

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**REGRESYON VE YAPAY SİNİR AĞLARI İLE FOTOVOLTAİK
PANEL YÜZEY SICAKLIĞI TAHMİNİ**

YÜKSEK LİSANS TEZİ

Çağatay ÖZTÜRK

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

TEMMUZ 2020

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**REGRESYON VE YAPAY SİNİR AĞLARI İLE FOTOVOLTAİK
PANEL YÜZEY SICAKLIĞI TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Çağatay ÖZTÜRK
(301171009)**

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Dr. Öğr. Üy. Burak BARUTÇU

TEMMUZ 2020

İTÜ, Enerji Enstitüsü'nün 301171009 numaralı Yüksek Lisans Öğrencisi Çağatay ÖZTÜRK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "REGRESYON VE YAPAY SİNİR AĞLARI İLE FOTOVOLTAİK PANEL YÜZEY SICAKLIĞI TAHMİNİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Burak BARUTÇU**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Dr. Öğr. Üyesi M. Berker YURTSEVEN**
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi İsmail NAKİR
Yıldız Teknik Üniversitesi

Teslim Tarihi : **02 Haziran 2020**
Savunma Tarihi : **16 Temmuz 2020**





Aileme ve arkadaşlarıma,



ÖNSÖZ

Tez çalışmamda, en büyük desteği gösteren, görüşleri ile beni yönlendiren tez danışmanım Dr. Öğr. Üy. Burak BARUTÇU'ya sabır ve anlayışlarından dolayı teşekkür ederim.

Ayrıca tez çalışmamda kullandığım verilerin toplanması ve paylaşılması ile ilgili göstermiş olduğu cömert destekten dolayı SOLARIAN ENERJİ Genel Müdürü Orçun BAŞLAK'a ve kıymetli katkılarından dolayı değerli dostum Onur Erdem KORKMAZ'a teşekkür ederim.

Temmuz 2020

Çağatay ÖZTÜRK
(Elektrik - Elektronik Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	vii
KISALTMALAR	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ.....	1
1.1. Yenilenebilir Enerji ve Güneş Enerjisinin Dünya'daki Durumu	3
1.1.1. Neden yenilenebilir enerji?	3
1.1.2. Yenilenebilir enerjinin iç ihtiyaç için kullanımı	6
1.1.3. Yenilenebilir enerji hakkında kamuoyu görüşleri.....	7
1.2. Tezin Amacı	12
1.3. Literatür Araştırması	12
2. METOT	21
2.1. Regresyon Analizi	21
2.2. Yapay Sinir Ağları	23
2.2.1. İleri beslemeli sinir ağı.....	27
2.2.2. Genelleştirilmiş regresyon sinir ağları	30
2.2.3. Radyal tabanlı fonksiyon ağları.....	31
3. MODELLEME	35
3.1. Model Başarımlarının Değerlendirmesinde Dikkate Alınan Kriterler	35
3.2. Regresyon Modeli	37
3.3. İleri Beslemeli Sinir Ağı Modeli	39
3.4. Genelleştirilmiş Regresyon Sinir Ağı Modeli	41
3.5. Radyal Tabanlı Fonksiyon Ağı Modeli	43
4. BULGULAR	45
KAYNAKLAR	47
ÖZGEÇMİŞ.....	55



KISALTMALAR

AE	: Mutlak Hata
BIPV	: Binaya Entegre Fotovoltaik
ESS	: Hataların Kareler Toplamı
FFN	: İleri Beslemeli Sinir Ağı
G	: Güneş Işınımı
GRNN	: Genelleştirilmiş Regresyon Sinir Ağı
GW	: Gigawatt
HCPV	: Yükek Yoğunluklu Fotovoltaik
kWh	: Kilowatt Saat
MAE	: Ortalama Mutlak Hata
MBE	: Ortalama Sapma
MLP	: Çok Katmanlı Algılayıcı
MSPP	: Mega Güneş Enerji Santrali
MW	: Megawatt
NOCT	: Nominal Çalışma Hücresi Sıcaklığı
PV	: Fotovoltaik
R²	: Determisasyon Katsayısı
RBFN	: Radyal Tabanlı Fonksiyon Ağları
RH	: Bağlı Nem
rMAE	: Bağlı Ortalama Mutlak Hata
RMSE	: Ortalama Karesel Hatanın Karekökü
rRMSE	: Bağlı Ortalama Karesel Hatanın Karekökü
Ta	: Ortam Sıcaklığı
Tm	: Modül Sıcaklığı
TSS	: Kareler Toplamı
W	: Rüzgar Hızı
YE	: Yenilenebilir Enerji
YEK	: Yenilenebilir Enerji Kaynakları
YET	: Yenilenebilir Enerji Teknolojileri
YSA	: Yapay Sinir Ağları

SEMBOLLER

b	: Bias
β_0	: Model Sabiti
β_1	: Bağımsız Değişkenin Katsayısı
ε_i	: Rassal Hata
μ	: Dağılım Ortalaması
σ	: Standart Sapma
w	: Nöronlar Arasındaki Ağırlıklar
X	: Bağımsız Değişken
Y	: Bağımlı Değişken
\hat{Y}	: Bağımlı Değişken



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1: Kamuoyu görüşleri özetleri	10
Çizelge 1.2: Yenilenebilir enerjinin yaygınlaşmasında karşılaşılan engeller	11
Çizelge 4.1: Model hata kriterleri	45





ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: 2008-2018 yılları arasında küresel enerji üretim kapasitesi içinde yenilenebilir enerjinin payı.....	2
Şekil 1.2: 2012-2018 yılları arasında Farklı YEK'lerin YE kapasitesine katkısı.....	2
Şekil 1.3: 2000-2017 yılları arasında CO2 salımı miktarları.....	4
Şekil 1.4: 2014-2017 yılları arasında YEK kullanımı için politikalar ve bu politikaları uygulayan ülke sayısı	5
Şekil 1.5: 2007-2017 arasında güneş termal kollektörlerin küresel kapasitesi.....	7
Şekil 1.6: Kamuoyu görüşlerinin kaynağı ve tartışılan YEK'ler.....	9
Şekil 2.1: Nöronun yapısı	23
Şekil 2.2: Bias terimi eklenmiş nöron yapısı	24
Şekil 2.3: Sigmoid fonksiyonu	25
Şekil 2.4: Hiperbolik tanjant fonksiyonu	25
Şekil 2.5: ReLU fonksiyonu	26
Şekil 2.6: Sızıntı ReLU fonksiyonu	26
Şekil 2.7: Yapay Sinir Ağları Modeli	27
Şekil 2.8: Hatanın geri yayılımı algoritmasının şematik gösterimi	30
Şekil 2.9: GRNN tipik mimarisi	31
Şekil 2.10: RBFN tipik mimarisi	32
Şekil 2.11: Ortalama dağılım.....	34
Şekil 2.12: RBF nöron aktivasyonu (Gauss Dağılımı)	34
Şekil 3.1: Regresyon modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği	37
Şekil 3.2: Regresyon modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği.....	38
Şekil 3.3: FFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği	39
Şekil 3.4: FFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği	40
Şekil 3.5: GRNN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği	41
Şekil 3.6: GRNN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği	42



REGRESYON VE YAPAY SİNİR AĞLARI İLE FOTOVOLTAİK PANEL YÜZEY SICAKLIĞI TAHMİNİ

ÖZET

Güneş, tükenmez enerji kaynaklarının en önde gelen türlerinden biridir. Fosil kaynakların tükenmesi ve çevreye verdikleri zararın her geçen gün daha da belirgin hale gelmesiyle birlikte, güneş enerjisine yapılan yatırımlar da artmaktadır. Düşük bakım maliyetleri, kısa zaman içerisinde mega fotovoltaik tarlaların kurulabilmesi ve dünyanın hemen her bölgesinde verim sağlayabilmesi açısından batarya sistemlerinin maliyetlerinin zamanla azalması ile birlikte gelecekte elektrik üretimin en önemli kaynağı olması beklenmektedir. Fotovoltaik elektrik üretimi bugün itibarı ile de dünyada elektrik üretimine, hem ev veya fabrika gibi binaların iç ihtiyaçlarını karşılama hususunda hem de yüksek kurulu güç kapasiteli güneş tarlaları ile katkıda bulunmaktadır. Genellikle silikondan üretilen hücrelerin iç dirençleri artan panel sıcaklığıyla birlikte artış göstermektedir. Bu direnç elektrik üretimini negatif yönde etkilemektedir. Farklı coğrafi bölgelerde bu sıcaklığı olumlu ya da olumsuz yönde etkileyen meteorolojik değişkenler de farklılık gösterir. Dolayısıyla fotovoltaik panel yüzey sıcaklığının tahmin edilmesi bir güneş tarlasının kurulduğu ya da kurulması planlanan lokasyonda ne kadar verimli olduğu ya da olacağı açısından ve bu lokasyonda üreteceği yıllık enerji miktarının öngörülebilmesi açısından oldukça önemlidir. Bu nedenle bu çalışmada aktif bir güneş tarlasındaki fotovoltaik panel sıcaklığının tahmini üzerine yoğunlaşmıştır.

Bu çalışmada toplam dört adet model vasıtası ile fotovoltaik panel yüzey sıcaklığının tahmininin gerçekleştirilmesi ve bu tahminlerin belli hata kriterlerine göre doğruluklarının sınanması amaçlanmıştır. Bu modeller regresyon modeli ve yapay sinir ağı modelleridir. Bu modellerin sınanması ve kıyaslamaları yapılırken R^2 , MBE, MAE, RMSE gibi hata kriterlerinden faydalanılmıştır.

Gerçekleştirilen modeller arasında tahmin başarımının en yüksek olduğu model FFN modeli olarak göze çarpmaktadır. Başarımın en düşük olduğu model ise Regresyon modeli olduğu saptanmıştır. Ayrıca gerçekleştirilen tüm yapay sinir ağı modelleri regresyon modelinden daha yüksek başarıma sahip olmuştur. Yapay sinir ağı modellerinin başarımının regresyon modeline nazaran başarımlarının yüksekliği göze çarpmaktadır.



PHOTOVOLTAIC PANEL SURFACE TEMPERATURE PREDICTION BY USING REGRESSION AND ANN METHODS

SUMMARY

Solar energy is one of the leading sources of renewable energy sources in electricity generation. The reason for this is that it is one of the most accessible sources, and it can be obtained in most regions of the world. Electricity generation is generally carried out with photovoltaic panels made of silicon and germanium. Their use is increasing and widespread in terms of photovoltaic systems being largely applicable to all fields and producing in a wide spectrum of installed power spectrum from micro scale to macro scale. It is expected that the share of solar energy in electricity generation will increase significantly with the development of battery technologies and the decrease in costs. Photovoltaic systems are a candidate to be the leading actor of electricity generation in the coming years because of their low maintenance costs and the construction of high installed power capacities in a short time.

The efficiency of photovoltaic systems varies according to the geography in which it is built. Investors want to know how long the return of that investment will take place, as in investment, before the construction of photovoltaic systems begins. The main gain of a photovoltaic system; It is equal to the total electricity energy produced in kWh, usually multiplied by the unit price in kWh. In addition, institutions managing the grid in many regions require independent electricity producers to declare the amount of electricity they will produce for certain periods. Therefore, it is important to estimate the electrical energy produced by a photovoltaic system.

Temperature directly affects the amount of electrical energy produced by photovoltaic panels. With the increase in temperature, an electrical resistance is formed on the material from which the module is formed, resulting in decreases in energy production. Knowing the panel surface temperature is important for determining the return time of the previously disclosed investment and the amount of energy to be reported to the electricity administration. In addition, this surface is valuable in terms of guiding the studies for lowering the temperature.

For the reasons explained above, this study focuses on estimating the surface temperature of a photovoltaic panel. Sensor data measuring solar radiation, wind speed, ambient temperature data received from a photovoltaic power plant with an installed capacity of 1 MW within the boundaries of Hatay province and the actual panel surface temperature in the same power plant were collected. These data include the values from the first day of 2018 to the last day.

The surface temperature estimation study of the photovoltaic panel was carried out with the help of models installed with four different methods. These models are respectively regression model, artificial neural network models; The FFN model is the GRNN model and the RBFN model.

Regression model by establishing multiple regression model, $T_m(\hat{Y}) = 0.0157G - 0.6641W + 1.0469T_a + 8.3302$ photovoltaic surface temperature; Equation depending on the radiation, wind speed and ambient temperature was obtained. As expected, the effect of wind speed on panel surface temperature is negative. This results in the wind speed being positive for energy production. As the ambient temperature is high, it directly causes an increase in the temperature of the photovoltaic panels, which has a negative effect on energy production. It is observed that the solar radiation that enables the photovoltaic systems to generate electricity, on the other hand, increases the temperature of the photovoltaic panel, thus indirectly causing a decrease in energy production.

In the FFN model, panel surface temperature data taken at fifteen minute intervals are divided into groups of five. The first four data of each group were used to train the model and the remaining data was used to test the model. The number of neurons in the hidden layer started with 5 and increased to 20 neurons one by one. Experiments were carried out by increasing the input neurons from 1 to 50.

In the GRNN model, as in the FFN model, the panel surface temperature data, taken at intervals of fifteen minutes, is divided into groups of five. The first four data of each group were used to train the model and the remaining data was used to test the model. In this model, Gauss function was chosen as the activation function. Since this network model is fixed as in RBF, no determination has been made regarding the number of layers. The embedding size has been increased one by one from 200 to 200 and the model has been trained.

In the RBFN model, as with other artificial neural network models, panel surface temperature data, taken at intervals of fifteen minutes, is divided into groups of five. The first four data of each group were used to train the model and the remaining data was used to test the model. There is one RBF layer in this network structure. Since it is a fixed network model, no adjustment has been made to the number of layers. Gauss function was chosen as the activation function.

As explained in this study, it is aimed to estimate the photovoltaic panel surface temperature by means of a total of four models and to test the accuracy of these estimates according to certain error criteria. There is no single metric accepted in the literature in evaluating the model performance. Determination coefficient (R^2), Mean-Absolute Error (MAE), Relative Mean-Absolute Error (rMAE), Root Mean Square Error (RMSE), Relative Root Mean Square Error (rRMSE), Mean Bias to evaluate the performance of the method proposed in this thesis study. Criteria such as Error (MBE) and Relative Mean Bias Error (rMBE) were used.

