bu incelemeleri kronolojik olarak görüntüleyebilen serilerdir. Zaman serileri t zaman olmak üzere denklem (3.7) ile ifade edilir (Oğhan, 2010).

$$Y = f(t) \tag{3.7}$$

Örneğin Şekil 3.7'da gösterilen Menemen istasyonundan alınmış maksimum nispi nem grafiği zaman serilerine bir örnektir. Bu örnekteki zaman serisi 2021 ocak ve şubat aylarını kapsayan çok küçük bir zaman serisiyken Şekil 3.8'de gösterilen zaman serisinde ise bir otobüs firmasının 11 yıllık yolcu sayısı gösterilmektedir.



Şekil 3.7.Günlük maksimum nispi nem



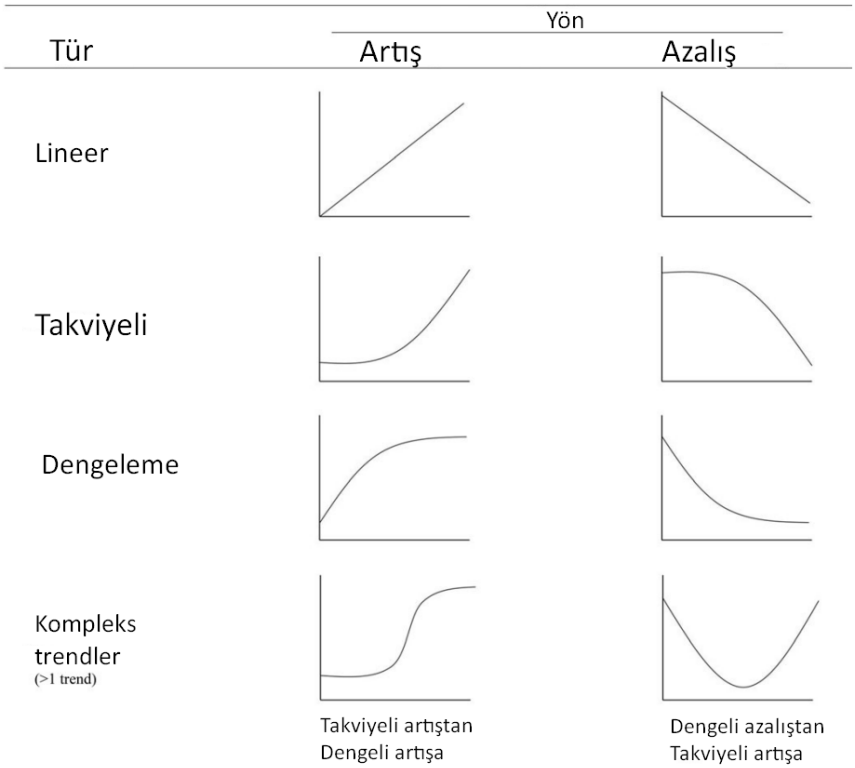
Şekil 3.8. Bir otobüs firmasının yolcu sayısı (Lök, 2022)

Bu örneklerde de görülebileceği üzere zaman serileri 2 aylık gibi nispeten kısa bir süreli veriler ile oluşabileceği gibi 10 yıllık 20 yıllık uzun süreli verilerden de oluşabilir. Zaman serilerinin sınıflandırılması seride bulunan değişkenlerin sayısına veya yapılan ölçümlerin şekline göre yapılır. Zaman serisinde birden fazla değişkenin kaydına yer veriliyorsa bu tip zaman serilerine çok değişkenli zaman serisi adı verilir. Zaman serisinde tek değişken bulunuyorsa bu zaman serisine tek değişkenli zaman serisi adı verilir. Ayrıca zaman serileri gözlemlerin ölçüm şekline göre de sınıflandırılabilir. Sürekli zaman serilerinde gözlemler her daim ölçülürken ayrık zaman serilerinde ölçümler farklı zaman noktalarında ölçülürler. Sıcaklık ölçümleri, kalp ritmi ölçümleri, nehrin debisi gibi seriler sürekli zaman serileri olarak adlandırılmaktadır. Ayrık zaman serilerine örnek olarak ise şirketlerin üretimi, para birimleri arasındaki oran, bir yerleşim yerinin nüfusu

verilebilir. Ayrık zaman serilerinde gözlemler saatlik, günlük, haftalık veya daha farklı bir zaman aralığıyla yapılabilir (Lök, 2022).

Zaman serilerinde bazı durumlarda düzenli veya kaotik değişimler meydana gelebilir. Zaman serilerinde serinin düzenini bozan veriler tespit edilmeli ve bu düzensizliğin neden yaşandığı anlaşılmalıdır. Zaman serilerindeki hareketler şu nedenlere dayalı olabilir: Trend, mevsimsel etki, konjonktür ,düzensiz değişim (Oğhan, 2010).

Trend, zaman serisinin uzun dönemli eğilimlerini ifade eder. Bu eğilim artma veya azalma şeklinde olabileceği gibi sabit de olabilir (Çabuk, 1995). Trendlerin türleri Şekil 3.9'deki gibidir.



Şekil 3.9. Trendlerin türleri (Hoehner, Sabounchi, Brennan, Hovmand ve Kemner, 2015)

Mevsimsel etki, sistematik olarak tekrar eden yıl içi hareketlere verilen isimdir. Mevsimsel etkinin oluşmasına neden olan sebepler 3 gruba ayrılabilir (Altınay, 2010).

- Sıcaklık, yağış, güneşlenme süresi vb. mevsimlere göre değişen doğa olayları.
- Belirli bir takvime dayalı dini ve milli bayramlar.
- İş günceli, okul tatilleri mali takvim gibi belirli bir zamana dayalı olaylar.

Konjonktür trendin etrafında oluşan dalgalanma olarak adlandırılabilir. Örneğin bir fabrikanın üretim fonksiyonu bu fabrikanın üretim trendini ifade etmektedir. Çalışanların fazla mesai yaptığı, makinelerin kapasitelerinin üzerinde çalıştırıldığı durumlarda üretim trend değerinin üzerine çıkabilir. Ancak trendin üzerindeki bu üretim sürdürülebilir değildir. Çıktı değerinde yaşanan bu geçici artış konjonktürel dalgalanma olarak ifade edilir (Özata, 2007).

Düzensiz değişimler zaman serisinde oluşan, çoğu zaman herhangi bir gerekçeyle açıklanamayan değişimlerdir. Bu özellikleri nedeniyle düzensiz değişimler belirli modellere uymaz ve tahmin edilebilir değildir (Çırak, 2019).

3.6. Kullanılacak Modelin Seçimi

Kullanılacak modelin seçimi için literatürde zaman serileri ve yenilenebilir enerji kaynaklarının üretimini tahmin eden çalışmalar incelenmiştir. Karasu ve arkadaşları rüzgar hızının tahmini için NAR ağını tercih etmiştir (Karasu, Altan, Saraç ve Hacioğlu, 2017). H.Nazaripouya ve arkadaşları güneş enerjisinin tek değişkenli zaman serisi ile tahmini için Hybrid Wavelet ARMA-NARX metodu kullanmıştır (Nazaripouya ve diğerleri, 2016). Ali Sarı ve arkadaşları güneş ışınımının tahmini için NARX modelini kullanmıştır (A. Sarı, Aktaş, Yönetken ve Doğan, 2021). Muhittin Şahan ve Yüksel Okur güneş enerjisinin tahmini için ileri beslemeli geri yayılımlı YSA ve Levenberg-Marquardt geri yayılım algoritması eğitim algoritması olarak kullanılmıştır (Şahan ve Okur, 2016).Selahattin Koşunalp güneş enerjisinin tahmini için Exponential Weighted Moving-Average algoritmasının geliştirilmiş modeli G-EWMA'yı önermiştir (Koşunalp, 2018). Halil Demolli ve arkadaşları Niğde ilinin güneş enerjisini tahmin etmek için k en yakın komşu algoritması, destek vektör makinesi algoritması ve Lasso regresyon algoritmasını kullanmıştır (Demolli, Ecemiş, Dokuz ve Gökçek, 2019).

3.6.1. NAR

NARX modeli ile yapılan tahminlemelerin ardından NAR modeli ile tahminleme işlemine geçilmiştir. NAR yani doğrusal olmayan otoregresif ağ, çok aşamalı tahminleme işlemleri için geliştirilmiş zaman gecikmeli sinir ağıdır. NAR sinir ağı, gelecekteki değerleri tahmin edebilmek için geçmiş verileri kullanır. NAR modeline göre t. andaki veri t-1,t-2,…,t-n. zamandaki verilerin etkisiyle oluşur. n sayısının değerinin belirlenmesi

için t. zamandaki verinin önceki kaç değerden etkilendiği bulunmalıdır(Karasu ve diğerleri, 2017). Denklem (3.8) deki gibi gösterilir.

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}) \tag{3.8}$$

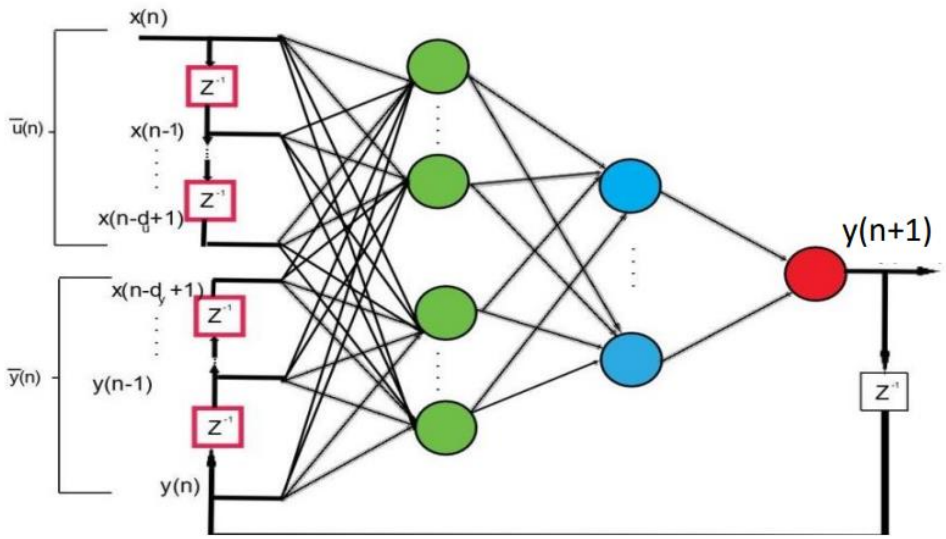
3.6.2. NARX

NARX yani doğrusal olmayan dış girdili otoregresif ağ, girdiler ve çıktı değeri arasındaki ilişkiyi m boyutlu girdi uzayı ile n boyutlu çıktı uzayı arasında doğrusal olmayan bağlantıyı kuran kara kutu modelleme araçlarıdır. NARX modelleri, doğrusal olmayan problemler, sınıflama problemleri, optimizasyon problemleri ve regresyon için uygundur. Zaman serilerinin modellenmesinde sıkça tercih edilen yöntemlerden biridir (Oral, 2021).