Models are evaluated one by one according to the specified error criteria and model achievements are revealed. First, the determination coefficient calculated in the multiple regression model was calculated as $R^2 = 0.9979$. The calculated errors of this model stand out as $MAE = 1.257$ and $MBE = 0.8482$.

In feed forward neural network model, determination coefficient was calculated as $R^2 = 0.9992$. It has been revealed that the calculated errors of this model are $MAE = 0.7039$ and $MBE = 0.0165$.

Determination coefficient in generalized regression neural network model; R^2 calculated as 0.9988. It has been determined that the calculated errors of this model are $MAE = 0.8760$ and $MBE = 0.0118$.

Determination coefficient in the radial basis function network model; R^2 calculated as 0.9983. The calculated errors of this model were determined as $MAE = 0.6867$ and $MBE = 0.0564$.

R^2 value is between 0 and 1. The large R^2 value is a positive factor for the significance of the model. In other words, the significance of the model will increase as R^2 approaches one. When the results given by the models described before are examined, the model with the largest R^2 value is FFN. ($R^2 = 0.9992$) At the same time, low RMSE value is important for the performance of the model. It can be said that the model with the nearest RMSE value to zero has a better performance. When the errors of the applied models are examined, it is seen that the model with the lowest RMSE value is the FFN model. Therefore, it seems that the best model is the FFN (Feed Forward Neural Network) model, because it has the largest R^2 value and the smallest RMSE value. In addition, when determination coefficient and errors are examined, it will be seen that all artificial neural network models give better results than multiple regression model. Thus, the results of this study revealed that artificial neural network methods provide superiority to regression method.

In this study light, where the photovoltaic panel surface temperature is estimated using wind speed, solar radiation and ambient temperature variables, a similar study can be carried out using data from different regions. Thus, the relationship between models in different geographical regions and models in this study can be examined. In addition, data such as soil temperature and humidity can be collected and added to the model. This can create a stronger model with more variables.




1. GİRİŞ

Dünya, nüfusun artan günlük enerji ihtiyacı nedeniyle hızla küresel bir köy haline gelirken, anlık olarak aynı oranda değişemez. İnsanlığı; sosyal ve ekonomik kalkınma, refah ve sağlık hususlarında tatmin etmek için enerji ve ilgili hizmetlere duyulan ihtiyaç artmaktadır. Tüm toplumlar, sağlık, aydınlatma, mekan konforu ve iletişim gibi temel insan ihtiyaçlarını karşılamak için enerji hizmetlerini talep ederler [1]. Enerji arzının güvence altına alınması ve iklim değişikliğine enerji üretiminden kaynaklı olumsuzlukların engellenmesi, enerji sektörünün sürdürülebilir bir geleceğine giden yolda iki ana zorluktur [2,3].

Tarihsel olarak, kayıtlara geçen ilk ticari kömür madenciliği, 1750 yılında Richmond yakınlarında, Virginia'da gerçekleşti. Anlık olarak, kömür, ilgili miktarda biyokütle bazlı yakıttan (yakacak odun ve odun kömürü) daha fazla enerji taşıma kapasitesi nedeniyle buhar motorları için en çok tercih edilen yakıt oldu. Fosil yakıt bazlı enerji üretiminin (Kömür, Petrol ve Gaz) baskınlığı ve son yıllarda nüfusun üstel artışı, karbondioksit (CO₂) emisyonlarında hızlı bir büyüme ile ilişkili olarak enerji talebinin artmasına neden oldu [4]. İklim değişikliği, yirmi birinci yüzyılın en büyük zorluklarından biri haline gelmiştir. Mevcut enerji sistemlerini dönüştürmek için çaba sarf edilirse, ciddi olumsuz etkilerden kaçınılabilir. Yenilenebilir enerji kaynakları, sera gazı emisyonlarını fosil yakıt bazlı enerji üreten ve dolayısıyla iklim değişikliğini azaltan önemli bir potansiyele sahiptir [1].

Yenilenebilir enerji kaynakları günümüzde dünyanın hemen hemen her bölgesinde enerji sektöründe ciddi bir oyuncu haline gelmiştir. 2018'de 90'dan fazla ülkede 1 GW'dan fazla yenilenebilir kurulu güç ve 30 ülkede ise 10 GW'dan fazla kurulu güç vardı. Yenilenebilir enerji kapasitesi, rüzgar enerjisi ve solar PV liderliğinde 2018'de %8 büyüdü. Birbirini takip eden son dört yılda, fosil yakıt ve nükleer enerjinin toplamından daha fazla yenilenebilir enerji santralleri kuruldu ve şekil 1.1'den anlaşılacağı üzere yenilenebilir enerji kaynakları küresel kurulu güç kapasitesinin üçte birinden fazlasını oluşturuyor [5].

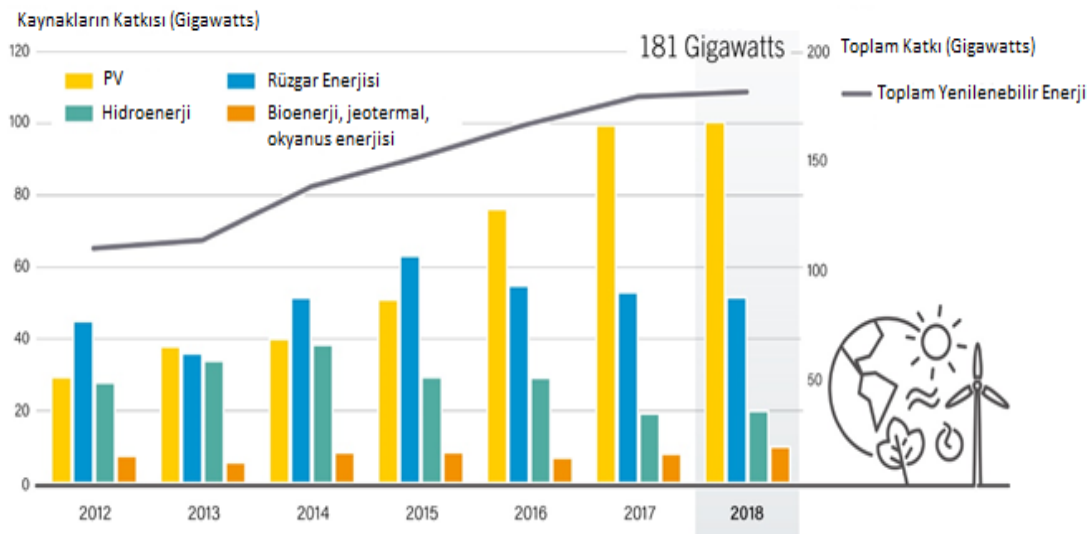
Küresel Enerji Üretim Kapasitesi (2008-2018)



Şekil 1.1 : 2008-2018 yılları arasında küresel enerji üretim kapasitesi içinde yenilenebilir enerjinin payı.

Dünya genelinde yenilenebilir enerji konusunda artan deneyim, küresel enerji ihtiyaçlarını karşılayabilme konusunda önyargıları parçaladı. Yenilenebilir enerji teknolojilerinin güvenilir olduğu kanıtlanmıştır ve artık birçok durumda en düşük maliyetli enerji üretim seçeneklerini sunmaktadır. Yenilenebilir enerji kaynakları mevcut şebekelere başarıyla entegre edilebilir: 2018'de en az dokuz ülke farklı yenilenebilir enerji kaynakları (rüzgar enerjisi ve güneş PV) ile elektriğinin %20'sinden fazlasını üretti [5].

Farklı kaynakların Yıllık Olarak Yenilenebilir Enerji Kapasitesine Katkısı



Şekil 1.2 : 2012-2018 yılları arasında Farklı YEK'lerin YE kapasitesine katkısı.

1.1. Yenilenebilir Enerji ve Güneş Enerjisinin Dünya'daki Durumu

1.1.1. Neden yenilenebilir enerji?

Yenilenebilir enerji (YE) konusu, uzmanları ve halkı giderek daha fazla ilgilendirmektedir. Yenilenebilir enerji kaynakları (YEK) ile ilgili çalışmalar son yıllarda mutlak ve görel olarak artmıştır [6]. YEK fosil yakıtların tükenmesi ve küresel ısınma konularını ele alarak önemli bir rol oynayabilir [7]. Fosil yakıtlar, nükleer kaynaklar ve yenilenebilir kaynaklar üç ana enerji kaynağıdır. Güneş, rüzgar, biyokütle, jeotermal ve hidroelektrik enerji gibi YEK, enerjiyi sürdürülebilir bir şekilde üretmek için kullanılır ve bu nedenle enerji krizleriyle mücadele konusunda oldukça faydalıdır [8].

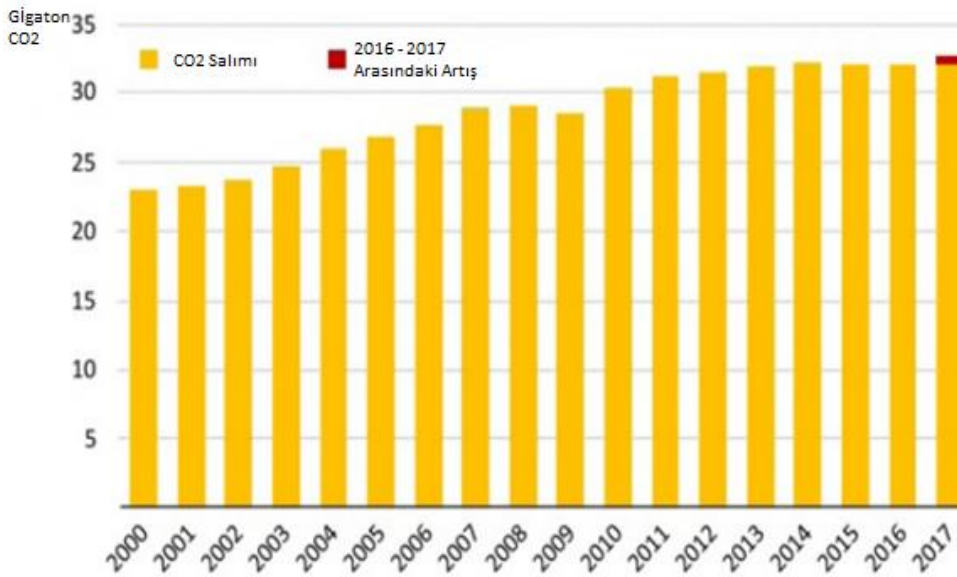
Yenilenebilir enerji kaynakları temiz enerji kaynakları olarak kabul edilmektedir [9] ve çevre dostu yapıları nedeniyle kritik önem taşımaktadır [10,11]. Temiz bir çevre bilincinin artmasıyla birlikte, fosil yakıtlara geleneksel bağımlılığın; karbondioksit (CO₂) emisyonlarına, sera gazı sorunlarına ve çevre kirliliğine yol açtığına inanılmaktadır [12,13]. YEK, hava kirlenici ve sera gazı emisyonlarının sıfır veya neredeyse sıfır olarak enerji üretimi sağlama potansiyeli ile evsel enerji gereksinimlerini karşılayabilir [14,15]. Kırsal bölgelerin sürdürülebilir kalkınması, çevre koruma ile ilgili uluslararası anlaşmaları yerine getirme yükümlülüklerinin yerine getirilmesi gibi çok önemli görevlerin YE ile çözülmesi beklenmektedir [16-18]. Aşırı enerji talebini karşılamak için, konvansiyonel yakıt bazlı üreteçlerin yerini YEK ile değiştirme eğilimi vardır [19]. Sera gazı emisyonları, CO₂ emisyonları, iklim değişikliği ve enerji güvenliği gibi YE'nin bugünün şartlarında artan bir ihtiyacı karşılamaya çalışmasına yol açan birçok neden vardır [20-22]. YEK, fosil yakıtların aksine çevreyi korur, kirlilik içermeyen bir çevre vaat eder, enerji güvenliği ve ekonomik faydalar sağlar [23],[24]. Bu nedenle, enerji ihtiyacını karşılamak için, mevcut ve gelecek nesillerin YEK'e güvenmesi gerçekten çok önemlidir. Bunu başarmak için, YE'nin kullanımını teşvik etmek için politika oluşturma ve kamuoyunun araştırılması gerekmektedir.

Enerji talebi hızla artıyor ve bu nedenle, büyüyen dünya nüfusunun gereksinimlerini karşılamak ve enerji krizlerinden kaçınmak için süreçler geliştirmek çok önemlidir. Mevcut enerji tüketimindeki talebin, 2004 yılı referans alınır 2030 yılına kadar %65 artması beklenmektedir [25]. Şu anda, küresel olarak kullanılan enerjinin çoğu

kömürle çalışan elektrik santralleri gibi yenilenemeyen kaynaklardan üretilmektedir. Bunların sera gazı (CO₂, NO_x ve SO_x) emisyonları gibi ciddi sorunlara neden olduğu ve küresel ısınmaya katkıda bulunduğu bilinmektedir [26, 27]. Atmosferdeki sera gazı seviyelerinin tehlikeli bir oranda artmasıyla, CO₂'yi azaltmanın yollarını belirlemenin yanı sıra fosil olmayan yakıt bazlı enerji kaynaklarının geliştirilmesi de önemlidir [43]. Fosil yakıtların aksine, YE alternatif temiz enerji kaynakları sunmaktadır. Ayrıca, gelecekteki elektrik taleplerinin karşılanmasında kilit rol oynayarak enerji krizlerini azaltması da beklenmektedir. Güneş ve rüzgar enerjisi, YE kaynaklarının; dünya çapında kullanımlarını arttırmaya yönelik ilgiyi teşvik eden en umut verici biçimleridir [28, 29].

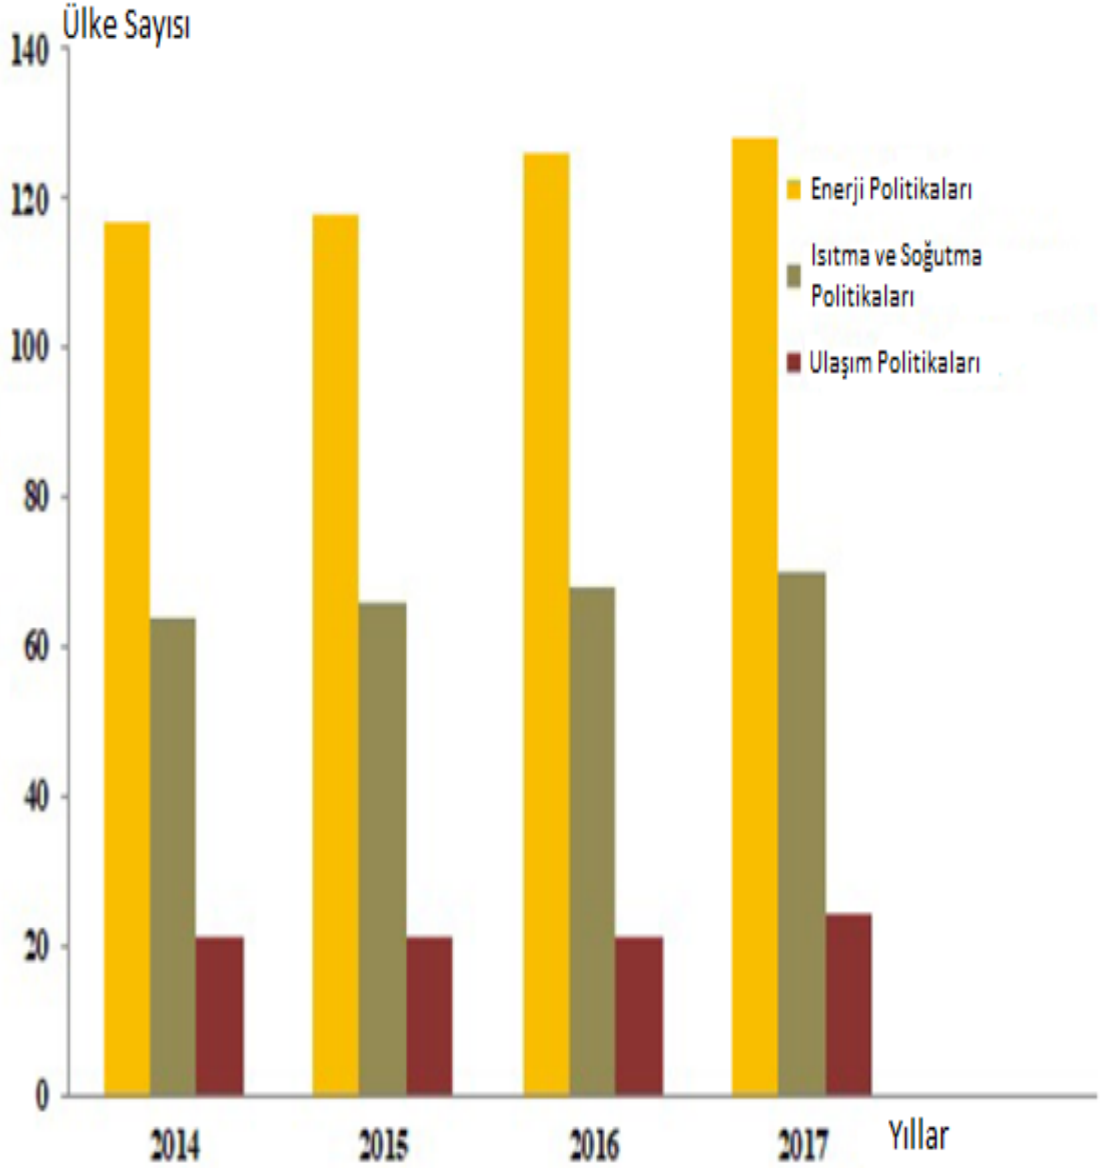
Gelişmiş ülkelerle karşılaştırıldığında, enerji krizleri (özellikle elektrik krizleri) az gelişmiş ülkelerde derindir. Shakeel ve arkadaşları [30] YEK'i enerji üretimine entegre ederek Pakistan'daki enerji krizlerinin üstesinden gelmek için bir yol haritası tanımlamıştır. Enerji ihtiyacını karşılamak için [31] tarafından yapılan bir inceleme, İran'ın kırsal bölgelerindeki fosil yakıtlara olan ağır bağımlılığı tespit etmiştir. Bu çalışma, fosil yakıtlara bağımlılık nedeniyle, çevrede önemli miktarda kirlilik olduğunu düşündürmektedir.

Şekil 1.3, 2000-2017 dönemi için CO₂ emisyonlarını göstermektedir [15]. CO₂ emisyonlarını kontrol etmek için küresel olarak RE gibi temiz enerji kaynaklarının kullanımını teşvik eden bir dizi politika yürürlüğe konmuştur.



Şekil 1.3 : 2000-2017 yılları arasında CO2 salımı miktarları.

Şekil 1.4, 2014-2017 yılları arasında YEK kullanımı için bu politikaların uygulanmasına katkıda bulunan ülkelerin sayısını göstermektedir[15]. Bu politikalar arasında güç politikaları, ısıtma ve soğutma politikaları ve ulaşım politikaları bulunmaktadır.



Şekil 1.4 : 2014-2017 yılları arasında YEK kullanımı için politikalar ve bu politikaları uygulayan ülke sayısı.

Bildirildiği gibi [32], 2017 yılı sonunda, küresel yenilenebilir enerji üretim kapasitesi 2.179 GW olmuştur. Buna göre, hidro enerjinin 1,152 GW kurulu güce sahip küresel toplamın en büyük payına sahip olduğu kaydedilmiştir. Rüzgar ve güneş enerjisi, geri kalanların çoğunu sırasıyla 514 GW ve 397 GW kapasiteyle oluşturdu. Diğer yenilenebilir kaynaklar 109 GW biyoenerji, 13 GW jeotermal enerji ve 500 MW deniz enerjisi (gelgit, dalga ve okyanus enerjisi) idi.

Yenilenebilir enerji kapasite artışına, çoğunlukla 2017 yılında kurulan tüm yeni kapasitenin % 85'ini oluşturan yeni güneş ve rüzgar enerjisi kurulumları katkıda bulunmaya devam etmektedir. YE kapasitesindeki hızlı iyileşme ekonomik büyüme ve istihdam yaratma; karbon emisyonlarının sınırlandırılması; hava kirliliğinin azaltılması; enerji erişiminin genişletilmesi; ve enerji güvenliğinin iyileştirilmesi açısından avantajlara sahiptir [8].

1.1.2. Yenilenebilir enerjinin iç ihtiyaç için kullanımı

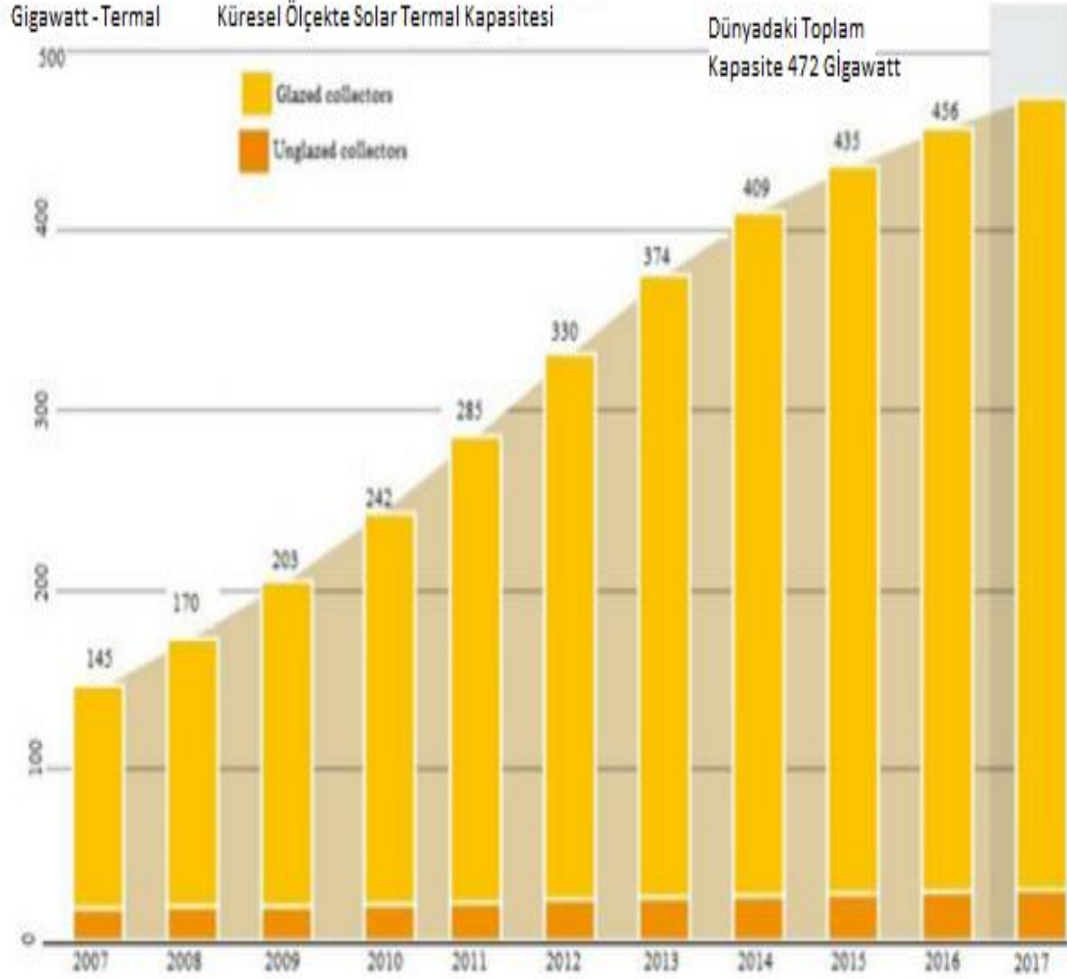
YEK gibi güvenilir enerji kaynakları yaşam standardını iyileştirmede hayati bir rol oynayabilir [28]. Güneş termal enerjisi en sık rastlanan YE türüdür. Güneş enerjisi, termal uygulamalar için geniş bir kapsama sahiptir: güneş enerjili su ısıtıcıları [33, 34]; soğutma sistemleri [35]. Bunlar bir ailenin ihtiyaçlarını karşılayabilir ve sürdürülebilir bir gelecek sağlayabilir [36].

Güneş termal tabanlı teknolojiler, birçok ülkede sıcak su üretmek için yaygın olarak kullanılmaktadır [37,38]. Ev uygulamaları için hibrit yenilenebilir enerji sistemleri de önem arz etmektedir. Bu uygulamalara fotovoltaiik ve termal teknolojiler tarafından tasarlanmış hibrit güneş ocakları örnek gösterilebilir [39].

Bir ailenin elektrik tüketimini en aza indirmek ve tek aileli müstakil bir evin enerji talebini karşılamak için YEK uygulamaları (güneş ve biyokütle) kullanılmaktadır [40,41]. Etkili bir şekilde güneş enerjisinden elektrik üretmek için güneş radyasyonu tahmini yapan yapay sinir ağının [42-44] kullanımı konusunda geniş miktarda literatür mevcuttur. Güneş ocakları, su ısıtıcıları, klimalar ve kurutucular dahil olmak üzere tüm bu araçlar, gelişmekte olan ülkelerde potansiyel enerji tasarrufu araçlarıdır. Bir rapor [45], 2015 yılında Bangladeş'in güneş enerjisi ev sistemlerinin kullanımı için en üst sırada yer aldığını göstermektedir. Hane halklarının enerji tüketiminin yapıldığı bir analizde [34], toplam hane halkı enerji tüketiminin bir güneş enerjili su ısıtıcısı ile yaklaşık % 13 oranında azaltılabileceğini ortaya koymuştur. Evler için uygulanan fotovoltaiik enerji sistemleri gelişmekte olan ülkelerde evsel enerji yoksunluğuna çözüm sağlamak için kullanılmaktadır [46].

Bu yenilenebilir kaynaklar sağlık için güvenli ve aynı zamanda ucuz olarak kabul edildiğinden ev tipi kullanımlarda halka ekstra bir motivasyon sağlar. YEK ev tipi kullanımlarda çeşitlilik gösterir. Örneğin, YEK (güneş), güneş kurutucular, güneş ocakları, güneş soğutma, güneş ısıtıcıları, soğutma sistemleri ve elektrik üretimi için

kullanılır. Benzer şekilde, rüzgar enerjisi; yel değirmenleri, su pompaları ve rüzgar jeneratörleri için kullanılır; biyokütle ise ısı ve enerji üretimi için kullanılır. Şekil 1.5, 2007-2017 döneminde güneş enerjili ısıtma kolektörlerinin küresel kapasitesini göstermektedir.



Şekil 1.5 : 2007-2017 arasında güneş termal kolektörlerin küresel kapasitesi.