NARX içerisinde geribildirim döngüleri barındıran geri beslemeli bir ağdır. Dinamik problemlerin kullanımı için uygundur. NAR ağının geliştirilmiş versiyonudur. NARX ağının "X" harfi dış dünyadan gelen diğer harici girdileri ifade etmektedir. NARX'i baz alan YSA'larnın gizli katmanında sigmoid aktivasyon fonksiyonu kullanılmaktadır. Aktivasyon fonksiyonu olarak ise doğrusal aktivasyon fonksiyonu kullanılmaktadır. NARX modeli zaman serileri için sıklıkla kullanılmaktadır. NARX modeli denklem (3.9)'deki fonksiyon ile ifade edilebilir (B. Yılmaz, 2015).

$$y(t) = f\left(y(t-1), y(x-2), \dots, y\left(x-n_y\right), u(t-1), u(t-2), \dots, u(t-n_u\right. \tag{3.9}$$

Bu denklemde bağımlı çıktı u(t) çıktının daha önceki değerleri ve dışarıdan giren giriş sinyaliyle regresyona tabi tutuluyor(B. Yılmaz, 2015).Yani NARX ağı dış girdi olarak geçmiş zamanlardaki bağımsız değişkenleri ve geçmiş zaman çıktılarını alarak mevcut çıktığı hesaplayan bir çok katmanlı algılayıcıdır. Geleneksel geribeslemeli ağlardan farklı olarak NARX gizli durumlardan değil çıktı nöronundan gelen bilgiyi geri bildirim ile iletir. NARX ağının mimarisi Şekil 3.10'da gösterildiği gibidir (H'meinde Maham, 2022).



Şekil 3.10.NARX Ağının Mimarisi (H'meinde Maham, 2022)

3.6.3. Bayes optimizasyon algoritması

Bayes optimizasyon algoritmasını anlamak için gerekli olan temel istatistiki fikirler yüzyıllardan beri bilinmektedir. Bayes algoritmasının temelleri 18. yüzyıl matematikçisi Thomas Bayes 'in çalışmalarına dayanmaktadır. Thomas Bayes bugün bayes metodu olarak bilinen temel matematiksel ilkeleri geliştiren kişidir. Bayes metodu olayların olasılığını ve ek bilgiler ışığında nasıl revize edilmesi gerektiğini açıklamak için geliştirmiştir (Gaurav ve Patel, 2020).

Bayes optimizasyonu Mockus tarafından geliştirilmiştir. Küresel optimizasyon problemine uyarlandığında ise popülerliği daha da artmıştır. Hemen hemen tüm küresel optimizasyon problemi için kullanılabilmektedir. Daha çok veri kullanılarak daha az hata yapmayı hedeflemektedir.

Bayes optimizasyon algoritması, sınırlı bir alanda x için bir skaler amaç fonksiyonu f (x)'i minimize etmeye çalışır. Fonksiyon deterministik veya stokastik olabilir, yani aynı x noktasında değerlendirildiğinde farklı sonuçlar döndürebilir. x'in bileşenleri sürekli

gerçeklikler, tamsayılar veya kategorik olabilir, yani ayrı bir isim kümesi anlamına gelebilir (http-6).

Bayes optimizasyon algoritması, sınırlı bir alanda x için bir skaler amaç fonksiyonu f (x)'i minimize etmeye çalışır. Fonksiyon deterministik veya stokastik olabilir, yani aynı x noktasında değerlendirildiğinde farklı sonuçlar döndürebilir. x'in bileşenleri sürekli gerçeklikler, tamsayılar veya kategorik olabilir, yani ayrı bir isim kümesi anlamına gelebilir(http-6).

Bayes'in kuralında A ve B örnek uzayda iki olaydır. B olayının bilinmesi durumunda A'nın gerçekleşmesinin olasılığı denklem (3.10) ile ifade edilir (Doruk, 2019).

$$P(A / B) = \frac{p(A \cap B)}{P(B)}, P(B) > 0 \tag{3.10}$$

A olayı biliniyorken B olayının gerçekleşme olasılığı denklem (3.11) ile ifade edilir.

$$P(B / A) = \frac{p(B \cap A)}{P(A)}, P(A) > 0 \tag{3.11}$$

Denklem (3.10) ve denklem (3.11) düzenlendiğinde denklem (3.12) elde edilir.

$$P(A \cap B) = P(B)P(A / B) = P(A)P(B / A) \tag{3.12}$$

İçerisinde B olayının yer aldığı ayrık olayların (a_1,a_2,a_3,…,a_k) örneklem uzayı olduğunu düşünülürse B olayı biliniyorken A olayının gerçekleşme olasılığı denklem (3.13) deki gibidir (Doruk, 2019).

$$P(A_i / B) = \frac{p(A_i)P(B/A_i)}{P(B)}, \text{ i=1, 2,…,k} \tag{3.13}$$

P(B) olasılık hesabı için toplam olasılık formülü denklem (3.14) deki gibidir:

$$P(A_i / B) = \frac{P(A_i)P(B/A_i)}{\sum_{J=i}^{k} P(A_J)P(B/A_J)} \tag{3.14}$$

Bu denklemde $P(A_i)$ önsel olasılık değerleridir ve önceden bilinmelidir (Doruk, 2019). Önceleri Bayes yaklaşımı istatistiki problemler için kullanılırken makine öğrenmesi, yapay zeka gibi kavramların gelişmesiyle kullanım alanları çokça

çeşitlenmiştir. Bayes teoremi bir rastlantı değişkeni için olasılık dağılımı içinde koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi gösterir (Doruk, 2019).

3.6.4. Regresyon analizi

Regresyon analizi, bağımlı değişkenler ve bağımsız değişkenlerin birbirleriyle olan sayısal ilişkilerini incelemek için kullanılır. Bağımlı değişkenler, bağımsız değişkenlerin etkisi ile değerler alan değişkenlerdir. Bağımlı değişkenler y ile gösterilirken bağımsız değişkenler x ile gösterilir. Regresyon analizleri değişkenlerin durumuna göre farklı isimler almaktadır. Bir bağımlı ve bir bağımsız değişken kullanılarak yapılan regresyon analizine basit regresyon analizi adını alır. Bir bağımlı değişken ve birden çok bağımsız değişken kullanılarak yapılan regresyon analizine çoklu regresyon analizi denir. Regresyon analizinde birden çok bağımlı değişken var ise çok değişkenli regresyon analizi adını alır. Regresyon analizleri aynı zamanda değişkenlerin arasındaki ilişkiye göre de isimlendirilir. Örneğin değişkenlerin ilişkisi doğrusal ise regresyon analizi doğrusal regresyon analizi adını alır. Eğer değişkenlerin arasındaki ilişki doğrusal değilse eğrisel regresyon analizi adını almaktadır (S. Koç ve Deniz, 2019).

4. UYGULAMA VE BULGULAR

4.1. Kullanılan Programlar

Elektrik üretimi ve tüketiminin YSA'lar ile tahmini için Matlab R2020b uygulaması kullanılmıştır. Regresyon analizi ile yapılan tahmin için Excel uygulaması kullanılmıştır. Tahminlemeye geçilmeden önce veri setinde bulunan eksiklerin tespiti ve giderilmesi için çalışma yapılmıştır.

4.2. Elektrik Üretiminin Tahmini

Bu çalışma kapsamında yapılan ilk tahminleme regresyon analizlerinden çoklu regresyon analizi kullanılarak yapılmıştır. Regresyon analizi ile elektrik üretimini tahmin edilmeden önce girdiler arasındaki ilişkinin tespit edilebilmesi için öncelikle korelasyon analizi yapılmıştır. 1 saat önceki veriler ile tahmin edilmek istenen üretim arasındaki korelasyonun analiz sonucu Tablo 4.1'de gösterilmiştir.

2 saat önceki veriler ile tahmin edilmek istenen üretim arasındaki korelasyonun analiz sonucu

Tablo *4.2*'de gösterilmiştir.

Tablo 4.1. 1 saat önceki girdiler ile üretimin korelasyon analizi

	Üretim (t-1)	**Radyasyon (t-1)**	**Bulutluluk (t-1)**	**Sıcaklık (t-1)**	**Rüzgar Hızı (t-1)**	**Üretim (t)**
Üretim (t-1)	1					
Radyasyon (t-1)	0,8	1				
Bulutluluk (t-1)	-0,4	-0,4	1			
Sıcaklık (t-1)	0,5	0,7	-0,4	1		
Rüzgar Hızı (t-1)	0,1	0,1	0,2	0	1	
Üretim (t)	0,9	0,7	-0,4	0,4	-0,1	1

Tablo 4.2. 2 saat önceki girdiler ile üretimin korelasyon analizi

	Üretim (t-2)	**Radyasyon (t-2)**	**Bulutluluk (t-2)**	**Sıcaklık (t-2)**	**Rüzgar Hızı (t-2)**	**Üretim (t)**
Üretim (t-2)	1					
Radyasyon (t-2)	0,9	1				
Bulutluluk (t-2)	-0,3	-0,3	1			
Sıcaklık (t-2)	0,6	0,7	-0,3	1		
Rüzgar Hızı (t-2)	0,1	0,1	0,3	0	1	
Üretim (t)	0,7	0,5	-0,4	0,3	-0,2	1

Yapılan regresyon analizinde t-2 ile gösterilen girdiler tahmin edilmek istenen saatten 2 saat önceki verileri, t-1 ise 1 saat önceki verileri ifade etmektedir. d-1 ile gösterilen yağış verisi ise 1 gün önceki yağış durumunu ifade etmektedir. Tablo incelendiğinde görülmektedir ki, tahmin edilmek istenen saatteki elektrik üretimi ile bir saat önceki elektrik üretiminin arasında 0,88 gibi çok yüksek bir korelasyon bulunmaktadır. Tahmin edilmek istenen saatin üretimi ile 1 saat önceki güneş radyasyonu ve 2 saat önceki elektrik üretimi arasında yüksek korelasyon bulunmaktadır. 1 saat önceki radyasyon ile tahmin edilmek istenen elektrik üretimi arasındaki korelasyon 0,68, 2 saat önceki elektrik üretimi ile tahmin edilmek istenen üretim arasındaki korelasyon ise 0,65'tir.

Tahmin edilmek istenen üretimin 2 saat önceki sıcaklık, 2 saat önceki rüzgar hızı, 1 gün önceki yağış ve 1 saat önceki rüzgar hızı ile arasındaki korelasyon çok zayıftır. Tahmin edilmek istenen üretim ile 1 saat önceki ve 2 saat önceki bulutluluk verisi arasında ters yönlü orta şiddette bir korelasyon vardır. Tüm girdiler kullanılarak yapılan regresyon analizinin sonucunda tahmini yapılan 28 aylık periyotta ortalama kare hataları (MSE) 831,3238 olmuştur. MSE'nin aylık değişimi Tablo 4.3'de görülmektedir. Regresyon analizi kullanılarak yapılan tahminler incelendiğinde MSE'nin temmuz,

ağustos aylarında daha düşükken mart, nisan, mayıs gibi aylarda daha yüksek olduğu görülmüştür.

Tablo 4.3.Elektrik üretiminin tahmini için regresyon analizi kullanılarak yapılan tahminlerin MSE değerleri

Tarih	MSE	Tarih	MSE	Tarih	MSE
Tem.19	655,7887	May.20	1495,508	Mar.21	1484,285
Ağu.19	426,5743	Haz.20	1420,017	Nis.21	1706,552
Eyl.19	673,4729	Tem.20	226,125	May.21	917,4221
Eki.19	799,65	Ağu.20	546,0117	Haz.21	596,022
Kas.19	519,53	Eyl.20	433,4729	Tem.21	446,1881
Ara.19	762,7148	Eki.20	682,325	Ağu.21	244,6499
Oca.20	679,1522	Kas.20	653,9768	Eyl.21	729,3594
Şub.20	1056,786	Ara.20	900,0029	Eki.21	1071,998
Mar.20	1207,894	Oca.21	802,007		
Nis.20	1078,171	Şub.21	1093,194		

YSA'lar ile tahminleme işleminde MATLAB uygulaması kullanılmıştır. Tahminleme işlemine başlanırken, öncelikle kullanılacak modelin seçimi yapılmıştır. Bu çalışma için yapılan literatür taraması ve alternatifler göz önüne alınmış ve NARX ve NAR denenmesine karar verilmiştir. NAR, bu çalışmanın da konusu olan dinamik zaman serilerinde sıklıkla kullanılan bir modeldir ve bu çalışmada da başarılı tahminlerde bulunulmasına katkı sağlamıştır. Model seçildikten sonra uygun öğrenme algoritmasının seçimi için çalışmalar yapılmıştır.