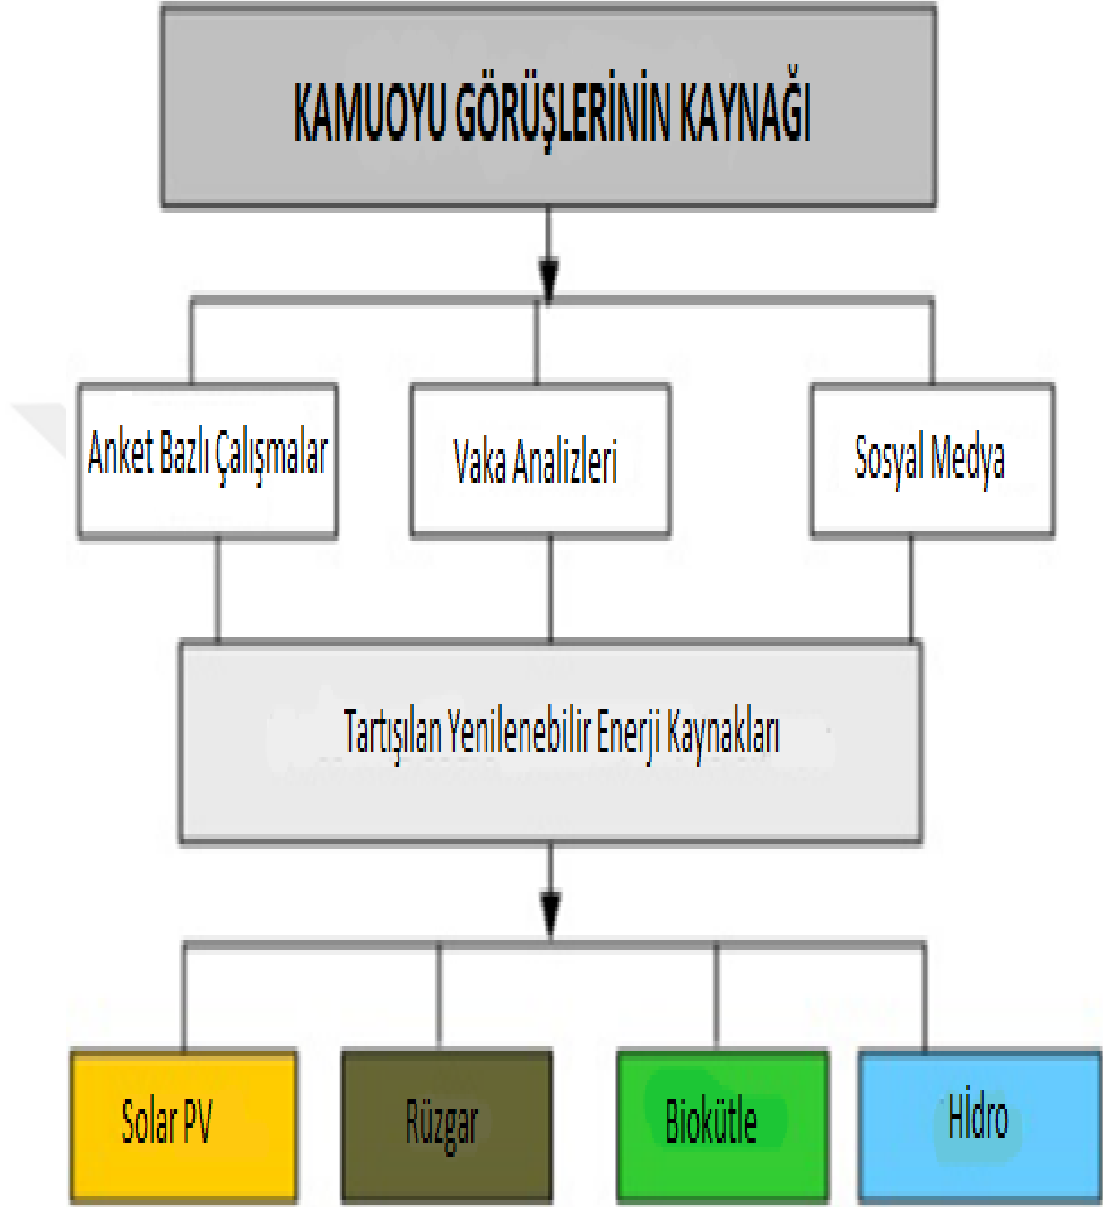
1.1.3. Yenilenebilir Enerji Hakkında Kamuoyu Görüşleri

Halkın temiz enerji kaynakları üzerindeki kabulünü artırmak için YET ve YEK farkındalığı çok önemlidir [18, 47]. YEK'in kabulünü artırmak ve küresel ısınmanın kritik sorunlarından (fosil yakıtların sağladığı enerji nedeniyle) kaçınmak için YEK'e yönelik kamuoyunun analizi hayati önem taşımaktadır [48]. Bu durumda, YE çevreyi temiz tutmak için iyi bir alternatiftir [49]. Türkiye'de ortaokul öğrencileri arasında YE tabanlı sistemlere olan ilgilerini belirlemek için bir anket yapılmıştır. Öğrencilerin

büyük çoğunluğu elektrik üretmek için YEK olarak güneş ve rüzgar santrallerine aşına olduğu ortaya çıkmıştır. Bu öğrencilerin küresel ısınma sorununun farkında olmakla beraber YE'nin kullanımının küresel ısınmayı azaltacağını düşünmekte oldukları ortaya çıkmıştır [50]. Halkın YET kullanımı hakkındaki görüşü Portekiz'de yapılan bir anket çalışması ile elde edilmiştir [51]. Portekizlilerin ülkelerinde daha fazla YE projesinin geliştirilmesini genel olarak destekledikleri, ancak tüm YEK'lere aşına olmadıkları görülmüştür. Gelişmekte olan ülkeler arasında, Malezya sürdürülebilir bir çevreye ulaşılmasına ve iklim değişikliğinin azaltılmasına önemli katkıda bulunmaktadır. Bununla birlikte, kantitatif analize dayanarak, Yarımada Malezya'sındaki kişilerin YET kullanımına karşı olumsuz bir tutuma sahip oldukları görülmüştür [24]. Yerellerin rüzgar santralleri gibi yenilenebilir enerji projeleri konusunda isteksiz oldukları durumlar vardır. Japonya'da yapılan bir vaka çalışması, sessiz yerel katılımcıların arka bahçelerinde rüzgar santrallerine izin vermek istemediklerini ortaya koymuştur [52]. Çin, dünyanın en büyük sera gazı salıcısıdır ve Çinliler, iklim değişikliğini durdurmaya yönelik küresel çabaların büyük ölçüde Çin politikalarına bağlı olduğunun farkındadır. 2086 Çinli internet kullanıcısı arasında bir anket yapılmış ve büyük destek alınmıştır [53]. Massachusetts'te açık deniz rüzgar enerjisi için bir projenin kurulmasına ilişkin kamuoyu araştırması destekleyici nitelikteydi [54]. Kanada toplumlarındaki enerji planlarından 10'unun analizi, toplulukların enerji verimliliğini artırmaya odaklanan politikaları ve programları seçtiğini ve YE'nin çok daha az dikkat çektiğinden söz etmektedir [55]. ABD, Maine eyaletinde yaşayanların rastgele bir örnekleme dayanan bir araştırma, belirli YEK tiplerini tercih ettiklerini bulmuştur [56].

Malezya'daki iklim değişikliği ve YE ile ilgili kamuoyu analizleri, Malezyalıların çoğunluğunun YE hakkında yeterince bilgi sahibi olduklarını ve iklim değişikliği ile gerçekten ilgili olduklarını kanıtlamıştır [57]. Bununla birlikte, YE'nin maliyeti YET teknolojilerinin kabulü için önemli bir engeldir. Çalışma [58] sonuçları, YEK kaynaklarının genişletilmesi politikasında Kore halkının kabul edilebilirlik düzeyinin yüksek olduğunu ortaya koymuştur. Bununla birlikte, katılımcıların eğitim düzeyinin YEK artışının tercih edilmesi üzerinde önemli bir etkisi olmuştur. Halkın YET kabulü algılarının analizinde, çalışma [59] eğitimin özellikle ekonomik, çevresel ve sosyal algıları haklı çıkarmak için uygun olduğunu ve bunların teknolojinin kabulü için önemli değişkenler olduğunu ortaya koymuştur.

Şekil 1.6'de kamuoyu görüşlerinin kaynakları ve bu inceleme çalışmasında kamuoyunun tartıştığı YE kaynakları açıklanmaktadır[8].



Şekil 1.6 : Kamuoyu görüşlerinin kaynağı ve tartışılan YEK'ler.

Çizelge 1.1, halkın YEK ve YET'in kabulü hakkındaki görüşlerini özetleyen gözden geçirilmiş çalışmalardan elde edilen sonuçları içermektedir. Çizelge 1.2'de popüler kaynaklar, çıkar politikaları, gürültü, ses, bilgi ve farkındalık eksikliği, ekonomik koşullar, demografik yapı, ve iklim koşulları gibi YE'nin yaygınlaşması ve kabul edilebilirliği karşısına sıkça çıkan engeller vurgulanmaktadır [8].

Çizelge 1.1: Kamuoyu görüşleri özetleri.

Ülke	Veri Toplama Metodu	Kaynak Tipi	Görüş	Kamuoyu Görüşü Işığında Karşılaştırmalı Analiz ve Ortaya Konulan Gerçekler
Türkiye	Genel Anket	YEK ve Enerji Santralleri	Destekleyici	Farkındalık Yüksek ve YET'in faydaları kabulünü artırır.
Portekiz	Genel Anket	Hidro,rüzgar, biokütle ve güneş	Destekleyici	Hidro, rüzgar ve güneş; biokütle ile kıyaslandığında daha çok teşvik edilir.
Malezya	Genel Anket	YEK ve YET	Karşıt Görüş	Algılanan kullanılıl ve kullanım kolaylığı YET kullanımını açısından önemlidir.
Japonya	Genel Anket	Rüzgar Tarlaları	Kısmen Destekleyici	Rüzgar tarlasına karşı ıkan yerelleri teşvik etmek için fikir birliği oluşturulmalıdır.
Çin	Online Anket	YEK	Destekleyici	Hava kirliliğini azaltmak, sera gazı emisyonlarını azaltmak, ülkenin gelişimi için YE kabul görmektedir.
Kanada	Vaka Analizi	Bio-yakıt, rüzgar,solar termal, PV	Kısmen Destekleyici	Daha küçük ve uzak toplulukların YET konusunda teşviği daha olasıdır.
Massachusetts	Telefon Röportajı ve online anket	Açık Deniz rüzgar	Destekleyici	Fosil yakıtların zarar ve açık deniz rüzgar enerjisinin faydaları YEK hususunda kabulü artırır.
ABD	Genel Anket	YE ve enerji verimliliği	Kısmen Destekleyici	Enerji kaynağı türü, sosyo-demografik ve kişisel özelliklere bağlı olarak kabul edilmektedir.
Almanya	Genel Anket	Rüzgar Tarlaları	Destekleyici	Rüzgar çifliği kabulü katılımcıların cinsiyetlerine, gelirlerine, eğitim düzeylerine, sahilleri ziyaret sıklığına ve kara tabanlı türbinleri deneyimine bağlıdır.
Yunanistan	Online Anket	Rüzgar Tarlaları	Kısmen Destekleyici	Rüzgar tarlaları ile kamu refah politikaları birlikteliğinde YET kabulünde daha etkili bir yaklaşımdır.
Hollanda	Vaka Analizi	Akıllı Biokütle	Karşıt Görüş	Akıllı biokütle kullanımı daha çok firmalar arası güven konusunda daha açıktır.
Finlandiya	Varsayımsal Tercih	Rüzgar Trübini ve Güneş Panelleri	Kısmen Destekleyici	YET'ler hakkındaki bilgi artışı, YET'lerin evde kullanımını artırabilir.
Güney Afrika	Anket	YET güneş termal su ısıtıcısı	Kısmen Destekleyici	Eğitim ve maddi olarak indirim programları gerekmektedir.
Portekiz	Anket	YET	Kısmen Destekleyici	Aşinalık ve ilgi mevcut. Çevresel etkileri bilinmektedir.

Çizelge 1.2 (devam): Kamuoyu görüşleri özetleri.

Ülke	Veri Toplama Metodu	Kaynak Tipi	Görüş	Kamuoyu Görüşü Işığında Karşılaştırmalı Analiz ve Ortaya Konulan Gerçekler
Malezya	Anket	YEK, YET ve iklim değişikliği	Destekleyici	Yenilenebilir enerji ürünlerinin yüksek fiyatı, hükümet politikaları hakkında bilgi eksikliği, etkisiz programlar YEK & YET'in önündeki engellerdir
Güney Kore	Anket	YEK	Kısmen Destekleyici	Hükümetin; halkın YEK kabulünü dikkate alırken eşzamanlı olarak artan elektrik faturası zamlarını takip etmesi gerekiyor.
Portekiz	Anket	Hidro, rüzgar, biokütle, güneş	Destekleyici	Riske karşı eğitim ve tutum, YET kabulü için önemlidir
Katar	Anket ve Röportaj	YEK	Kısmen Destekleyici	Halkı yenilenebilir enerjinin verimliliği konusunda eğitmek için gereklidir.
Fransa, Almanya ve İsviçre Yukarı Ren Bölgesi	Anket	YET	Destekleyici	Politika yapıcılar halkın kabulü için potansiyel sonuçların farkında olmalıdır.

Çizelge 1.3 : Yenilenebilir enerjinin yaygınlaşmasında karşılaşılan engeller.

Çalışma	Popüler Kaynaklar	Çıkar Politikaları	Gürültü	Bilgi ve Farkındalık Eksikliği	Ekonomik Koşullar	Demografik Yapı	İklim Koşulları
[50]	×	✓	×	✓	×	×	×
[51]	×	×	×	×	✓	✓	×
[57]	×	✓	×	✓	×	×	×
[52]	✓	×	✓	✓	×	×	×
[23]	✓	×	×	✓	×	×	✓
[54]	×	×	×	✓	×	✓	×
[55]	×	×	✓	✓	✓	×	×
[56]	×	✓	×	✓	×	×	×
[60]	✓	×	✓	×	×	×	×
[61]	✓	×	✓	×	✓	✓	✓
[62]	✓	×	×	✓	×	×	✓
[63]	×	×	✓	×	✓	×	×
[64]	×	✓	×	✓	×	✓	×
[65]	✓	×	×	✓	×	✓	✓

Çizelge 1.4 (devam): Yenilenebilir enerjinin yaygınlaşmasında karşılaşılan engeller.