NARX modeli kullanılarak bayes optimizasyon algoritması ve Levenberg-Marquardt algoritmalarının hangisinin daha iyi performans verdiğinin tespit edilebilmesi için elde bulunan 28 aylık veri ocak şubat mart- nisan mayıs haziran- temmuz ağustos eylül- ekim kasım aralık olarak 4 çeyreğe ayrılmış ve tahminler bu şekilde yapılmıştır. Bayes optimizasyon algoritması ve Levenberg-Marquardt algoritmalarının MSE ve R değerleri Tablo 4.4'de gösterilmiştir.

Tablo 4.4.Elektrik üretiminin tahmini için NARX modeli ile bayes optimizasyon ve Levenberg-Marquardt algoritmalarının yılın 4 çeyreği için MSE ve R değerleri

YSA Bilgileri	1. Çeyrek		2. Çeyrek		3. Çeyrek		4. Çeyrek	
	MSE	R	MSE	R	MSE	R	MSE	R
Levenberg–Marquardt	872,99	0,91	1009,80	0,92	294,51	0,91	597,27	0,92
Bayes	483,30	0,95	757,50	0,94	272,13	0,94	470,30	0,94

Yapılan bu denemeler incelendiğinde görülmektedir ki NARX modeli kullanılarak yapılan tahminlerde 3. çeyrek yüksek doğruluk oranları ile tahmin edilmişken 2. çeyrekte doğruluk oranı diğer çeyreklerden daha düşüktür. NARX modeli ile bayes optimizasyon algoritması kullanılarak oluşturulmuş modelin saatlik MSE ve R değerleri Tablo 4.5'de verilmiştir.

Tablo 4.5. Elektrik üretiminin tahmini için NARX modeli ile bayes optimizasyonu kullanılarak yapılan tahminlerin MSE ve R değerleri

Veri Seti	Saat	1. Çeyrek		2. Çeyrek		3. Çeyrek		4. Çeyrek	
		MSE	R	MSE	R	MSE	R	MSE	R
Training	08:00	27,45	0,99	3,67	1	6,38	0,99	6,09	0,99
Testing	08:00	147,28	0,96	607,39	0,82	125,7	0,88	83,45	0,88
Training	09:00	246,86	0,96	311,25	0,95	2,35	1	43,16	0,99
Testing	09:00	634,78	0,9	112,27	0,99	105,01	0,87	293,13	0,91
Training	10:00	104,67	0,99	323,35	0,97	91,84	0,96	68,13	0,99
Testing	10:00	693,45	0,94	618,89	0,96	969,41	0,87	462,34	0,95
Training	11:00	748,51	0,95	1022,43	0,93	265,94	0,9	119	0,99
Testing	11:00	579,89	0,97	2079,07	0,89	151,67	0,92	865,69	0,91
Training	12:00	181,54	0,99	9,95	1	61,61	0,98	23,89	1
Testing	12:00	1807,68	0,86	1037,52	0,97	187,33	0,9	3315,08	0,77
Training	13:00	977,31	0,94	17,89	1	27,04	0,99	35,61	1
Testing	13:00	651,1	0,96	5648,77	0,74	1312,9	0,76	2850,65	0,82
Training	14:00	980,05	0,93	6	1	10,85	1	65,19	0,99
Testing	14:00	498,09	0,97	859,5	0,96	1588,81	0,85	790,07	0,91
Training	15:00	9,97	1	758,16	0,93	36,63	0,99	417,96	0,93
Testing	15:00	1361,28	0,91	820,72	0,96	852,62	0,95	399,75	0,94
Training	16:00	9,15	1	20,67	1	8,61	1	8,15	1
Testing	16:00	659,78	0,89	1928,15	0,85	17,19	0,93	458,95	0,88
Training	17:00	0,55	1	4,91	1	2,54	1	0,63	1
Testing	17:00	304,43	0,92	339,43	0,95	95,83	0,95	38,28	0,94
Training	18:00	0	1	11,54	0,99	3,84	1	0	1
Testing	18:00	8,75	0,97	123,59	0,86	62,69	0,96	1,37	0,93

Bayes optimizasyon algoritmasının saatlik sonuçları incelendiğinde, en düşük MSE'nin elektrik üretiminin nispeten düşük olduğu 18:00, 17:00 08:00 ve 09:00 gibi saatlerde elde edilmiştir. En yüksek MSE değerleri ise elektrik üretiminin daha yüksek olduğu 12:00, 13:00, 14:00 gibi saatlerde elde edilmiştir. R değeri saatlerin çoğunda 0,9'dan daha büyüktür ancak MSE'nin yüksek olduğu saatlerde 0,74'lere kadar

düşmektedir. NARX modeli ile Levenberg-Marquardt algoritması kullanılarak oluşturulmuş modelin saatlik MSE ve R değerleri Tablo 4.6'da verilmiştir.

Tablo 4.6. Elektrik üretiminin tahmini için NARX modeli ile Levenberg-Marquardt optimizasyonu kullanılarak yapılan tahminlerin MSE ve R değerleri

Veri Seti	Saat	1. Çeyrek		2. Çeyrek		3. Çeyrek		4. Çeyrek	
		MSE	R	MSE	R	MSE	R	MSE	R
Training	08:00	70,58	0,97	253,33	0,92	21,82	0,97	25,04	0,96
Validation	08:00	125,99	0,97	395,59	0,87	27,65	0,96	57,78	0,88
Testing	08:00	125,56	0,86	470,56	0,78	49,05	0,96	45,76	0,93
Training	09:00	285,07	0,96	283,54	0,96	61,67	0,96	164,95	0,95
Validation	09:00	1610,69	0,83	714,84	0,92	204,72	0,76	323,37	0,94
Testing	09:00	667,03	0,9	517,58	0,93	111,76	0,91	296,12	0,89
Training	10:00	195,39	0,98	696,09	0,95	490,93	0,96	260,59	0,98
Validation	10:00	873,06	0,92	756,25	0,95	1281,37	0,89	1155,08	0,87
Testing	10:00	2708,54	0,77	1531,32	0,86	878,82	0,95	1913,72	0,84
Training	11:00	774,77	0,95	812,69	0,95	406,17	0,83	202,95	0,98
Validation	11:00	875,1	0,94	1063,74	0,92	1705,38	0,66	1505,64	0,79
Testing	11:00	2504,84	0,84	1487,1	0,93	369,89	0,86	1006,57	0,92
Training	12:00	419,17	0,98	923,58	0,95	137,98	0,96	602,39	0,95
Validation	12:00	1569,67	0,72	2125,91	0,89	156,14	0,96	1652,45	0,82
Testing	12:00	3367,36	0,84	2927,85	0,87	663,03	0,75	1265,86	0,9
Training	13:00	665,62	0,96	1170,21	0,94	187,96	0,95	435,65	0,96
Validation	13:00	1165,09	0,91	1842,32	0,9	771,9	0,73	1316,49	0,88
Testing	13:00	2383,29	0,86	1518,5	0,91	199,45	0,9	1357,61	0,89
Training	14:00	945,51	0,92	1184,77	0,94	99,01	0,97	1041,25	0,93
Validation	14:00	1437,27	0,92	1939,43	0,91	77,93	0,98	1253,57	0,91
Testing	14:00	1108,7	0,95	2253,53	0,91	770,57	0,66	1330,15	0,92
Training	15:00	440,5	0,96	1132,44	0,9	215,35	0,95	443,97	0,94
Validation	15:00	1178,69	0,9	807,02	0,98	57,86	0,97	657,26	0,92
Testing	15:00	1119,57	0,85	2159,3	0,88	159,2	0,81	610,26	0,91
Training	16:00	197,5	0,97	978,78	0,91	13,53	0,99	184,7	0,95
Validation	16:00	559,35	0,94	700,5	0,92	83,78	0,94	283,88	0,92
Testing	16:00	800,71	0,89	1348,92	0,91	130,32	0,95	265,97	0,9
Training	17:00	137,44	0,95	51,98	0,99	41,44	0,98	17,28	0,98
Validation	17:00	185,99	0,91	387,16	0,94	157,67	0,94	25,42	0,97
Testing	17:00	217,99	0,91	533,41	0,9	119,63	0,95	7,18	0,99
Training	18:00	0,62	1	39,89	0,97	11,45	0,99	0,4	0,96
Validation	18:00	32,95	0,91	197,91	0,9	31,06	0,98	0,17	0,99
Testing	18:00	59,16	0,89	117,48	0,94	24,21	0,98	0,59	0,94

Saatlik tahminler incelendiğinde, bayes optimizasyon algoritması 1. çeyrekte en az MSE 4,375 ile üretimin az olduğu 18.00 saatinde bulunmaktadır. 2. çeyreğe gelindiğinde en az MSE yine saat 18.00'da bulunmaktadır ancak bu hata 67,565'tir. 3. çeyrekte en az MSE saat 16.00'da bulunmuştur ve değeri 12,9'dur. 4. Çeyrekte tıpkı 1. ve 2. çeyrekte olduğu gibi en düşük MSE saat 18.00'da elde edilmiştir ve değeri 0,685'tir. Tüm tahminler incelendiğinde görülmektedir ki en az MSE'ye sahip saatler sırasıyla 18:00, 17:00, 8:00 ve 9:00'dır. En yüksek hataya sahip saatler ise sırasıyla 13:00, 12:00, 11:00 ve 14:00'dır. Bunun başlıca nedenlerinden biri öğle saatlerinde elektrik üretiminin fazla olmasından dolayı tahminlemede yapılan hata yüzdesel olarak küçük olsa bile MSE üretimin az olduğu saatlere göre daha fazla olmasına neden olmaktadır.

Bayes eğitim algoritması kullanılarak oluşturulan NARX ağının Levenberg-Marquardt eğitim algoritması kullanılarak oluşturulan NARX ağından daha doğru tahminlerde bulunduğu görülmüştür. Çalışmanın devamında farklı test ve eğitim setleri ile yapılan denemelerin tahmin üzerindeki etkisinin görülebilmesi için bir deneme yapılmıştır. Bayes eğitim algoritması kullanılarak 5 farklı eğitim ve test veri seti ile denemeler yapılmıştır. Bu denemelerin birbiri ile ve Levenberg-Marquardt eğitim algoritması ile kıyaslanması Tablo 4.7'de görülmektedir.

Tablo 4.7. Elektrik üretiminin tahmini için NARX modeli kullanılarak oluşturulmuş Bayes optimizasyon algoritması ile yapılan 5 deneme ve Levenberg-Marquardt algoritması ile yapılmış denemenin MSE değerleri

	Deneme 1	**Deneme 2**	**Deneme 3**	**Deneme 4**	**Deneme 5**	**Levenberg-Marquardt**
1. Çeyrek	409,86	368,77	368,52	332,80	369,42	575,36
2. Çeyrek	347,13	388,61	285,40	360,51	237,43	818,35
3. Çeyrek	134,59	107,20	98,01	90,36	98,03	563,73
4. Çeyrek	200,28	205,60	182,27	169,57	205,27	1658,05

Yapılan bu denemelerin sonucunda farklı veri setlerinde, farklı denemelerde sonuçların değiştiği görülmüştür. Sonuçların değişmesine rağmen yapılan tüm denemelerde bayes optimizasyon algoritması ile oluşturulan modellen Levenberg-Marquardt algoritması ile oluşturulan modelden daha doğru sonuç vermiştir. Aynı nöron sayısı ile yapılan bu denemelerin tarihsel olarak birbiri arasında ve Levenberg-Marquardt algoritması ile kıyaslanması Tablo 4.8'de görülmektedir.

Tablo 4.8. Elektrik üretiminin tahmini için NARX modeli ve bayes optimizasyon kullanılarak yapılan tahminlerin MSE değerleri

Tarih	Bayes Deneme 1 MSE	Bayes Deneme 2 MSE	Bayes Deneme 3 MSE	Bayes Deneme 4 MSE	Bayes Deneme 5 MSE	Levenberg-Marquardt MSE
Tem.19	342,06	264,12	60,52	50,09	31,91	169,49
Ağu.19	137,02	114,00	94,27	165,25	85,72	198,53
Eyl.19	178,73	138,65	241,38	169,64	350,94	305,62
Eki.19	72,25	97,31	81,02	43,36	97,51	902,54
Kas.19	139,44	167,89	192,13	123,30	143,47	2124,88
Ara.19	160,85	178,06	186,42	243,69	266,16	1250,95
Oca.20	242,62	228,72	288,40	203,08	233,10	521,46
Şub.20	354,02	281,65	331,73	314,49	483,99	596,27
Mar.20	456,90	409,52	478,56	254,22	331,11	660,43
Nis.20	456,80	565,06	554,25	353,64	175,00	941,13
May.20	348,76	377,64	331,17	547,20	489,28	798,31
Haz.20	402,76	245,02	250,93	371,96	224,01	738,82
Tem.20	19,55	19,10	14,69	19,53	45,87	1261,07
Ağu.20	146,63	200,66	152,01	175,76	149,73	595,91
Eyl.20	128,42	74,66	96,35	55,40	121,24	475,26
Eki.20	191,26	84,46	113,03	131,67	142,14	2200,48
Kas.20	323,26	216,53	224,84	166,62	198,01	1110,54
Ara.20	168,24	284,00	203,22	224,21	242,12	2194,79
Oca.21	355,51	349,36	329,45	371,60	306,00	541,05
Şub.21	637,13	474,52	416,48	460,44	427,71	524,74
Mar.21	432,87	474,76	372,29	401,63	446,40	607,41
Nis.21	461,62	688,28	337,92	513,09	308,02	1301,16
May.21	282,93	329,79	164,58	218,14	112,89	690,12
Haz.21	133,43	123,12	76,06	155,97	107,83	442,86
Tem.21	35,39	24,83	87,52	31,24	21,69	796,99
Ağu.21	62,11	48,14	31,78	38,06	37,75	729,65
Eyl.21	165,02	80,77	113,28	112,97	53,07	520,19
Eki.21	268,92	342,87	214,83	177,78	280,56	1345,38

Yapılan denemeler sonucunda 1. denemede en iyi MSE değeri 19,55 ile 2020 yılının temmuz ayında elde edilmiştir. Aynı ay için 2.denemede MSE 19,10 , 3. denemede MSE 14,69 , 4. denemede MSE 19,53 5. denemede MSE 45,87 elde edilmiştir. Levenberg – Marquardt algoritması ile yapılan denemede ise MSE 1261,07 olmuştur.

1.denemede en yüksek MSE 2021 yılının şubat ayında elde edilmiştir. 2021 şubat ayı için 1.denemede MSE 637,13 olarak hesaplanmıştır. Aynı ay için 2.denemede MSE

474,52 , 3.denemede MSE 416,48 , 4.denemede MSE 460,44 5.denemede MSE 427,71 olarak hesaplanmıştır. Levenberg – Marquardt algoritması ile yapılan denemede ise 524,74 MSE'ye ulaşılmıştır.

2.denemede tıpkı 1.denemede olduğu gibi en iyi sonuç 2020 yılının temmuz ayında elde edilmiştir. En yüksek MSE ise 2021 yılının nisan ayında elde edilmiştir. 2021 yılı nisan ayında ise MSE 688,28 olarak hesaplanmıştır. Aynı ay 1.denemede MSE 461,62 , 3.denemede MSE 337,92 , 4.denemede MSE 513,09 5.denemede ise MSE 308,02 olarak hesaplanmıştır.

3.denemede 1. ve 2. denemede olduğu gibi en iyi sonuç 2020 temmuz ayında elde edilmiştir. En kötü sonuç ise 2020'nin nisan ayında elde edilmiştir. 2020'nin nisan ayında 3.denemede MSE 554,25 olarak hesaplanmıştır. Aynı ay için 1. denemede MSE 456,80 2.denemede MSE 565,06 4.denemede MSE 353,64 5.denemede MSE 175,00 olarak hesaplanmıştır. Levenberg – Marquardt algoritması ile yapılan tahminde ise MSE 941,13 olarak hesaplanmıştır.

4.denemede daha önceki denemeler gibi en iyi sonuç en iyi sonuç 2020 yılının temmuz ayında elde edilmiştir. En kötü sonuç ise 2020 yılının mayıs ayında elde edilmiştir. 2020 yılının mayıs ayında 4. denemede MSE 547,2 olarak bulunmuştur. Aynı ay 1. denemede MSE 348,76, 2.denemede MSE 377,64 3.denemede MSE 331,17 5.denemede ise MSE 489,28 olarak hesaplanmıştır. Levenberg Marquardt algoritması ile ise MSE 798,31 olarak hesaplanmıştır.

5.denemede diğer denemelerin aksine en doğru sonuç 2021 yılının temmuz ayında elde edilmiştir. 2021 yılının temmuz ayında MSE 21,69 olarak hesaplanmıştır. Aynı ay için 1.denemede MSE 35,39 2.denemede MSE 24,83 3.denemede MSE 87,52 4.denemede MSE 31,24 olarak hesaplanmıştır. Levenberg- Marquardt modelinde ise MSE 796,99 olarak hesaplanmıştır.

NAR modeli ve bayes optimizasyon algoritması ile farklı nöron sayıları kullanılarak bayes optimizasyon algoritması ile yapılan tahminleme işleminin sonuçları Tablo 4.9'da verilmiştir. Yapılan bu tahminlemede 5 nörondan 15 nörona kadar yapılan tahminlerin sonuçları görülmektedir.

Tablo 4.9. Elektrik üretiminin tahmini için NAR modeli ile bayes optimizasyon eğitim algoritması kullanarak farklı nöron sayıları ile yapılmış tahminlerin MSE değerleri

	5 Nöron MSE	**6 Nöron MSE**	**7 Nöron MSE**	**8 Nöron MSE**	**9 Nöron MSE**	**10 Nöron MSE**	**11 Nöron MSE**	**12 Nöron MSE**	**13 Nöron MSE**	**14 Nöron MSE**	**15 Nöron MSE**
Tem.19	709,10	687,99	669,31	691,27	578,81	655,23	582,58	600,20	571,79	565,58	588,97
Ağu.19	461,64	455,86	471,12	451,69	409,17	464,16	422,21	402,00	419,44	396,50	449,58
Eyl.19	803,53	803,27	844,60	800,94	807,68	852,03	790,94	795,02	804,23	812,77	809,32
Eki.19	796,98	806,16	712,10	744,04	756,27	732,49	765,35	711,34	734,03	746,88	761,39
Kas.19	772,86	764,08	788,62	776,42	794,23	766,31	789,96	784,59	798,76	785,13	776,93
Ara.19	979,07	958,56	969,27	990,58	944,47	990,08	921,79	916,58	943,96	905,91	952,74
Oca.20	604,90	621,14	565,26	566,72	616,62	579,82	593,03	600,61	605,30	580,77	578,09
Şub.20	1304,64	1282,46	1275,60	1256,87	1301,61	1269,80	1279,96	1262,58	1254,32	1264,51	1268,89
Mar.20	1855,79	1861,64	1741,80	1770,26	1739,78	1731,32	1739,14	1696,12	1694,74	1669,49	1648,09
Nis.20	1085,21	1079,97	1030,86	1070,47	1085,41	1049,19	1057,16	1045,26	1016,27	1054,78	1015,23
May20	1389,84	1441,50	1416,44	1448,95	1410,49	1410,56	1390,10	1433,97	1388,82	1374,71	1359,40
Haz.20	1468,90	1513,24	1467,89	1481,46	1425,91	1458,73	1437,75	1465,49	1412,56	1409,56	1428,23
Tem20	420,83	409,90	406,38	398,98	288,85	390,27	266,10	315,67	272,06	262,11	317,53
Ağu20	623,70	559,62	591,75	591,28	537,76	601,67	567,93	502,90	549,37	510,16	563,20
Eyl.20	480,00	485,23	526,15	511,02	463,39	536,02	490,51	480,50	511,57	491,55	495,47
Eki.20	563,03	563,63	523,29	513,69	506,96	540,59	500,82	496,00	509,95	465,23	514,68
Kas.20	731,67	709,63	722,35	715,78	680,32	742,15	697,13	669,28	683,20	648,82	688,93
Ara.20	1160,58	1148,33	1156,53	1127,42	1113,03	1132,27	1085,98	1126,55	1128,18	1100,69	1119,15
Oca.21	1041,81	1031,23	1013,03	1003,59	1035,86	1022,84	992,20	995,13	1004,56	982,92	1015,37
Şub.21	1258,12	1243,35	1230,41	1240,42	1244,10	1226,15	1212,54	1238,64	1208,33	1222,21	1242,37
Mar.21	1552,79	1570,07	1576,22	1553,23	1516,52	1559,68	1507,14	1501,54	1512,24	1498,85	1604,85
Nis.21	1662,42	1680,51	1700,27	1697,47	1682,49	1682,40	1676,83	1676,98	1694,24	1702,08	1676,78
May21	760,76	778,59	760,66	757,64	766,34	762,90	780,19	776,09	773,31	785,98	755,13
Haz.21	741,74	753,49	737,98	738,17	722,90	717,59	765,15	748,24	733,54	735,42	702,46
Tem21	583,12	569,05	556,16	579,73	513,17	542,49	512,21	528,71	510,58	525,81	500,17
Ağu21	322,97	320,00	307,99	312,85	272,95	317,97	282,87	258,10	259,94	251,48	344,26
Eyl.21	779,49	787,66	836,72	796,72	775,46	832,67	813,92	807,44	832,75	835,46	827,70
Eki.21	1159,05	1155,92	1121,31	1090,29	1101,28	1125,98	1056,46	1068,86	1074,86	1054,31	1091,33

Bu tabloya göre bayes optimizasyon algoritması en doğru tahminlemeyi 12 nöron ile yapmıştır. 12 Nöron ile yapılan tahminlemede en doğru tahmin 2021 yılının ağustos ayı için yapılmıştır. 2021 yılının ağustos ayı için bulunan MSE 258,10'dur. En kötü tahminlemenin yapıldığı ay ise 2021 yılının nisan ayı için yapılmıştır. 2021 yılının nisan ayı için bulunan MSE 1676,98'dir.

28 aylık tahmin süreci değerlendirildiğine ise yapılan tahminlerin MSE değerleri Tablo 4.10'da gösterildiği.