Çalışma	Popüler Kaynaklar	Çıkar Politikaları	Gürültü	Bilgi ve Farkındalık Eksikliği	Ekonomik Koşullar	Demografik Yapı	İklim Koşulları
[57]	×	✓	×	✓	✓	×	×
[58]	×	×	×	✓	✓	×	×
[59]	×	×	×	×	×	×	×
[36]	×	×	×	✓	×	×	×
[66]	×	✓	×	✓	×	×	×

1.2. Tezin Amacı

Bir PV panelin modül sıcaklığı, o panelin elektrik üretim verimini önemli ölçüde etkiler. Sıcaklık artışı elektrik enerjisi üretiminin düşmesine neden olur. Modül sıcaklığının doğru tahmini, fotovoltaik sistemlerin ekonomik ve enerji değerlendirmesinde önemli bir rol oynar. Bu tezin temel amacı, fotovoltaik panellerin modül sıcaklığını; güneş ışınımı, rüzgar hızı ve ortam sıcaklığı değişkenlerine bağlı olarak farklı yöntemlerle tahmin etmek ve doğrulamaktır. Toplam dört yöntem ile sıcaklık saptamalarını değerlendirmek için Hatay ilinde bulunan bir güneş enerjisi santralinden gerçek veriler kullanılarak incelenmiştir. Yöntemlerin performansları ayrı ayrı incelenerek hangi yöntemin sahadan toplanan verilere en az hata ile ulaştığının ortaya konulması ve yarı-ampirik denklemler yerine yapay sinir ağlarının kullanılıp kullanılmayacağıın tespiti amaçlanmıştır.

1.3. Literatür Araştırması

Literatürde yapılan çalışmalar incelendiğinde, Eduardo ve arkadaşlarının yaptığı ‘Şebekeye Bağlı Fotovoltaik Sistemde Atmosferik Parametrelere Bağlı Olarak Hücre Sıcaklığının Tahmini İçin Yeni Bir Yöntem’ isimli çalışmada [67] fotovoltaik sistemlerin çalışma hücresi sıcaklığı, performanslarını ve güvenilirliklerini değerlendirirken çok önemli bir parametre olduğunu ayrıca hücre sıcaklığının doğrudan ölçümünün çok karmaşık olduğunu ve genellikle farklı dolaylı yöntemler kullanılarak elde edildiğini belirtmişlerdir. Yapılan bu çalışmada atmosferik parametrelerin mevcut bulunması durumunda hücre sıcaklığını tahmin etmek için belirli avantajların bulunduğu belirtilmiştir. Bu amaca ulaşmak için iki farklı yöntem ortaya koyulmaktadır: Birinci yöntem olarak basit matematiksel ilişkilere dayalı, ikinci yöntem ise yapay zeka tekniklerine dayandırılmıştır. Bu yöntemler

uygulandıktan sonra alınan sonuçlar, bir invertöre bađlı modülün sıcaklıđını tahmin ederken her iki yöntemin normalleştirilmiř bir kök ortalama kare hatası % 3,3'ün altında veya buna eřit, mutlak bir kök ortalama kare hatası 2 °C'nin altında veya buna eřit düřük bir hata payına sahip olduđunu göstermektedir. Ortalama mutlak hata 1,5 °C'den düřük veya eřittir ve ortalama sapma hatasının ve ortalama bađlı hatanın neredeyse % 0'a eřit olduđu ortaya koyulmuřtur.

Eduardo ve arkadaşlarının yaptıđı “Gerçek alıřma kořulları altında bir HCPV modülünün maksimum gü noktasında hücre sıcaklıđını tahmin etmek için bir yöntem” isimli alıřmada bir HCPV modülünün veya sisteminin hücre sıcaklıđının, verimi ve güvenilirliđi dođrudan etkilediđi için önemli bir faktör olduđu belirtilmiřtir. Bu nedenle, bir HCPV modülündeki hücre sıcaklıđının dođru tahmini ok önemlidir. Gerçek alıřma kořullarında, HCPV modülleri bir invertöre bađlı oldukları için maksimum gü noktasında alıřır. Maksimum gü noktasında, hücre sıcaklıđı açık devrenin hücre sıcaklıđından daha düřüktür, ünkü güneř pilleri ısıya dönüřmeyen enerji üretir. řu anda, mevcut yöntemlerin hibiri bir invertöre bađlı bir HCPV modülünün alıřma hücresi sıcaklıđını tahmin etmek için geçerli deđildir. Bu makalede, bu sıcaklıđı tahmin etmek için bir prosedür sunulmuřtur. Sonuçlar, önerilen yöntemin bir eviriciye bađlı bir HCPV modülündeki hücre sıcaklıđının tahmininde etkili bir řekilde performans gösterdiđini gösterir. Ek olarak, bir HCPV'de açık devrenin hücre sıcaklıđı ile maksimum gü noktasındaki hücre sıcaklıđı arasındaki farkın bir analizi yapılır ve 21 °C 'ye kadar bir fark bulunmuřtur[68].

Ghias ve arkadaşlarının ortaya koyduđu bir diđer alıřma, bir fotovoltaiik (PV) modülünün alıřma sıcaklıđını basit diyot modelini kullanarak tahmin etmek için etkili yeni bir yaklařım ihtiva etmektedir. Geliřtirilen yöntem basittir ve herhangi bir ek donanıma ihtiyaç duymaz. Önerilen yaklařım, sıcaklıđı maksimum gü noktası voltajı ve akımından elde etmek için analitik bir formül kullanır. Sıcaklık tahmini PV modülünün modeline dayandıđından, ilk önce model açıklanır. Modelde, sıcaklık katsayılarının etkileri dikkate alınmıřtır. Ayrıca, bir PV modül modelinin tüm parametrelerini bulmak için yeni bir yaklařım açıklanmaktadır. Diđer yöntemlerden farklı olarak, burada önerilen parametrelerin ıkarma yöntemi yalnızca üretimden kaynaklı özellikleri içeren katalogdan üretici verilerine ihtiyaç duyar ve ek bilgiye ihtiyaç duymaz. Yeni sıcaklık tahmini prosedürünün etkinliđi, MATLAB / Simulink

ortamında gerçekleştirilen bazı simülasyonlarla araştırılmış ve geçerliliği REC-AE220 güneş modülündeki deney ile doğrulanmıştır [69].

Ghias ve arkadaşlarının yaptığı “Güneş Pilleri için Yeni Bir Sıcaklık Tahmin Yöntemi” isimli başka bir çalışmada, bir fotovoltaik (PV) modülünün çalışma sıcaklığını tahmin etmek için etkili bir yaklaşım sunulmaktadır. Geliştirilen yöntem basittir ve herhangi bir ek donanıma ihtiyaç duymaz. Önerilen yaklaşım, sıcaklığı maksimum güç noktası (MPP) voltajından ve akımından türetmek için analitik bir formül kullanır. Yeni yöntemin etkinliği MATLAB / Simulink ortamında gerçekleştirilen bazı simülasyonlarla araştırılmış ve geçerliliği REC-AE220 güneş modülleri üzerinde yapılan deneylerle doğrulanmıştır [70].

Kensuke ve arkadaşları “Gerçek çevre koşullarında çalışan fotovoltaik modülde güneş pili sıcaklığının doğru ölçümü ve tahmini” isimli çalışmalarında düşük maliyetli yerinde performans ölçümü, izleme ve arıza teşhisi için fotovoltaik (PV) modüllerin hassas dış mekan performans ölçümüne artan bir ihtiyaç var olduğunun altını çizmişlerdir. Bir PV modülünün kesin değerlendirmesi için doğru bir sıcaklık ölçüm tekniği gereklidir. Güneş pili sıcaklığının bir modül yapısında (eklem sıcaklığı) ölçülmesi gereklidir, çünkü arka tabakanın sıcaklığı yerine PV modülünün sıcaklık özelliklerini belirler. Bu çalışmada, dahili termokupllu bir PV modülü imal edilmiştir. Güneş hücresinin hemen altına bir ısı çift yerleştirildi, böylece hücre ile doğrudan temas edebildi ve doğru bir sıcaklık ölçümü sağlandı. Ayrıca, PV modülü yapısındaki güneş pilinin sıcaklığı, kolayca ölçülebilen alt tabaka sıcaklığı kullanılarak ısı akısı hesaplaması ile tahmin edilmiştir. Bu şekilde, güneş pili sıcaklığının $+1^{\circ}\text{C}$ 'lik bir hata içinde doğru olarak tahmin edildiğinden söz edilmiştir [71].

Mohamed ve arkadaşlarının gerçekleştirdiği “Malezya'nın tropik iklimi için yapay sinir ağı tabanlı fotovoltaik modül sıcaklık tahmini ve fotovoltaik sistem enerji verimi üzerindeki etkisi” isimli çalışmalarında, meteorolojik değişkenler kullanarak fotovoltaik (PV) modül sıcaklığını tahmin etmek için yapay sinir ağı (YSA) tabanlı bir yaklaşım sunulmaktadır. Önerilen yaklaşım, girdi değişkenleri olarak ortam sıcaklığı T_a , güneş ışınımı G , bağıl nem RH ve rüzgar hızı W gibi çeşitli meteorolojik parametrelerin gerçek saatlik kayıtlarını kullanır. Saatlik meteorolojik veriler, 2009 yılında 9 ay boyunca Malezya'nın Selangor kentindeki 92 kWp kurulu PV sisteminden toplandı. Veriler iki gruba ayrıldı: 1849 (Nisan-Ekim) saatlik verilerden oluşan eğitim verileri ve test verileri olarak çalışılan 578 (Kasım-Aralık) saatlik kayıtlar. Giriş olarak

farklı meteorolojik parametrelerin kombinasyonu kullanılarak dört YSA modeli geliştirilmiştir ve her model için PV modülü çıkış sıcaklığı T_m 'dir. RH ve W'ler dahil olmak üzere tüm parametreleri girdi olarak kullanan modelin, MBE, RMSE ve MPE için sırasıyla korelasyon katsayısı (r) % 95.9 ve % 0.41, 0.1 ve 4.5 ile en doğru sonuçları verdiği bulunmuştur. Geliştirilen YSA modelinin üstünlüğünü ve uygulanabilirliğini göstermek için, önerilen YSA modelinden elde edilen sonuçlar Malezya Enerji Merkezi tarafından kabul edilen geleneksel model ve regresyona dayalı bir başka matematik model ile karşılaştırılmıştır. Modelin sadeliği ile önerilen yaklaşım, doğrudan veya ölçüm ekipmanı bulunmayan uzak veya kırsal yerlerde, her tür PV sistemi için PV modül sıcaklığını tahmin etmek için etkili bir araç olarak kullanılabilir olduğu kanısına varılmıştır. Geliştirilen model aynı zamanda PV sistem performansını incelemekte ve enerji çıktısını tahmin etmede çok faydalı olacağı öngörüsüne ulaşılmıştır [72].

Eduardo ve arkadaşlarının literatüre kattığı “Voc kullanarak bir HCPV Modülünde Hücre Sıcaklığının Hesaplanması” isimli çalışmada güneş hücresi çalışma sıcaklığı bilgisi, bir HCPV modülünün enerji performansını değerlendirmek için önemlidir. Bununla birlikte, HCPV modüllerindeki hücre sıcaklığının ölçümü, bu tür modüllerin özel özelliklerinden dolayı çok karmaşık bir görevdir, bu nedenle bunu hesaplamak için dolaylı yöntemler bulmak yararlıdır. İspanya'nın güneyinde bulunan Jaen Üniversitesi'nin Enerji ve Çevre İleri Araştırmalar Merkezi'nde DNI, hücre sıcaklığı ve I-V eğrileri bir yıl boyunca ölçülmüştür. Bu ölçümler sayesinde, hücre sıcaklığı Voc'nin bir fonksiyonu olarak ortalama % -0.38 göreceli hata ile belirlenebilir [73].

Fotovoltaik hücrelerin sıcaklıklarını tahmin etmek için katkı sağlayan bir başka çalışmada, hücre sıcaklığı farklı yöntemler kullanarak hesaplanmaktadır. Bir HCPV modülünün hücre sıcaklığını tahmin etmek için kullanılan dört yöntem, IEC 60904-5 yöntemi, Fotovoltaik Sistemler Enstitüsü tarafından önerilen termal dirence dayalı bir yöntem, analitik yöntem ve yapay sinir ağları yöntemi dahil karşılaştırmalı bir çalışma yapıldığı belirtiliyor. Her bir yöntemle hücre sıcaklığını tahmin etmek için gereken tam prosedürler, parametreler ve katsayılar sağlanır. Sonuçlar, HCPV modülünün doğrudan ölçümlerine dayanan yöntemlerin, atmosferik parametrelere dayalı yöntemlerden daha iyi performans gösterdiğini gösterdiği ortaya konulmuştur. Bununla birlikte, incelenen yöntemlerin tümü, kabul edilebilir bir hata payı ile hücre sıcaklıklarını tahmin etmek için kullanılabilir olduğu görüşü savunulmaktadır [74].

Malezya gibi tropikal iklimlerde poli ve mono kristal teknolojiler için PV modül sıcaklığının tahmin edilmesine yönelik bir araştırma ortaya koyan Mohamed ve arkadaşları yeni matematiksel modeller önermektedir. Geliştirilen modeller, ölçülen saatlik küresel güneş radyasyonu, ortam sıcaklığı, bağıl nem, rüzgar hızı ve modül sıcaklığına dayanmaktadır. Tüm veriler 2009 yılında Malezya Selangor'da kurulu GreenTech 92 kWp PV sisteminde toplandı. Modeller r , MBE, RMSE ve MPE kullanılarak karşılaştırılmıştır. Sonuçlar, önerilen modellerin en yüksek korelasyon katsayısı r değerini ve istatistiksel göstergeleri, yani düşük RMSE, düşük MBE ve düşük MPE değerlerini dikkate alırken iyi bir sonuç verdiğini göstermiştir. Sonuçlar, önerilen regresyon modellerinin saatlik ve günlük ortalama PV modülü sıcaklığının hesaplanması için geleneksel yaklaşımlara göre avantajlara sahip olduğunu ve gerçek ölçümlere kıyasla en yakın sonuçları verdiğini göstermektedir. Önerilen yaklaşımlar, basit bir PV modülü, açık raf sistemi, BIPV kurulumları, hatta doğrudan ölçüm ekipmanı olmayan uzak ve kırsal yerlerde PV modülü sıcaklığını tahmin etmek için etkili araçlar olarak kullanılabilir. Önerilen modeller PV sistemi performansını incelemek ve enerji çıktısını tahmin etmek için çok yararlı olabilir [75].

Güneş enerjisi santrallerinin izleme sistemleri için uzaktan erişim talepleri artmakta olduğu gerçeğini öne sürerek yapılan bir çalışmada mega güneş enerjisi santrallerinde (MSPP'ler) hatalı modülleri otomatik olarak tespit eden bir izleme sistemi kurmayı hedefliyoruz. Sistem, elektrik santrallerinde dizi güçleri veya güneş ışınları gibi nispeten kolay bir şekilde elde edilebilen ölçülen verileri kullanır. Güneş ışınları, hücrede üretilen gücün büyüklüğünü belirleyen en önemli faktördür ve hücre sıcaklıkları en önemli ikinci faktördür. Bununla birlikte, hücre sıcaklıkları genellikle doğrudan elektrik santrallerinde ölçülmez. Bu makalede, günümüzde en yaygın olan kristalin silikon güneş pillerinin sıcaklığını, güçleri nispeten kolay ölçülebilen hücre güçleri, güneş ışınları atmosfer sıcaklığı ve rüzgar hızları gibi ölçülen verileri kullanarak tahmin etmek için yeni bir yöntem önerilmektedir. Yöntemimizi Japonya'daki Yoshinogari MSPP'de gerçekten ölçülen modüllerin tahmini hücre sıcaklıklarını ve yüzey sıcaklıklarını karşılaştırarak da değerlendirme yapıldığı belirtilmektedir [76].

“Yapay Sinir Ağları ile PV Modül Yüzey Sıcaklığının Tahmini” isimli çalışmada, bir fotovoltaik (PV) panelin yüzey sıcaklığını tahmin etmek için yapay sinir ağı (YSA) yönteminin kullanılması amaçlanmıştır. Deneysel olarak elde edilen PV verileri

kullanılarak YSA modelinin doğruluğu değerlendirilmiştir. Yapay sinir ağını (YSA) eğitmek için dış sıcaklık güneş radyasyonu ve rüzgar hızı değerleri girdi, yüzey sıcaklığı ise çıktıdır. YSA, PV panel yüzey sıcaklığını tahmin etmek için kullanılmıştır. Levenberg-Marquardt (LM) algoritması kullanılarak, ileri beslemeli yapay sinir ağı eğitilmiştir. İki geri yayılım tipi YSA algoritması kullanılmıştır ve performansları, LM algoritmasından elde edilen tahmin ile karşılaştırılmıştır. Yapay sinir ağını eğitmek için deneysel veriler üçte ikisi için, geri kalan üçüncüsü de test için kullanılmıştır. Ayrıca LM algoritması ile karşılaştırmak için ölçekli konjüge gradyanı (SCG) geri yayılımı ve esnek geri yayılım (RB) tipi YSA algoritmaları kullanılmıştır. Bu üç yapay sinir ağının performansı karşılaştırılmış ve % 0.005962 ile % 0.012177 arasında ortalama hata oranları elde edilmiştir. En iyi tahmin LM algoritması ile üretilmiştir. PV yüzey sıcaklığının yapay sinir ağları ile hesaplanması geleneksel korelasyon yöntemlerinden daha iyi sonuç verir. Bu çalışma, yapay sinir ağlarının PV yüzey sıcaklığını tahmin etmek için etkili bir şekilde kullanılabileceği ortaya konulmuştur [77].

Ortaya konulan başka bir çalışmada modül sıcaklığının Nominal Çalışma Hücresi Sıcaklığından (NOCT) simülasyonu, yıl boyunca modül performansını kolayca tahmin etmek için yaygın olarak kullanıldığından söz edilmektedir. Bu bağlamda, farklı modül tasarımlarının performansını karşılaştırmak için kullanıldığından ve sistem tahminlerini etkileyebileceğinden, bu parametreyi güvenilir bir şekilde belirlemek önemlidir. Şu anda, kristalli ve ince film karasal fotovoltaik modüllerde NOCT'yi hesaplama yöntemini gösteren birkaç uluslararası standart vardır. Bu çalışma, bu standartları cam-cam ve cam-tedlar yapılar, kristalin ve ince film teknolojileri ve bina entegrasyon uygulamaları için bazı özel modül tasarımları dahil olmak üzere farklı PV modüllerine uygularken elde edilen sonuçları sunar. Bu şekilde hesaplanan NOCT değerleri, farklı tahminler ve eğik açılar için yıllık modül sıcaklığını ve performansını tahmin etmek, bu tahminlerdeki sıcaklık etkisini analiz etmek için kullanılmıştır. Hatalı NOCT değerlerine yol açabilecek olası hata kaynakları da analiz edilir [78].

Yanping ve arkadaşları “Fotovoltaik panel sıcaklığının gerçekçi senaryolarda değerlendirilmesi” isimli çalışmalarında Fotovoltaik (PV) panel sıcaklığı, gerçekçi senaryolarda kullanılabilecek teorik modeller geliştirilerek değerlendirildi. Güneş ışınımı, rüzgar hızı ve ortam sıcaklığının PV panel sıcaklığı üzerindeki etkileri incelenmiştir. Parametrik çalışma güneş ışınımı ve rüzgar hızının PV panel sıcaklığı

üzerinde önemli bir etkisi olduğunu göstermektedir. Ortam sıcaklığının artmasıyla, güneş hücrelerinin sıcaklık artışı azalır. Gerçekçi senaryolarda panel sıcaklığının özellikleri analiz edildi. Kararlı hava koşullarında, 100-500 lm Si kalınlığında bir güneş hücresinin termal tepki süresi yaklaşık 50–250 s'dir. Gerçekçi senaryolarda iken, bir gün içindeki panel sıcaklık değişimi, termal histerezinin etkisi nedeniyle sabit hava koşullarından farklıdır. Fotovoltaik verim üzerindeki ısıtma etkisi, gerçekçi hava koşullarında güneş hücrelerinin gerçek zamanlı sıcaklık ölçümüne dayanılarak değerlendirildi. Sıcaklık katsayısı % 0.21 - % 0.50 aralığında olan güneş hücreleri için, mevcut saha testleri % 2.9 ila % 9.0 arasında yaklaşık bir verimlilik kaybı gösterdiği belirtilmektedir [79].

Hücre sıcaklığını tahmin etmek için yapılan başka bir çalışmada bir fotovoltaik modülün sıcaklığı, performansının doğru değerlendirilmesi için anahtar bir parametre olduğundan bahsedilmektedir. Gerçek ölçümlerin mevcut olmadığı durumlarda, modülün sıcaklığını tahmin etmek için bir dizi farklı model kullanılabilir. Bu tür yedi ilişki deneysel verilere göre uygulanır ve değerlendirilir. Karşılaştırmalar, artıkların minimum yarı genişliği maksimum 2.2 °C olan bir Gauss dağılımı ile açıklanabileceğini göstermektedir. Basit bir ısı transfer modelinin uygulanması da benzer belirsizlikler ile sonuçlanır (2.1-2.2 °C). İlişkilerin basitliği, ilgili fiziğin karmaşıklığı (ısı transfer katsayılarındaki belirsizlikler, geçici fenomenler) göz önüne alındığında, bu doğruluğun genellikle tatmin edici olduğu düşünülmektedir. Modül sıcaklığını belirlemenin daha güvenilir bir yolu, bu tek değer ideal olarak tüm hücrelerin ortalama sıcaklığı hakkında bilgi sağladığı açık devre voltaj yöntemini kullanmaktır. EN 60904-5 standardını kullanan bu yöntemin uygulanması kolay değildir ve doğruluk çeşitli parametrelerin belirsizlikleri ile sınırlıdır. Özellikle, termal voltajın belirlenmesindeki deneysel belirsizlik, diyot kalite faktörü tam olarak bilinmediği takdirde modül performansını karakterize eden parametrelerin belirlenmesinde önemli bir belirsizlik kaynağı haline gelir. Hücre sıcaklığının belirlenmesi, referans koşullarda açık devre voltajı, sıcaklıktaki değişim hızı ve diyot kalite faktörü gibi gerekli parametrelerin doğruluğunun analizi, sıcaklık kontrollü bir ortamda bir dizi ölçümün hedefine ulaşmak için 1 °C veya daha düşük bir hata ile kullanılabilmesini göstermektedir [80].

Karmaşık hesaplamalara ihtiyaç olmaksızın ortaya koyulan bir diğer çalışmada Fotovoltaik (PV) modüllerin çalışma hücre sıcaklıkları doğrudan PV sisteminin

performansını etkilediği belirtilmiştir. Bu çalışmada, bir fotovoltaik modülün çalışma sıcaklığını tahmin etmek için etkili yeni bir yaklaşım sunulmuştur. Geliştirilen model basittir ve karmaşık hesaplamalara gerek yoktur. Önerilen yaklaşım, PV hücre sıcaklığını ortam sıcaklığı, ışınım ve rüzgar hızı gibi çevresel değişkenlerden türetmek için basit bir formül kullanır. Yeni sıcaklık tahmin prosedürünün etkinliği MATLAB / Simulink ortamında gerçekleştirilen bazı simülasyonlarla araştırılmış ve geçerliliği UNI-SOLAR US-64 güneş fotovoltaik modülleri üzerinde yapılan deneylerle doğrulanmıştır. Genel olarak, modelin sıcaklık tahmininde daha iyi sonuçlar verme eğiliminde olduğu bulunmuştur. Sonuçlardan, tahmin edilen PV hücre sıcaklıkları ölçülen verilerle iyi bir korelasyon gösterir. Öngörülen ve ölçülen PV hücre sıcaklıklarının MBE, NMBE, RMSE, NRMSE ve korelasyon katsayısı sırasıyla -0.3490 °C, % -0.7328, 1.3571 °C, % 2.8492 ve 0.9763'tür. İstatistiksel sonuçlar modelin, % 3'ten daha az bir hata ile PV hücre sıcaklıklarını tahmin etmek için kullanılabilirliğini göstermektedir. Sonuç olarak, PV hücre sıcaklıkları, kararlı durum yaklaşımı tahminine dayanan yeni bir doğrusal model kullanılarak tahmin edilebilir olduğu görüşünde bulunulmuştur [81].

Belli bir bölge için tahmin yapma amacı taşıyan çalışmada hava sıcaklığı ve güneş ışınımına göre fotovoltaik modül sıcaklığı tahmin edilmiştir. Bu araştırma için, deney sisteminde 10, 20, 30 ve 40 °C ortam hava sıcaklığı ve farklı güneş radyasyonları için fotovoltaik modül sıcaklıkları belirlenmiştir. Bu deneysel çalışma açık havada yapılmış ve güneş radyasyonu ölçülmüş ve daha sonra bu ölçülen veriler YSA eğitimi için kullanılmıştır. Fotovoltaik modül sıcaklıkları, Türkiye'deki Ege bölgesi için güneş radyasyonu ve dış hava sıcaklığına göre tahmin edilmiştir. Öngörülen modül sıcaklığına bağlı olarak elektrik verimliliği ve gücü de hesaplanmıştır. Kütahya, Uşak ve Afyon, Türkiye'nin Ege bölgesinde elektrik verimliliği ve fotovoltaik enerji üretimi açısından en uygun şehirlerdir [82].

Sıcaklık tahminlerinin yapıldığı bir dizi çalışmaya ek olarak verim düşürücü bir parametre olan sıcaklığın düşürülmesi de önem taşır. Ortaya konulan bir çalışmada rüzgârın PV hücre sıcaklığı üzerindeki soğutma etkisine odaklanıldı. Bolzano'daki (İtalya) bir PV test tesisinde kurulan teknolojilerin çoğu için, rüzgar verilerini içeren modellerin PV hücre sıcaklığını, rüzgar verilerini içermeyen standart yaklaşımlardan daha iyi öngördüğünü gösteriyoruz ve lineer hava tahmini modellerinden elde edilen çümlerinin yerini alabileceğini gösteriyoruz [83].



2. METOT

2.1. Regresyon Analizi

Regresyon analizi, deęişkenler arasındaki ilişkinin matematiksel bir modelle gösterilmesine dayanmaktadır. Regresyon analizi yapılırken gözlem deęerlerinden yola çıkarak, olayları matematiksel bir fonksiyon şeklinde ifade etmek amaçlanır. Sonuç olarak bu ilişkiyi incelemek amacıyla elde edilen istatistiksel yöntem Regresyon Analizi denir [84].

Bağımlı deęişken ile bir ya da birden fazla bağımsız deęişkenlerin bir araya gelmesi ve söz konusu bağımlı deęişken ve bağımsız deęişken ya da deęişkenler arasındaki ilişkiyi inceleyen analiz yöntemidir. Regresyon analizi genel olarak bir deęişken üzerinde başka bir deęişkenin etkisinin olup olmadığını araştırdığımız durumlarda tercih edilir [85]. Basit bir örnek ile açıklamak gerekir ise, bir öğrencinin başarı notu ile okula devam edip etmemesi arasındaki ilişkisinin incelendięi bir model kurulabilmektedir. Bu modelde öğrencinin başarı notu bağımlı deęişken, okula devam edip etmemesi ise bağımsız deęişkendir. Yani öğrencinin başarı notunun okula devamı ile ilişkili olup-olmadığı sorgulanmaktadır. Bir başka örnek ise bir evin fiziksel özellikleri ile satış fiyatını ilişkilendirilmek istendiğini varsayalım. Bu durumda binanın seçkin bazı fiziksel özellikleri, yani evin kullanım alanı, evin bulunduğu kat, binadaki oda sayısı vb bağımsız deęişkenleri gösterirken, evin satış fiyatı bağımlı deęişkenini ifade eder. Burada bağımlı deęişken bir yada birden fazla olabilmektedir. Tek bağımsız deęişken içeren regresyon modeline basit doğrusal regresyon birden fazla bağımsız deęişken içeren regresyon modeline de çoklu doğrusal regresyon adı verilir.

Bağımsız deęişken sayısının bir olması durumunda doğrusal regresyon modeli aşağıda bulunan denklem 2.1’de olduğu gibi ifade edilmektedir.

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad i=1,2,\dots,n \quad (2.1)$$

Denklem 2.1’de yer alan bağımsız değişken X, bağımlı değişken Y, β_0 model sabiti, β_1 bağımsız değişkenin katsayı ve ε_i ise rassal bir hatasını göstermektedir.