Tablo 4.10. Denemelerin MSE değerleri

Deneme Sayısı	MSE
1.Deneme	257,9746
2.Deneme	250,4612
3.Deneme	219,1478
4.Deneme	223,1587
5.Deneme	214,7464

NAR modeli ile Levenberg – Marquardt eğitim algoritması kullanılarak yapılan tahminlemede aynı nöron sayısı ile yapılan farklı denemelerin etkisini görebilmek adına 10 nöron ile 3 tahminleme yapılmıştır. Bu tahminlemenin birbiriyle ve diğer nöron sayıları ile kıyaslanması Tablo 4.11'de gösterilmiştir.

Tablo 4.11. Elektrik üretiminin tahmini için NAR modeli ve Levenberg- Marquardt algoritması ile yapılan tahminlerin MSE değerleri

	7 Nöron MSE	8 Nöron MSE	9 Nöron MSE	10 Nöron MSE	10 Nöron MSE	10 Nöron MSE	11Nöron MSE	12 Nöron MSE
Tem.19	671,22	680,39	693,97	674,51	667,81	697,02	654,75	592,17
Ağu.19	438,91	454,51	456,77	461,79	438,41	479,56	468,59	425,51
Eyl.19	766,51	780,23	809,49	790,76	846,43	787,27	803,68	776,21
Eki.19	731,66	743,92	810,43	750,72	738,84	752,44	714,12	693,67
Kas.19	774,97	758,82	807,18	728,33	807,84	807,56	735,09	784,72
Ara.19	903,61	981,88	915,05	923,24	899,73	965,56	954,61	934,12
Oca.20	612,29	606,44	576,89	581,39	601,49	586,78	567,95	603,98
Şub.20	1265,88	1220,81	1276,86	1249,57	1216,34	1307,31	1286,66	1241,13
Mar.20	1796,59	1804,02	1750,56	1778,23	1756,94	1833,19	1781,39	1742,98
Nis.20	1114,74	1074,69	1039,50	1031,02	1116,64	1103,26	1073,23	1057,05
May20	1500,95	1461,10	1555,09	1431,15	1481,82	1456,76	1404,87	1403,11
Haz.20	1562,00	1477,58	1570,74	1503,47	1529,14	1518,22	1456,63	1421,97
Tem20	368,23	382,80	380,75	390,62	418,53	441,13	361,02	297,46
Ağu20	580,50	589,09	605,89	597,07	571,97	639,90	581,99	591,29
Eyl.20	458,90	499,04	509,07	491,83	486,15	469,53	492,45	499,12
Eki.20	508,18	539,18	524,39	534,78	515,45	585,13	514,35	486,17
Kas.20	642,15	719,32	662,07	688,42	654,30	719,04	724,57	674,91
Ara.20	1125,44	1128,89	1128,63	1080,52	1103,01	1125,10	1128,81	1108,71
Oca.21	993,47	1025,72	998,63	990,59	986,95	1045,47	1002,52	1015,07
Şub.21	1190,34	1250,23	1187,19	1208,93	1208,27	1225,89	1209,54	1206,60
Mar.21	1509,24	1546,00	1509,29	1489,94	1501,56	1517,94	1551,74	1509,13
Nis.21	1701,25	1709,46	1690,50	1683,72	1682,03	1691,25	1667,54	1659,69
May21	804,56	773,37	784,56	769,56	806,47	778,02	751,02	780,56
Haz.21	778,22	760,92	802,53	769,84	797,42	783,23	733,97	772,20
Tem21	585,24	567,34	592,84	573,91	601,60	590,42	568,03	515,53
Ağu21	290,32	310,10	293,23	321,59	298,81	344,59	324,61	276,76
Eyl.21	775,78	783,11	826,87	794,94	832,68	769,89	798,98	809,93
Eki.21	1059,75	1136,71	1063,21	1116,47	1093,72	1157,74	1085,18	1078,51

Tabloya göre NAR modeli ve Levenberg-Marquardt eğitim algoritması ile yapılan tahminlerin en doğrusu 12 nöron ile elde edilmiştir. Aynı nöron sayısı ile yapılan denemelerin ise birbiriyle benzer sonuçlar verdiği ama arada farklar olduğu da görülmüştür. En başarılı tahmin 2021 yılının ağustos ayı için yapılmıştır. 2021 yılının ağustos ayı için bulunan MSE 276,76'dır. En başarısız tahminin yapıldığı ay ise 2020 yılının mart ayıdır. 2020 yılının mart ayı için bulunan MSE 1742,98'dir.

Levenberg-Marquardt eğitim algoritması ile bulunan MSE'nin en düşük olduğu 12 nöronlu model ile bayes optimizasyon eğitim algoritması kullanılarak bulunan MSE'nin en düşük olduğu 12 nöronlu model kıyaslandığında bayes optimizasyon algoritmasının yapılan 28 aylık tahminin 16'sında daha iyi sonuç verdiği görülmüştür. Levenberg – Marquardt algoritması yalnızca 12 ayda daha iyi sonuç vermesinin yanı sıra, yıllık ortalama da bayes optimizasyon algoritmasından daha yüksek hataya sahiptir. Hem NAR hem de NARX modellerinde bayes optimizasyon algoritmasının daha başarılı olduğu görülmüştür. Yapılan bu tahmine ait R^2 değeri 0,9745'tir.

4.3. Elektrik Tüketiminin Tahmini

İzmir Bakırçay Üniversitesinin elektrik tüketiminin tahmin edilmesi için tıpkı elektrik üretimde olduğu gibi NAR modeli ve NARX modeli bayes optimizasyon eğitim algoritması ile Levenberg-Marquardt eğitim algoritması kullanılmıştır. NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak 11 farklı nöron ile tahminleme yapılmıştır. Yapılan tahminleme Tablo 4.12 'de gösterilmektedir.

Tablo 4.12. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak yapılan denemelere ait MSE ve R değerleri

Nöron Sayısı	**5**		**6**		**7**		**8**		**9**	
Değerlendirme Türü	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**
Training	745,73	0,96	786,83	0,95	788,88	0,95	767,91	0,95	776,29	0,95
Validation	740,95	0,96	817,87	0,95	796,56	0,95	769,92	0,95	722,16	0,96
Testing	888,51	0,95	678,18	0,96	694,84	0,96	782,97	0,95	833,17	0,95

	10		**11**		**12**		**13**		**14**		**15**	
	MSE	**R**	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**	**MSE**	**R**
Training	719,84	0,96	768,69	0,96	754,67	0,96	739,12	0,96	789,73	0,95	734,43	0,96
Validation	834,72	0,95	689,40	0,96	685,10	0,96	862,65	0,95	717,92	0,96	763,17	0,96
Testing	859,05	0,95	788,83	0,95	836,72	0,95	698,62	0,96	657,59	0,96	928,93	0,94

Levenberg-Marquardt eğitim algoritması ve NAR modeli kullanılarak elde edilen en başarılı MSE 751,58 ile 13 nöronlu modelde elde edilmiştir. Tablo 4.13 ‘de NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak yapılan tahminlere ait aylık MSE değerleri gösterilmektedir.

Tablo 4.13. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt eğitim algoritması kullanılarak yapılan tahminlere ait aylık MSE değerleri

Tarih	5 nöron	6 nöron	7 nöron	8 nöron	9 nöron	10 nöron	11 nöron	12 nöron	13 nöron	14 nöron	15 nöron
Tem.19	227,4	205,7	190,1	184,8	189,8	219,6	221,3	242,0	211,9	211,3	211,3
Ağu.19	109,5	101,5	92,9	89,4	91,7	102,8	105,6	113,3	106,9	101,3	101,3
Eyl.19	498,1	522,3	520,1	512,8	528,9	506,1	494,1	499,8	510,0	493,7	493,7
Eki.19	475,4	497,0	489,8	474,0	495,2	482,9	475,5	481,8	480,5	477,4	477,4
Kas.19	660,0	665,8	668,3	660,9	675,6	668,4	672,2	671,4	663,7	661,2	661,2
Ara.19	2005,5	2040,6	2138,8	2077,4	2126,3	2004,7	1974,3	1982,2	2039,4	2003,9	2003,9
Oca.20	1222,7	1224,3	1337,7	1300,8	1347,4	1264,9	1263,5	1213,3	1256,5	1242,5	1242,5
Şub.20	2954,4	2943,5	2752,3	2854,2	2792,6	2827,7	2840,1	2842,4	2802,0	3355,5	3355,5
Mar.20	1089,7	1054,6	1003,4	1015,7	1016,0	1008,7	1038,3	1051,5	1000,1	1053,3	1053,3
Nis.20	96,6	109,9	101,7	98,0	111,0	98,1	92,5	100,8	98,1	91,6	91,6
May.20	51,2	66,3	60,8	56,6	73,0	54,1	48,3	53,7	51,8	45,2	45,2
Haz.20	458,6	458,3	488,4	469,9	482,5	456,8	464,3	475,5	471,6	456,7	456,7
Tem.20	763,9	742,4	795,4	786,2	791,2	767,8	787,7	736,9	754,9	766,8	766,8
Ağu.20	828,2	841,8	883,5	823,1	900,7	809,4	801,2	788,1	819,0	787,9	787,9
Eyl.20	526,0	540,1	558,2	532,9	546,5	515,0	519,8	504,9	523,0	513,4	513,4
Eki.20	242,1	271,8	296,1	279,3	290,6	241,5	215,8	228,0	236,0	223,5	223,5
Kas.20	512,4	498,5	568,9	551,1	540,3	553,3	545,3	551,3	534,9	517,6	517,6
Ara.20	401,2	382,4	401,1	410,1	406,0	407,1	429,5	411,0	397,8	404,4	404,4
Oca.21	606,7	626,8	565,6	580,0	580,6	571,9	583,5	607,3	563,8	594,9	594,9
Şub.21	712,3	728,5	678,1	687,8	672,2	658,8	698,5	694,0	664,4	701,7	701,7
Mar.21	1158,1	1183,9	1030,3	1104,3	1065,1	1077,6	1064,6	1059,0	1046,7	1098,2	1098,2
Nis.21	353,9	359,8	348,8	353,8	353,1	356,3	352,5	364,3	355,3	347,6	347,6
May.21	108,1	138,4	139,2	118,1	164,2	112,6	110,5	113,6	116,3	108,9	108,9
Haz.21	2000,3	2114,6	2213,5	2273,4	2213,9	2051,0	2101,9	2067,3	2055,9	1948,5	1948,5
Tem.21	917,2	918,4	928,0	868,2	923,9	895,6	908,3	902,7	889,1	876,0	876,0
Ağu.21	1302,5	1289,6	1335,5	1373,1	1311,6	1315,4	1344,4	1269,7	1317,2	1345,7	1345,7
Eyl.21	863,7	889,5	850,7	749,1	768,9	885,8	793,1	852,9	774,4	784,4	784,4
Eki.21	418,7	396,5	383,9	389,0	382,4	407,9	429,0	408,4	400,3	412,1	412,1

Aylık tahminler incelendiğinde Aralık 2019, Ocak 2020 Şubat 2020 Mart 2020 Haziran 2021 ve Ağustos 2021 NAR modeli için MSE’nin en yüksek olduğu değerlerdir. Tahminlemenin en doğru yapıldığı aylar ise Mayıs 2020, Nisan 2020 ve Ağustos 2019’dur. NAR modeli ve Levenberg-Marquardt optimizasyon algoritması kullanılarak

da denemeler yapılmıştır. Yapılan bu denemelere ait sonuçlar Tablo 4.14'te gösterildiği gibidir.