Model yorumlama aşamasında söz konusu değişkenler β_0 , X’e sıfır verildiğinde doğrunun Y eksenini kestiği noktayı gösterirken, β_1 ise, bağımsız değişken bir birim değiştiğinde bağımlı değişkendeki ortalama değişimi göstermektedir. Diğer bir deyişle X, 1 birim arttığında ya da azaldığında bağımlı değişkenin ne kadar değişeceğini gösterir. Bu artma veya azalma durumu X’in katsayısının değişimi ile ifade edilir.

Sosyal ve teknik bilim dallarındaki olaylar dikkate alındığında bir değişkendeki değişmelerin sadece tek bir değişkenle açıklanması yeterli değildir. Yani yukarıda verilen örnek ele alındığında bir evin satış fiyatı ile, bu satış fiyatını (Y) etkileyecek olan faktörlerin (X) ilişkisi birden fazla olabilir. Bir başka deyişle Y bağımlı değişkenindeki değişimler birden fazla X değişkeni ile açıklamaya gereksinim duyulabilmektedir.

Basit regresyondan farklı olarak çoklu regresyonda, çok sayıda bağımsız değişkenin bir bağımlı değişkeni ile nasıl ilişkilendirildiğini ve yanıt üzerinde aynı anda birden çok açıklayıcı değişkenin etkisini incelemeye olanak sağlayan bir istatistiksel araçtır.[85] Bu istatistiksel ilişki değişkenini etkileyen k tane açıklayıcı değişken içeren çoklu bir doğrusal regresyon modeli olup denklem 2.2’deki gibi ifade edilebilmektedir.

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (2.2)$$

Denklem 2.2’de verilen Çoklu regresyon denkleminin yorumlanması ise bağımsız değişkenlerin birbiri ile ilişkili olmadığı varsayımına dayanmaktadır. Söz konusu eşitliği yorumlarken basit doğrusal regresyonda olduğu gibi bir yol izlenir. Bağımsız değişkendeki bir birimlik artış veya azalış (katsayıların pozitif veya negatif olmasına göre değişir) bağımlı değişkeni, bağımsız değişkenlerin katsayısına göre yorumlanmaktadır.


Burada regresyon modeli varsayımına göre hataların ortalaması ya da beklenen değeri ($E(\varepsilon)=0$) sıfır olduğu dikkate alınır, Y’nin ortalama değeri $E(Y) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$ biçiminde yazılabilir. Bu durumda bağımsız değişkenin beklenen değeri bağımlı değişkenle ilgili fonsiyonel bir ilişkidir. Ancak bağımsız değişkenin

gerçek değeri, beklenen değerden kaynaklanan ϵ rassal hata terimine sahiptir. Hataların ilişkisiz, normal ve aynı varyansa sahip oldukları varsayılır[86].

Bağımsız değişkenler arasında yakın doğrusal bir ilişki yani bağımlılık söz konusu ise çoklu doğrusal bağlantı problemi olarak adlandırılır. Çoklu doğrusal bağlantı verinin yapısı ile ilgili bir durumdur. Çoklu bağlantı regresyon modelinde bağımsız değişkenler arasında yüksek bir korelasyon ($r \geq 0.75$) istenmeyen bir durum olup problemi fade etmektedir [87]. Varsayımlar çoklu bağlantı durumunda bozulmaktadır. Bu tarz bir durumda modelde yer alan değişkenlerin varyansı dikkat edilmesini gerektirecek boyutta artar ve bu parametreler gerçek değerinden uzak birbirinden farklı çok büyük ve zıt değerler alır. Çoklu bağlantının varlığı durumunda regresyon analizine dayalı sonuçlar güvenilirliğini kaybetmektedir.

2.2. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) (ing. Artificial Neural Networks, ANN), insan beynini oluşturan nöronlar ağına benzer bir yapı oluşturma girişimidir, böylece bilgisayarlar bir şeyler öğrenebilir ve insan gibi karar verebilir [88]. Yapay sinir ağı nöron adı verilen birçok düğümden oluşmaktadır. Şekil 2.1’de bir nöronun yapısı görülmektedir.




Şekil 2.1 : Nöronun yapısı.

Belirli bir düğüm, girdilerinin ağırlıklı toplamını alır ve bunu doğrusal olmayan bir aktivasyon fonksiyonundan geçirir. Bu, düğümün çıktısıdır ve daha sonra bir sonraki katmandaki başka bir düğümün girişi olur. İşlemler soldan sağa doğru akar ve son çıktı (y) tüm düğümler için bu prosedürün uygulanmasıyla hesaplanır. Bu derin sinir ağını eğitmek, tüm düğümlerle ilişkili ağırlıkları güncellemek anlamına gelir.

$$z = f(x \cdot w) = f\left(\sum_{i=0}^n x_i w_i\right) \quad (2.3)$$

Düğüm (nöron) denklemi denklem 2.3'teki gibidir. Burada x_n girişleri, w_n ağırlıkları, f aktivasyon fonksiyonunu, z ağırlıklandırılmış toplamının aktivasyon fonksiyonundan geçirilerek elde edilen değerini yani çıkışı (y) ve n ise düğüm için girdi sayısını ifade etmektedir.




Şekil 2.2 : Bias terimi eklenmiş nöron yapısı.

Ayrıca tüm düğümlerin girişinde bias değeri mevcuttur. Genellikle 1 olan bias değeri (b), bütün girdilerin sıfır olması durumunda bile nöronun hesaba katılmasını sağlar. Aktivasyon fonksiyonunu sağa veya sola kaydırma imkânı sağladığı için sinir ağının öğrenmesinde önemli bir yeri vardır. Bias eklenmiş nöron denklemi denklem 2.4'deki gibidir.

$$z = f(b + x \cdot w) = f(b + \sum_{i=0}^n x_i w_i) \quad (2.4)$$


Ağırlıklandırılmış toplam değeri doğrusal olmayan aktivasyon fonksiyonuna tabi tutulur ve sıklıkla kullanılan şekliyle (0,1) veya (-1,1) arasına normalize edilir [89]. Sigmoid, hiperbolik tanjant, düzeltilmiş doğrusal birim (ReLU) ve sızıntı ReLU literatürde sıklıkla kullanılan aktivasyon fonksiyonlarıdır [90].



Şekil 2.3 : Sigmoid fonksiyonu.

Aktivasyon fonksiyonu olarak sigmoid kullanıldığında işlem yükü fazla olduğundan algoritma yavaş çalışır. Ayrıca fonksiyonun uçlarında türev sifıra yakınsadığından öğrenme işlemi güçleşir. Sigmoid fonksiyonunun matematiksel ifadesi;


$$f(x) = \frac{1}{1+e^{-x}} \quad (2.5)$$



Şekil 2.4 : Hiperbolik tanjant fonksiyonu.

Hiperbolik tanjant fonksiyonunun en büyük avantajı, sigmoid fonksiyonuna göre daha geniş türevlenebilir değer aralığının olmasıdır. Hiperbolik tanjant fonksiyonunun matematiksel ifadesi;


$$f(x) = \frac{1-e^{-2x}}{1+e^{2x}} \quad (2.6)$$



Şekil 2.5 : ReLU fonksiyonu.

Literatürde sıklıkla kullanılan bir diğer aktivasyon fonksiyonu ise ReLU'dur. Hesaplama karmaşıklığı sigmoid ve hiperbolik tanjanta göre çok düşüktür bu yüzden ReLU'nun kullanıldığı algoritmalar çok daha hızlı çalışır ve çok katmanlı ağlarda sıklıkla tercih edilir. Negatif bölgede fonksiyonun değerinin sıfır olması öğrenmenin çok hızlı gerçekleşmesine olanak sağlarken bu bölgede türevinde sıfır olması bilgi kaybına dolayısıyla yeterince öğrenememeye yol açmaktadır. ReLU'nun matematiksek ifadesi;

$$f(x) = \max(0, x) \quad (2.7)$$




Şekil 2.6 : Sızıntı ReLU fonksiyonu.

ReLU fonksiyonun negatif bölgelerdeki dezavantajını ortadan kaldırmak için geliştirilmiş olan Sızıntı ReLU fonksiyonu, ReLU fonksiyonuna benzer şekilde hesaplama yükü azdır dolayısıyla hızlı öğrenme gerçekleşir. Sızıntı ReLU fonksiyonuna ait matematiksel ifade;

$$f(x) = \max(0.01x, x) \quad (2.8)$$

Nöronlar ve katmanlar kullanılarak yapay sinir ağı oluşturulur. İlk katman giriş katmanı, son katman çıkış katmanı ve aradaki katman veya katmanlar ise gizli katman olarak isimlendirilir. Çok sayıda gizli katmanın eklenmesiyle Derin Sinir Ağı Modeli oluşturulur ve karmaşık sınıflandırma problemlerinin çözümünde kullanılır. Yapay Sinir Ağları, aşağıdaki şekle benzeyen çok katmanlı tam bağlı sinir ağlarıdır.



Şekil 2.7 : Yapay Sinir Ağları Modeli.

2.2.1. İleri beslemeli sinir ağı

Her bir katmanın bir sonraki katmanı besleyerek ileri yönlü işlemlerin gerçekleştirildiği ağlara İleri Beslemeli Sinir Ağları denilmektedir [91]. Burada bilgi ağda sadece ileri yönlü hareket eder.

Bu ağ yapısı aynı zamanda Çok Katmanlı Algılayıcı (MLP) (ing. Multi Layer Perceptrons) olarak da isimlendirilmektedir. Çok katmanlı algılayıcılar, denetimli sınıflandırma için kullanılan bir tür sinir ağı mimarisidir. Adından da anlaşılacağı gibi, mimari birbiri üzerine yığılmış perceptron katmanlarından oluşur.

Katman sayısı, her katmandaki düğüm sayısı, her katmanın aktivasyon fonksiyonu tasarım parametreleri olduğundan bir MLP çok farklı konfigürasyonlarda tasarlanabilir. Katman sayısı belirlenmesinde kabul görmüş kesin bir kural yoktur. Bunlara hyper parametreler denilmektedir ve deneme yanılma yoluyla optimum değerler elde edilmektedir. Gizli katman sayısı gerektiğinden az olan yapay sinir ağları karmaşık fonksiyonların çözümünde yetersiz kalırken, çok fazla gizli katmana sahip yapay sinir ağları ise kararsızdırlar. Yine gizli katmandaki nöron sayısı da önemli bir parametredir ve optimum değerde seçilmesi sistemin başarısını doğrudan etkileyecektir [92]. Mimarideki ilk seviyeye giriş katmanı, son seviyeye çıkış katmanı denir. Gizli katmanlar aralarındaki katmanlardır ve eğer birden fazla varsa, model derin bir katman olarak kabul edilir, aksi takdirde sıg bir mimaridir. MLP'de ileri yayılma ve geri yayılma olmak üzere iki akış yönü vardır. Akış aşağıdan yukarıya doğru ise, ileri yayılma olarak adlandırılır ve ağ bu akışta bir tahmin yapar. Eğer yukarıdan aşağıya doğru ise, ağ ağırlıkları tahmin aşamasında hatalarını düzeltecek şekilde ayarlar. Bu optimizasyon aşaması, birkaç dönem için geri yayılma algoritması kullanılarak tamamlanır [93].

Giriş katmanı ağda kullanılacak olan veriyi (x_n) ifade eder. Giriş katmanında değerler üzerinde herhangi bir işlem uygulanmadığından (yani ham veriler doğrudan ağa verildiğinden) sinir ağı numaralandırılırken bu katman sayılmaz; gizli katman ve çıkış katmanı sayıları toplanır. Örneğin Şekil 7'de bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunmakta. Giriş katmanı numaralandırılırken hesaba katılmadığından şekilde gösterilen ağ üç katmanlı olarak isimlendirilmektedir. Giriş katmanındaki her bir değer bağlı olduğu noda göre ağırlıklandırılarak gizli katmandaki her bir nörona giriş yapar; gizli katmandaki nöronlar da hesaplamaların sonucunu çıkış katmanına iletir [90].

Ağırlıkları rastgele başlatan bir sinir ağı, verilerle eşleşen bir model elde edilene kadar ağırlıklar optimize edilir. Sinir ağının öğrenmesi olarak adlandırılan bu işlem bir optimizasyon problemidir. Burada amaç giriş-çıkış arasındaki ilişkinin güçlü bir şekilde modellenmesi için nöronlar arasındaki ağırlıkların (w) ve biasın (b) uygun bir şekilde ayarlanmasıdır [94]. Veri setindeki örnekler sırayla bu ağda kullanılır ve böylelikle ağırlıkların her defasında güncellenmesiyle en uygun değerler elde edilmeye çalışılır. Kısaca hatanın minimize edilebilmesi için ağırlıklar ayarlanmaya çalışılır.

Yapay sinir ağlarında öğrenme

- Denetimli
- Denetimsiz
- Takviyeli olmak üzere üç gruba ayrılır.

Bu tez çalışmasında hatanın geri yayılımı algoritması (ing. error backpropagation algorithm) yöntemi kullanılmıştır. Literatürde en dik iniş (ing. steepest descent algorithm) algoritması olarak da bilinen geri yayılım algoritması, sinir ağlarında hatanın minimize edilmesi için ortaya atılmış ilk fikirlerdendir [95]. Ancak yavaş olması ve hatayı minimize ederken yerel minimuma takılması yönleriyle dezavantajlıdır.

Optimizasyon amaca ulaşmaya yönelik bir süreçtir. Makine öğrenmesinde bu amaca kayıp fonksiyonu (ing. loss function) denir. Bu işlev, yaklaşımın verilere ne kadar yakın olduğunun bir ölçüsüdür. Optimizasyon sürecinde kaybı olabildiğince sıfıra indirme hedeflenir. Burada en yaygın kullanılan kayıp fonksiyonlarından biri karesel hatadır (ing. square error).

$$L = \frac{1}{2M} \sum_m (N^m - y^m)^2 \quad (2.9)$$

Burada y^m veri setindeki m . dataya ait gerçek değeri, N^m ise sinir ağının ilgili çıkışını ve M ise veri setindeki toplam örnek sayısını göstermektedir. Kayıp fonksiyonu optimizasyon sürecinde modelin ne kadar iyi olduğuna dair bir rehber görevi görür. Kayıp azaldıkça model verilere daha doğru bir şekilde benzemeye başlar.