Tablo 4.14. Elektrik tüketiminin tahmini için NAR modeli ve Levenberg-Marquardt algoritması kullanılarak yapılan denemelere ait MSE ve R değerleri

Nöron Sayısı	Değerlendirme Türü	Training	Validation	Testing
5 Nöron	MSE	745,73	740,95	888,51
5 Nöron	R	0,96	0,96	0,95
6 Nöron	MSE	786,83	817,87	678,18
6 Nöron	R	0,95	0,95	0,96
7 Nöron	MSE	788,88	796,56	694,84
7 Nöron	R	0,95	0,95	0,96
8 Nöron	MSE	767,91	769,92	782,97
8 Nöron	R	0,95	0,95	0,95
9 Nöron	MSE	776,29	722,16	833,17
9 Nöron	R	0,95	0,96	0,95
10 Nöron	MSE	719,84	834,72	859,05
10 Nöron	R	0,96	0,95	0,95
11 Nöron	MSE	768,69	689,4	788,83
11 Nöron	R	0,96	0,96	0,95
12 Nöron	MSE	754,67	685,1	836,72
12 Nöron	R	0,96	0,96	0,95
13 Nöron	MSE	739,12	862,65	698,62
13 Nöron	R	0,96	0,95	0,96
14 Nöron	MSE	789,73	717,92	657,59
14 Nöron	R	0,95	0,96	0,96
15 Nöron	MSE	734,43	763,17	928,93
15 Nöron	R	0,96	0,96	0,94

Bayes optimizasyon eğitim algoritması ve NAR modeli kullanılarak elde edilen en başarılı MSE 670,01 ile 14 nöronlu modelde elde edilmiştir. Bayes optimizasyon algoritması ile yapılan aylık tahminlerin hatası ise Tablo 4.15'teki gibidir.

NAR modeli ile yapılan tahminler incelendiğinde tıpkı elektrik üretiminin tahmin edilmesinde olduğu gibi elektrik tüketiminin tahmininde de Bayes optimizasyon algoritmasının Levenberg-Marquardt eğitim algoritmasına kıyasla daha iyi sonuç verdiği görülmüştür. 14 nöronlu bayes optimizasyon algoritması kullanılarak oluşturulan ağ 670,01'lik bir MSE değerine sahipken Levenberg-Marquardt eğitim algoritmasıyla oluşturulmuş en iyi model 13 nöronludur ve MSE değeri 751,58'dir.

Tablo 4.15. Elektrik tüketiminin tahmini için NAR modeli ve Bayes optimizasyon algoritması kullanılarak yapılan tahminlere ait aylık MSE değerleri

	5 Nöron	**6 Nöron**	**7 Nöron**	**8 Nöron**	**9 Nöron**	**10 Nöron**	**11 Nöron**	**12 Nöron**	**13 Nöron**	**14 Nöron**	**15 Nöron**
Tem.19	267	268	288	289	247	270	254	264	228	262	279
Ağu.19	108	106	112	110	99	101	114	99	97	91	91
Eyl.19	416	424	401	400	406	405	415	399	431	385	401
Eki.19	398	412	398	400	403	385	398	379	398	368	366
Kas.19	583	589	582	585	575	567	593	555	586	583	553
Ara.19	1914	1798	1809	1807	1705	1757	1807	1685	1684	1528	1806
Oca.20	1247	1155	1177	1176	1099	1189	1148	1187	1148	1109	1169
Şub.20	2640	2603	2590	2594	2502	2509	2642	2482	2432	2405	2380
Mar.20	1017	938	926	922	952	971	936	920	873	894	915
Nis.20	109	103	110	110	120	113	110	115	109	115	111
May.20	74	61	64	65	66	66	65	65	61	63	62
Haz.20	358	367	340	338	344	334	403	345	322	328	326
Tem.20	693	696	677	679	666	630	618	631	633	664	632
Ağu.20	716	711	669	672	657	641	623	635	611	664	641
Eyl.20	435	433	421	419	429	409	412	414	403	411	416
Eki.20	255	239	242	244	248	247	258	273	241	237	292
Kas.20	503	511	508	506	534	481	499	523	451	506	540
Ara.20	409	384	365	363	355	354	368	361	330	320	357
Oca.21	528	531	518	519	509	512	509	500	503	499	512
Şub.21	549	580	548	550	548	536	534	530	561	541	517
Mar.21	917	953	946	948	901	885	936	959	887	896	874
Nis.21	337	338	347	344	340	332	347	346	339	344	328
May.21	131	113	121	127	130	133	131	123	121	126	125
Haz.21	1554	1585	1514	1511	1573	1566	1636	1404	1503	1372	1429
Tem.21	788	766	783	786	776	752	734	761	739	747	804
Ağu.21	1210	1163	1149	1150	1140	1151	1155	1124	1119	1115	1111
Eyl.21	824	896	668	669	710	841	687	683	682	713	643
Eki.21	387	343	356	360	343	339	345	339	345	328	332

NAR modeli ile NARX modelinin karşılaştırılabilmesi için elektrik tüketimi değerleri NARX modeli ile de tahmin edilmiştir. NARX modeli ve bayes eğitim algoritması kullanılarak yapılan tahminlemenin MSE değerleri Tablo 4.16'daki gibidir.

Tablo 4.16. Elektrik tüketiminin tahmini için NARX modeli ve bayes optimizasyon kullanılarak yapılan tahminlerin MSE değerleri

	5 Nöron	**6 Nöron**	**7 Nöron**	**8 Nöron**	**9 Nöron**	**10 Nöron**	**11 Nöron**	**12 Nöron**	**13 Nöron**	**14 Nöron**	**15 Nöron**
Tem.19	488	506	521	542	482	528	532	669	491	485	492
Ağu.19	223	226	260	252	223	258	229	254	221	241	231
Eyl.19	239	266	251	225	228	220	252	237	236	255	219
Eki.19	270	298	291	253	251	217	306	250	306	284	278
Kas.19	424	437	464	455	481	470	538	480	521	573	489
Ara.19	761	879	811	854	1018	914	914	1008	909	1020	942
Oca.20	750	843	778	895	1046	1168	1094	1065	1010	1136	1044
Şub.20	1208	1320	1156	1299	1386	1302	1302	1255	1127	1199	1131
Mar.20	520	560	557	509	565	581	579	552	573	592	577
Nis.20	81	62	65	49	46	55	70	50	58	57	66
May.20	43	33	38	39	25	26	23	36	30	24	32
Haz.20	260	292	287	288	283	288	294	303	322	326	293
Tem.20	480	470	483	509	568	566	639	557	605	605	616
Ağu.20	459	510	485	605	568	555	699	719	700	736	667
Eyl.20	419	459	435	465	498	475	531	531	527	544	539
Eki.20	121	132	132	109	130	111	127	113	147	130	116
Kas.20	321	324	350	301	330	341	371	314	329	396	336
Ara.20	463	443	482	454	480	494	508	497	521	534	487
Oca.21	618	607	581	542	654	642	618	558	645	592	614
Şub.21	578	585	581	498	524	477	498	450	553	524	498
Mar.21	725	745	745	666	759	715	693	732	756	740	712
Nis.21	283	270	292	263	249	227	267	248	282	250	246
May.21	66	55	68	61	57	57	62	70	66	63	76
Haz.21	362	430	471	579	419	429	613	553	652	715	642
Tem.21	434	427	463	499	570	534	591	560	593	640	507
Ağu.21	593	559	591	650	717	695	699	699	860	791	727
Eyl.21	562	554	568	678	554	586	596	709	701	729	732
Eki.21	484	496	478	471	454	462	481	492	446	495	431

NARX modeli ve Levenberg-Marquardt eğitim algoritması ile yapılan aylık tahminler Tablo 4.17'deki gibidir.

Tahminler incelendiğinde bayes optimizasyon algoritmasının en doğru sonucu 5 nöron ile verdiği görülmektedir. 5 Nöron kullanılarak oluşturulan modelde MSE 435,82'dir. NARX modeli ve Levenberg-Marquardt algoritması kullanılarak yapılan tahminlerdeki en düşük MSE ise 13 nöron ile elde edilen 751,58'dir. Tıpkı elektrik üretiminin tahmin edilmesinde olduğu gibi elektrik üretiminin tahmin edilmesinde de eğitim algoritması olarak bayes optimizasyonunu kullanan NARX modeli en az hatalı sonucun bulunmasını sağlamıştır.

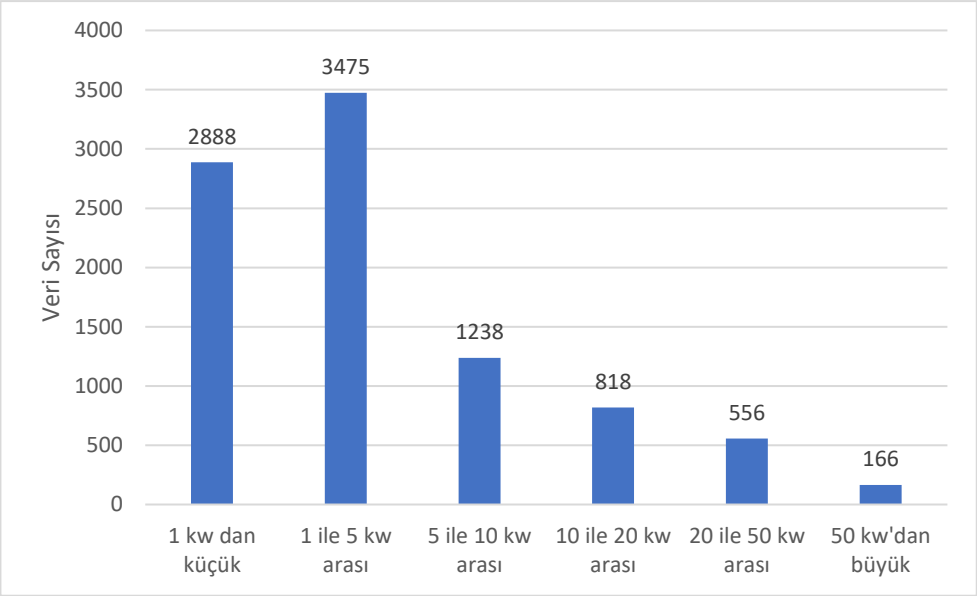
Tablo 4.17. Elektrik tüketiminin tahmini için NARX modeli ve Levenberg-Marquardt algoritması kullanılarak yapılan tahminlerin MSE değerleri

	5 Nöron	**6 Nöron**	**7 Nöron**	**8 Nöron**	**9 Nöron**	**10 Nöron**	**11 Nöron**	**12 Nöron**	**13 Nöron**	**14 Nöron**	**15 Nöron**
Tem.19	389	492	505	413	430	458	499	525	510	574	425
Ağu.19	182	229	235	184	211	216	200	222	228	236	173
Eyl.19	176	281	237	188	184	247	233	240	224	233	222
Eki.19	190	315	240	210	170	284	247	259	225	222	290
Kas.19	301	491	383	362	290	433	376	395	359	344	495
Ara.19	726	888	785	871	916	762	884	989	953	883	787
Oca.20	592	866	791	760	826	827	832	844	873	856	964
Şub.20	1610	1007	1235	1086	1645	937	1189	1407	1291	1028	1253
Mar.20	523	516	539	546	572	463	496	527	550	499	502
Nis.20	59	54	64	52	61	46	44	38	52	49	52
May.20	44	23	37	35	40	29	24	23	33	26	28
Haz.20	222	262	279	210	241	261	256	267	267	277	237
Tem.20	412	425	554	398	485	459	479	499	553	491	536
Ağu.20	379	403	517	359	438	460	490	503	527	508	552
Eyl.20	324	376	469	335	377	407	451	449	486	455	468
Eki.20	101	118	115	97	101	111	99	102	128	122	108
Kas.20	280	310	273	296	313	305	302	286	292	318	389
Ara.20	381	471	421	437	420	476	468	442	393	418	486
Oca.21	476	586	545	525	579	544	598	520	525	543	582
Şub.21	489	527	488	542	532	471	539	460	503	561	545
Mar.21	592	765	661	720	646	622	680	646	682	744	624
Nis.21	235	274	242	255	233	258	247	227	237	254	282
May.21	89	45	68	57	76	48	47	47	58	57	46
Haz.21	455	273	411	330	488	453	381	476	450	494	426
Tem.21	367	353	478	327	432	466	419	427	476	419	508
Ağu.21	528	488	652	498	611	621	564	600	720	581	606
Eyl.21	504	443	513	447	527	488	489	623	667	521	567
Eki.21	400	493	415	485	369	369	434	404	394	444	352

Regresyon analizi ile elektrik tüketiminin tahmini için 1 saat önceki sıcaklık ve 1 gün önceki ziyaretçi sayısı girdi olarak kullanılmıştır. Bu girdiler ve elektrik tüketiminin korelasyon analizi yapıldığında elektrik tüketiminin sıcaklık ve ziyaretçi sayısı ile bağının çok zayıf olduğu görülmüştür. Elektrik tüketiminin sıcaklık ile korelasyonu-0,008 iken kişi sayısı ile korelasyonu 0,162'dir. Elektrik tüketiminin sıcaklık ve kampüsü ziyaret eden kişi sayısı ile korelasyonunun çok düşük olması nedeniyle elektrik üretiminde kullanılan güneş radyasyonu gibi verilerle de regresyon analizi yapılmış ve hiçbirinin elektrik tüketimi ile arasında kayda değer bir regresyon değeri bulunamamıştır.

Elektrik tüketimi ile ilişkili bir girdi bulunamadığından elektrik tüketiminin regresyon analizi ile tahmini yapılamamıştır.

Bu çalışmalarda elde edilen sonuçlar incelendiğinde, yapılan tahminlerin ile gerçekleşen üretimin arasındaki fark 2888 saatte 1kw'den küçüktür. 3475 saatte üretim ile tahmin arasındaki fark 1kw ile 5kw arasındadır. 1238 saatte fark 5kw ile 10kw arasında, 818 saatte 10kw ile 20kw arasında 556 saatte 20kw ile 50kw arasında 166 saatte ise 50'den daha büyüktür. Farkların yüzdesel dağılımı Şekil 4.1'de gösterilmiştir.

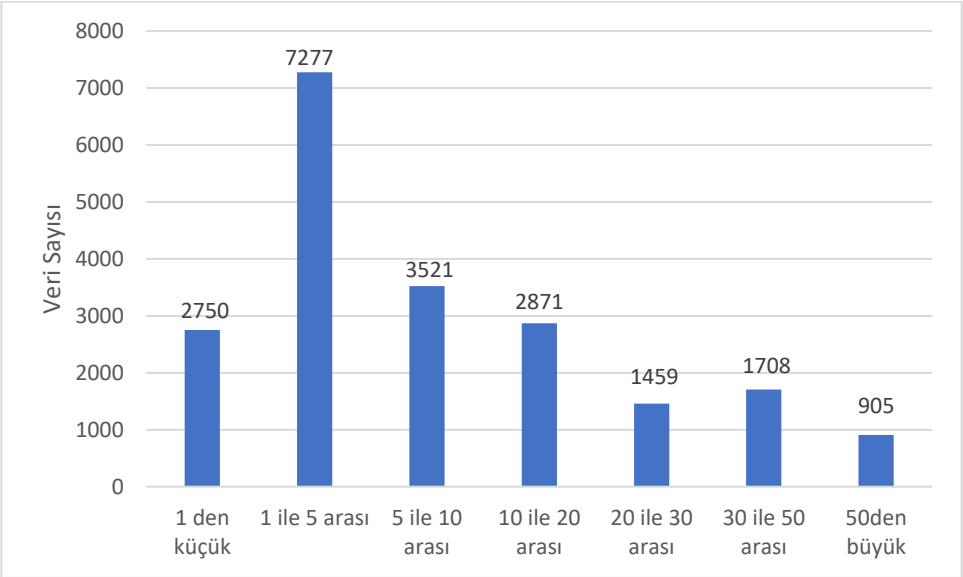


Şekil 4.1. Elektrik üretim ile tahmin arasındaki farkın yüzdelik dağılımı

Bu tabloya göre elektrik üretimi için yapılan tahminlerin %83'ü 10kw'tan daha az hata ile yapılmıştır. Üretim değerleri ile tahmin değerleri yüzdesel olarak kıyaslandığında da yapılan tahminlerin %79'unda hata %10'un altındadır. %69'unda ise hata %5'in altındadır.

Elektrik tüketiminin tahmininde de tıpkı elektrik üretiminde olduğu gibi bayes optimizasyonu eğitim algoritması ile oluşturulmuş NARX modeli en başarılı model olarak ön plana çıkmıştır. 5 Nöron ile en başarılı tahmini yapan modelin MSE değeri 435,82'dir. Elektrik tüketiminde MSE'den de anlaşılabileceği gibi yapılan tahminler elektrik üretiminin tahminine kıyasla daha başarısızdır. Elektrik tüketiminin tahmininde gerçekleşen tüketim ile yapılan tahmin arasındaki fark 2750 saatte 1 kW'tan daha düşüktür. 7277 saatte tüketim ile tahmin arasındaki fark 1kw ile 5kw arasındadır. 3521 saatte fark 5kw ile 10kw arasında, 2871 saatte 10kw ile 20kw arasında 1459 saatte 20kw

ile 30kw arasında 1708 saatte 30kw ile 50kw arasında 905 saatte ise 50kw'dan daha büyüktür. Farkların yüzdesel dağılımı Şekil 4.2'de gösterilmiştir.



Şekil 4.2. Elektrik tüketiminin tahmini ile gerçekleşen tüketim arasındaki farkın yüzdesel dağılımı

Yapılan tüketim tahminlerinin %67'sinde tüketim 10kw'nın altında bir doğruluk ile tahmin edilebilmiştir. %81'inde ise tüketim 20kw'nın altında doğruluk değerleri ile tahmin edilmiştir.

5. SONUÇ ve ÖNERİLER

Yapılan bu çalışma ile İBÜGES'in elektrik üretimi ve İzmir Bakırçay Üniversitesi'nin elektrik tüketimi tahmin edilmiştir. Elektrik üretiminin tahmini için YSA'lar ve regresyon analizi kullanılmıştır. En iyi tahminlemeyi yapan YSA'nın seçimi için NAR modeli ve NARX modeli ile bayes optimizasyon algoritması ve Levenberg-Marquardt algoritmaları kullanılarak denemeler yapılmıştır. Yapılan bu denemelerin sonucunda en iyi sonuç veren ağ modelinin NARX ağı en iyi sonuç veren eğitim algoritmasının da bayes optimizasyon algoritması olduğu görülmüştür. NARX modeli ve bayes optimizasyon algoritması kullanılarak yapılan tahminlerden en başarılı sonucu 214,75 MSE ile 10 nöronlu 5. deneme adı verilen model vermiştir.

Yapılan bu tez çalışmasının sonucunda İzmir Bakırçay Üniversitesi'nin kendi kendine yetebilen bir üniversite olma hedefine katkı sağlayabilecek tahminlemeler yapılmıştır. Mevcut veri setinin azlığı ve elektrik üretimini tahmin etmek için kullanılan meteorolojik bilgilerin santrallere belirli bir uzaklıktaki bölgeden alınmasına rağmen tahmin edilen elektrik üretiminin %70'inde 5kw'ın altında bir hataya ulaşılmış, verilerin %83'ü ise 10kw'ın altında bir hata ile tahmin edilmiştir.

Özellikle 2019 yılında yaşanan covid pandemisinin de etkisiyle İzmir Bakırçay Üniversitesi'nin elektrik tüketiminin tahmin edilmesi daha da zorlaşmıştır. Örneğin üniversitelerin uzaktan eğitim yaptığı 2020 yılının nisan ayında İzmir Bakırçay Üniversitesi'nin elektrik tüketimi nispeten yatay bir grafik seyretmiş ve maksimum tüketim 193,2kw ile 9 nisanda kaydedilirken en düşük tüketim 86,25 kW ile 5 nisanda kaydedilmiştir. 2021 yılına gelindiğinde ise üniversitelerin eğitime başlamasıyla tüketim 500,25 kW'lara kadar çıkmıştır. En düşük tüketim değeri ise 62,1 kW olarak ölçülmüştür. Tüketimde yaşanan bu dalgalanma elektrik tüketiminin tahmin edilmesi için regresyon analizinin yapılmasını ve YSA'ların eğitilmesini zorlaştırmaktadır.

İzmir Bakırçay Üniversitesi'nin henüz çok yeni kurulan bir üniversite olmasından dolayı kurulu GES'in elektrik üretimi ve üniversitenin elektrik tüketimini tahmin etmek için kullanılan veri seti nispeten az veriye sahiptir. Bu çalışmaya başlandığında ocak, şubat, mart, nisan, kasım ve aralık aylarına ait yalnızca 2 yıllık veri bulunmaktaydı. Özellikle covid pandemisinin elektrik tüketim verilerine etkisi hesaba katıldığında, bu aylara ait 2 yıllık veri arasında ciddi uyumsuzluklar bulunmaktadır. İlerleyen yıllarda

elektrik üretim ve tüketim verilerinin artmasıyla beraber tahminlerde iyileşmeler görülebilir bu sayede elektrik üretimi ve tüketimi 1 gün veya 1 hafta önceden tahmin edilebilir.

İzmir Bakırçay Üniversitesi binalarının enerji performansını arttırmaya yönelik çalışmalar yapılabilir. ISO 50001 Enerji Yönetim Sistemi sertifikası doğrultusunda oluşturulabilecek enerji izleme ve kontrol sistemi, Bakırçay Üniversitesi'nin hedefleri için önemli bir ihtiyaçtır. Akıllı enerji yönetimi sisteminin kurulması durumunda bu çalışmada kullanılan modeller sisteme entegre edilebilir veya bu modeller baz alınarak daha gelişmiş modellerin oluşturulabilir.

Şebekeden kaynaklanabilecek elektrik kesintilerine karşı İzmir Bakırçay Üniversitesi'nin kendi kendine yetebilen bir üniversite olabilmesi için bir enerji depolama sistemi veya doğalgaz jeneratörü destekli bir trijenerasyon sistemi kurulabilir.

KAYNAKÇA

Ağıralioğlu, S. ve Ağıralioğlu, N. (2020). Türkiye'de enerji ve politikaları. Takvim-i Vekayi Dergisi, 8(2), 166–198.

Altınay, G. (2010). Aylık elektrik talebinin mevsimsel model ile orta dönem öngörüsü. Enerji, Piyasa ve Düzenleme, 1(1), 1–23.

Arı, A. ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. Acta Infologica, 1(2), 55–73.

Atasoy, S. (2012). Yapay sinir ağları ve sinirsel bulanık ağlar ile insan kaynaklarında performans yönetimi modellemesi. Yıldız Teknik Üniversitesi.

Aydın, E. (2019). Yapay sinir ağları yardımı ile futbolda puan tahmini ve süper lig için bir uygulama. Marmara Üniversitesi.

Baş, N. (2006). Yapay sinir ağları yaklaşımı ve bir uygulama. Mimar Sinan Güzel Sanatlar Üniversitesi.

Biçer, A. (2018). Enerji talep tahminine yönelik program geliştirme ve bir bölge için uygulaması. Afyon Kocatepe Üniversitesi.

BP. (2022). bp Statistical Review of World Energy. Londra.

Çabuk, H. A. (1995). Türkiye'de 1969-1988 dönemi ihracat ve ithalat aylık fiyat endeks trendlerinin analizi. Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 3(3), 97–114.

Çağlayan, M. S. (2022). Montaj hattında malzeme besleme sisteminin yapay sinir ağı yöntemi ile seçimi. Bursa Uludağ Üniversitesi.

Çırak, C. R. (2019). Kontrol teorisi uygulamaları ile zaman serisi öngörülerinin iyileştirilmesi. Hacettepe Üniversitesi.

Demircioğlu, C. (2003). Türkiye için sürdürülebilir enerji çevre politikaları. Ankara Üniversitesi.

Demolli, H., Ecemiş, A., Dokuz, A. Ş. ve Gökçek, M. (2019). Makine öğrenmesi algoritmalarıyla güneş enerjisi tahmini: Niğde ili örneği. International Turkic World Congress on Science and Engineering, 775–783.

Doğan, A. (2019). Namazgah barajına ait buharlaşma miktarının yapay sinir ağı ile tahmin edilmesi. Kocaeli Üniversitesi.

Doğmuş, O., Onat, A., Yılmaz, Ş. ve Ergün, Ş. (2005). Tekstil fabrikalarındaki bağıl nemin yapay sinir ağları yöntemi ile kontrolü. KSÜ Fen ve Mühendislik Dergisi, 8(1), 53–59.

DORUK, E. (2019). Sakarya Bölgesi Hanehalki Elektrik Tüketiminin Dinamik Lineer Model ile Tahmini. YL Tezi, 1–101.

Ege, B. (2011). IBM WATSON. Bilim ve Teknik.

Elibüyük, U. ve Üçgül, İ. (2014). Rüzgar türbinleri, çeşitleri ve rüzgar enerjisi depolama yöntemleri. SDÜ Yekarum e-Dergi, 2(3).

Ferdi., D. ve Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. Sakarya University Journal of Computer and Information Sciences, 22(2), 213–219.

Gaurav, K. A. ve Patel, L. (2020). Machine Learning With R. doi:10.4018/978-1-7998-2718-4.ch015

Grossi, E. ve Buscema, M. (2007). Introduction to artificial neural networks. European Journal of Gastroenterology and Hepatology, 19(12), 1046–1054.

Güllü, M. (2015). Karbon emisyonu ve enerji tüketiminin büyüme üzerindeki etkileri: Mıst ülkeleri karşılaştırması. Çankırı Karatekin Üniversitesi.

Güngör, D. B. (2015). Apgar alternatifi olarak doğum öncesi siniflandirma yaklaşimlari. Sakarya Üniversitesi.

H'meinde Maham, F. (2022). Güneş ışınım tahmini için farklı güneşlenme durumlarını dikkate alan hibrit bir yöntem tasarımı. Afyon Kocatepe Üniversitesi.

Hoehner, C. M., Sabounchi, N. S., Brennan, L. K., Hovmand, P. ve Kemner, A. (2015). Behavior-over-time graphs: Assessing perceived trends in healthy eating and active living environments and behaviors across 49 Communities. Journal of Public Health Management and Practice, 21, 45–54.

İsmiç, B. (2015). Gelişmente olan ülkelerde elektrik tüketimi, ekonomik büyüme ve nüfus ilişkisi. Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 5(1), 259–274.

Kara Kılıçarslan, S. (2019). Yapay zekanın hukuki statüsü ve hukuki kişiliği üzerine tartışmalar, 2019(2), 363–389.

Karaçal, B. (2022). İnsansız hava araçlarında kümelenme ve sürü kontrolü. Karabük Üniversitesi.

Karasu, S., Altan, A., Saraç, Z. ve Hacioğlu, R. (2017). Rüzgâr hızının doğrusal plmayan otoregresif sinir ağları ile tahmini. 25. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 1–4.

Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. Takvim-i Vekayi, 5(2), 8–18.

Koç, M. (2021). Türkiye'nin güneş enerjisi ile ilgili araştırmalara katkısı: 2000-2019 dönemi için bibliyometrik analiz. Amasya Üniversitesi.

Koç, S. ve Deniz, G. (2019). Türkiye de ekonomik büyüme ile bazı makro değişkenler arasındaki ilişki: Çoklu doğrusal regresyon modeli analizi. İşletme Araştırmaları Dergisi, 11(1), 101–113.

Koşunalp, S. (2018). Güneş enerjisi kullanan sistemler için yeni bir enerji tahmin algoritması. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 23(1), 369–378.

Kutlu, B. ve Badur, B. (2009). Yapay sinir ağları ile borsa endeksi tahmini. İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi, 20(63), 25–40.

Lök, S. (2022). Zaman serisi analizi ile deprem tahmini. Fırat Üniversitesi.

Nazaripouya, H., Wang, B., Wang, Y., Chu, P., Pota, H. R. ve Gadh, R. (2016). Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method. Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference, 2016-July.

Oğhan, S. (2010). Zaman serisi analiz yöntemlerinin karşilaştirilmasi. Ege Üniversitesi.

Oral, Ç. (2021). Lityum iyon bataryaların makine öğrenimi yöntemleri ile sağlık durumu kestirimi. İstanbul Teknik Üniversitesi.

Oruç, E. N. (2021). Yapay sinir ağları kullanılarak kısa süreli güneş enerjisi tahmini. İstanbul Teknik Üniversitesi.

Özata, E. (2007). Türkiye'de konjonktürel dalgalanmaların zaman serisi analizi. Anadolu Üniversitesi.

Özgün, Z. (2021). Pisagor bulanık analitik hiyerarşi süreci kullanılarak türkiye'de sürdürülebilir enerji planlaması. Eskişehir Osmangazi Üniversitesi.

Özkan, F. ve Yurtseven, N. B. (2019). Rüzgar türbini ile Türkiye'de tarımsal sulama (I): Denizli ve Muğla için bir egzersiz. Bilkent Enerji Notları.

Öztemel, E. (2006). Yapay zeka ve makine öğrenmesine genel bakış Yapay sinir ağlarının yapısı ve temel elemanları. Yapay sinir ağları. İstanbul Ankara İzmir Adana: Papatya Yayıncılık.

Özturk, K. ve Şahin, M. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. Takvim-i Vekayi, 6(2), 25–36.

Öztürk, S. ve Saygın, S. (2017). 1973 Petrol krizinin ekonomiye etkileri ve stagflasyon Olgusu. Balkan Sosyal Bilimler Dergisi, 6(12), 1–12.

Pata, U. K. (2019). Enerji tüketimi çeşitleri ile çevresel kuznets eğrisinin ampirik olarak analizi: türkiye örneği. Karadeniz Teknik Üniversitesi.

Pekmezci, Z. (2020). Nükleer santrallere yönelik yerel halkın bakışı: sinop ili örneği. Ondokuz Mayıs Üniversitesi.

Şahan, M. ve Okur, Y. (2016). Akdeniz bölgesine ait meteorolojik veriler kullanılarak yapay sinir ağları yardımıyla güneş enerjisinin tahmini. Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi, 11(1), 61–71.

Şardağı, E. (2021). Yöneticilerin kurumsal sürdürülebilirlik kararlarında etkili olan motivasyonlar: Turizm sektörü üzerine bir araştırma. Anadolu Üniversitesi.

Sarı, A., Aktaş, M., Yönetken, A. ve Doğan, R. (2021). Güneş ışınım tahmininde NARX modelinin uygulanması. Afyon Kocatepe Üniversitesi Uluslararası Mühendislik Teknolojileri ve Uygulamalı Bilimler Dergisi, 4(1), 1–6.

Sarı, M. (2016). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. Sakarya Üniversitesi.

Soylu, B. N. (2019). İktisat anabilim dalı iktisat bilim dalı yenilenebilir enerji potansiyeli. Selçuk Üniversitesi.

Suganthi, L. ve Samuel, A. A. (2012). Energy models for demand forecasting - A review.

Renewable and Sustainable Energy Reviews, 16(2), 1223–1240. doi:10.1016/j.rser.2011.08.014

Tabanoğlu, M. (2019). Konut yapılarının rayiç değerlerinin yapay sinir ağları metodu kullanılarak tahmin edilmesi: Düzce ili örneği. Düzce Üniversitesi.

Ticaret Bakanlığı. (2021). Yeşil mutabakat eylem planı. Türkiye Cumhuriyeti Ticaret Bakanlığı, 60.

Türkyilmaz, O. (2017). 11. Yerli kömür kaynakları elektrik üretiminde kullanılmalı mı, neden? Türkiye'de Termik Santraller. Ankara.

World Energy Outlook 2021. (2021).IEA Publications. www.iea.org/weo adresinden erişildi.

Yaman, M. ve Haşıl, F. (2018). Türkiye'deki hidroelektrik santrali (HES) uygulamalarına çevre açısından bakış. Uluslararası Afro-Avrasya Araştırmaları Dergisi, 1(5), 145–156.

Yıldız, S. (2021). Sürdürülebilirlik performansının çok kriterli karar verme yöntemleri ile ölçümü. Alanya Alaaddin Keykubat Üniversitesi.

Yılmaz, B. (2015). Akarçay havzasında çözünmüş oksijen değerlerinin yapay sinir ağları ile belirlenmesi. T.C. Orman Ve Su İşleri Bakanlığı.

Yılmaz, E. ve Darende, V. (2021). Türkiye'de yağış ölçümü yapılan manuel-otomatik meteoroloji gözlem istasyonu verilerinin karşılaştırılması. Türk Coğrafya Dergisi, 77, 53–66.

http1:https://yearbook.enerdata.net/total-energy/world-import-export-statistics.html (erişim tarihi 15.06.2022)

http-2:https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy/downloads.html (erişim tarihi 10.05.2022)

http-3:https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes (erişim tarihi 16.05.2022)

http-4:https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history1.html (erişim tarihi 14.05.2022)

http-5:https://mind.ilstu.edu/curriculum/mcp_neurons/index.html (erişim tarihi 08.04.2022)

http-6:https://www.mathworks.com/help/stats/bayesian-optimization-algorithm.html (erişim tarihi 15.04.2022)

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	**Ertuğrul ORMAN**
E-Posta	ertugrulorman@gmail.com

Eğitim	
Lisans	2020, Makine Celal Bayar Üniversitesi, MühendislikFakültesi, Makine Mühendisliği Bölümü
Yüksek Lisans	2022,İzmir Bakırçay Üniversitesi, Lisansüstü Eğitim Enstitüsü, Akıllı Sistemler Mühendisliği Anabilim Dalı

Yayın Listesi	
Bildiri	İzmir Bakırçay Üniversitesi Güneş Enerji Santralinin Elektrik Üretiminin Saatlik Tahmini, Orman, E, (2022), 2. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi, İzmir
	Dikey Eksenli Rüzgâr Türbini Uygulamalarında Türkiye'nin Durumu, Orman,E ,Muştu. M, Köse B, (2021), Entegre Kirlilik Önleme ve Kontrol konulu sempozyum, Karabük
	Dikey Eksenli Rüzgar Türbini Gelişmeleri Üzerine Bir Araştırma. Kose.B, Orman. E, Taş. B, Daşdemirli.Y, Akderya.T, Güneşer M.T.(2021). Ulıbtk'21 Uluslararası Katılımlı 23. Isı Bilimi Ve Tekniği Kongresi, 08-10 Eylül 2021, Gaziantep (Özet Bildiri)