En dik iniş, modelin parametrelerine göre kayıp fonksiyonunun türevlerine dayanan bir optimizasyon algoritmasıdır. Modelin parametreleri (w_{ij}) aşağıda açıklanan algoritmaya göre güncellenir;

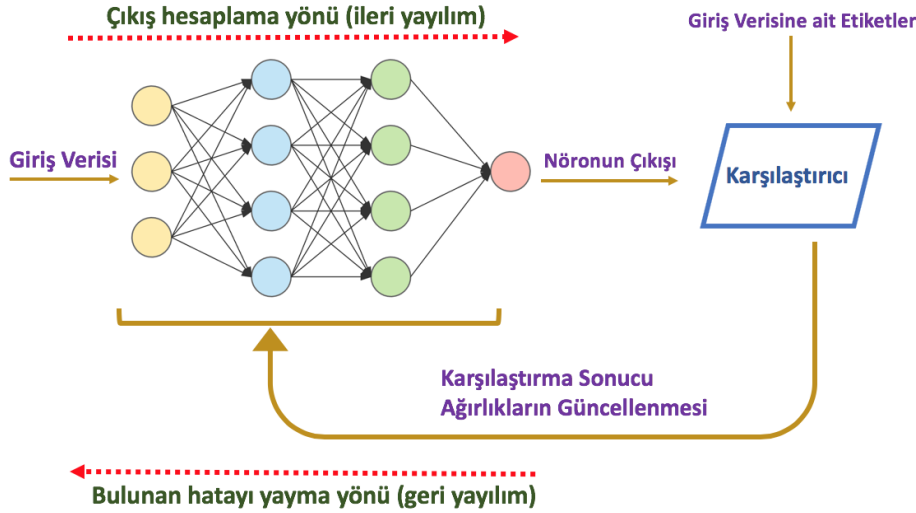
Başlangıçta rastgele w_{ij} değerleri ata

Eğer Kayıp > İstenilen Kayıp Değeri (olduğu sürece)

- Ağırlıklara göre L 'nin türevini hesapla, $\frac{\partial L}{\partial w_{ij}}$
- w_{ij} değerlerini güncelle, $w_{ij} - l \frac{\partial L}{\partial w_{ij}}$

Bitir

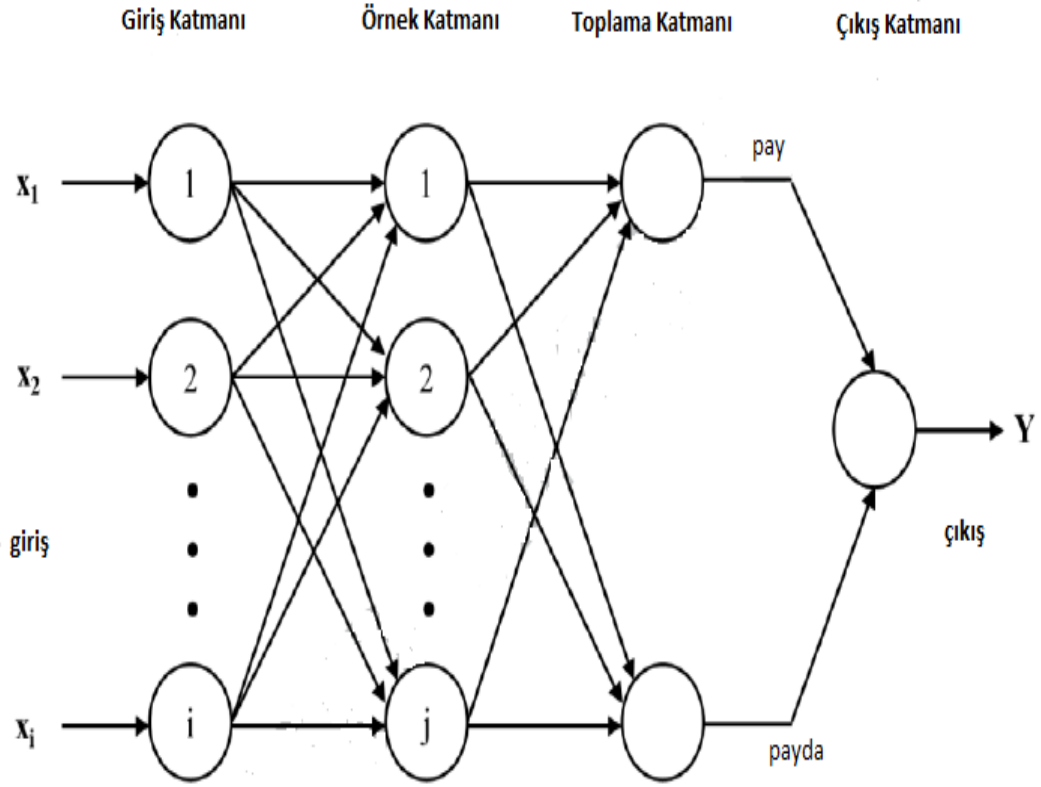
Burada l 'ye öğrenme hızı (veya adım büyüklüğü) (ing. learnin rate) denir. Tek bir güncelleme adımında gradyentin tersi yönünde ne kadar ilerleneceğini kontrol eder. Adım büyüklüğü çok büyük seçilirse global minimum değeri atlanabilir, çok küçük seçilirse bu kez de öğrenme işlemi çok yavaş gerçekleşir [96]. Literatürde bu tarz elle deneme yanılma yoluyla belirlenen parametrelere hyper parametre denilmektedir. Ağırlıkların güncellenmesini açıklayan görsel Şekil 2.8'de gösterilmiştir.



Şekil 2.8 : Hatanın geri yayılımı algoritmasının şematik gösterimi.

2.2.2. Genelleştirilmiş regresyon sinir ağları

GRNN radyal tabanlı fonksiyon sinir ağına (RBFFN) alternatif olarak geliştirilmiştir[97]. Doğrusal olmayan regresyon teorisine dayanan ileri beslemeli sinir ağı olarak GRNN, basit ve anlaşılır bir eğitim algoritmasına sahiptir. Şekil 2.9'da gösterildiği gibi, temel bir GRNN dört katman içerir: giriş katmanı, örnek katmanı, toplama katmanı ve çıkış katmanı. Giriş katmanı, eğitim kalıplarını ileriye doğru hareket ettirir ve ağırlıklı bağlantılarla kalıp katmanına bağlanır. Örnek katmanından elde edilen çıktı daha sonra iki tip toplama ünitesinden oluşan toplama katmanına beslenir: payda birimleri ve pay birimleri. Toplama katmanında, örnek katmanı çıktılarının ağırlıksız toplamını hesaplamak için kullanılan yalnızca bir payda birimi vardır. Pay üniteleri, örnek katmanı çıktılarının ağırlıklı toplamını hesaplamak için kullanılır, burada ağırlık, o desen katmanı ünitesinin eğitim durumu için bağımlı değişkenin değerine eşittir[98]. Pay birimi sayısı çıkış sayısına eşittir. Çıkış katmanı, her bir pay biriminin çıktısını payda biriminin çıktısına böler.



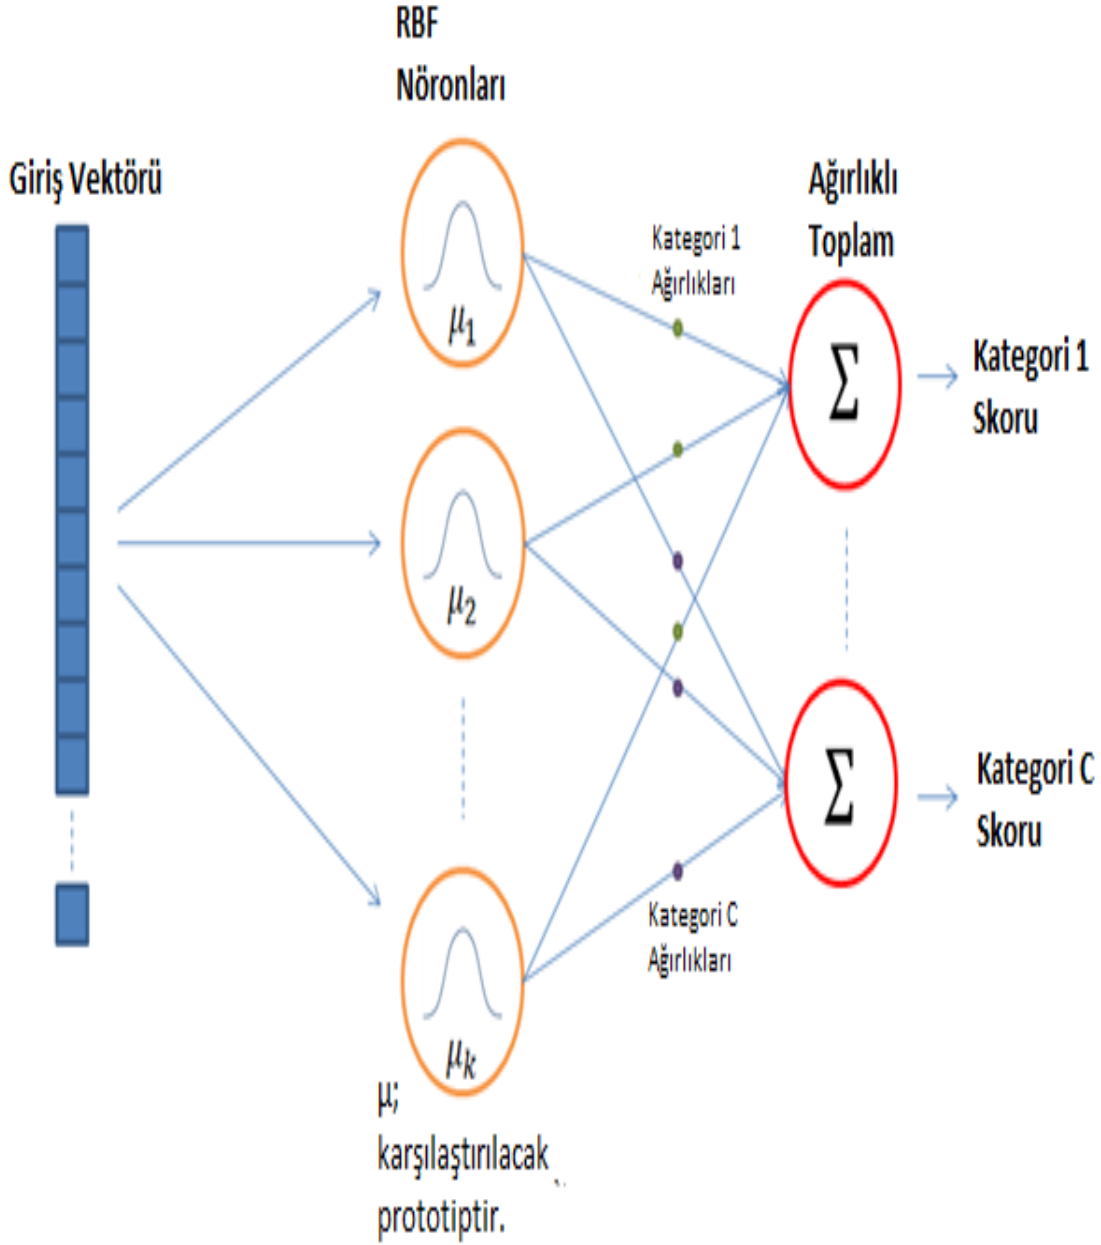
Şekil 2.9 : GRNN tipik mimarisi.

Reel sistemlerden ölçüm alma sureti ile ulaşılan veriler ileri beslemeli sinir ağı için çoğunlukla yeterlilik arz etmez. Dolayısıyla verilerle alakalı meydana getirilecek fonksiyona bir miktar eğitim verisi örneği ile yakınsama hususundaki doğruluğu genelleştirilmiş regresyon sinir ağını öne çıkarmaktadır [99].

2.2.3. Radyal tabanlı fonksiyon ağları

RBFN, güçlü doğrusal olmayan işleme ve yaklaşık özellikleri nedeniyle güçlü bir eğri uydurma aracı olarak tanınır [100-102]. Geleneksel yapay sinir ağları (yani çok katmanlı algılayıcı ağı) ile karşılaştırıldığında, RBFN daha basit ağ mimarisi sayesinde genel olarak daha hızlıdır [103]. RBFN yaklaşımı MLP'den daha sezgiseldir. Bir RBFN, girdinin eğitim setindeki örneklerle benzerliğini ölçerek sınıflandırma gerçekleştirir. Her RBFN nöronu, eğitim setindeki örneklerden sadece biri olan bir "prototip" saklar. Yeni bir girişi sınıflandırmak istediğimizde, her nöron girdi ve prototipi arasındaki Öklid mesafesini hesaplar. Kabaca ifade etmek gerekirse, girdi A sınıfı prototiplere B sınıfı prototiplerden daha yakından benziyorsa, A sınıfı olarak sınıflandırılır [104].

Aşağıda verilen şekil 2.10’da bir RBF Ağı'nın tipik mimarisi gösterilmektedir. Bir giriş vektörü, bir RBF nöronları katmanı ve her kategori veya veri sınıfı için bir düğüme sahip bir çıkış katmanından oluşur.



Şekil 2.10 : RBFN tipik mimarisi.

Giriş Vektörü

Giriş vektörü, sınıflandırmaya çalışılan n boyutlu vektördür. Bütün giriş vektörü RBF nöronlarının her birine gösterilmektedir.

RBF Nöronları

Her RBF nöronu, eğitim setindeki vektörlerden sadece biri olan bir “prototip” vektörü depolar. Her RBF nöronu, giriş vektörünü prototipiyle karşılaştırır ve benzerliğin bir ölçüsü olan 0 ile 1 arasında bir değer verir. Giriş; prototipe eşitse, o RBF nöronunun çıkışı 1 olacaktır. Giriş ve prototip arasındaki mesafe büyüdükçe, yanıt 0'a doğru katlanarak düşer. RBF nöronunun tepkisinin şekli, ağ mimarisi şemasında gösterildiği gibi bir çan eğrisidir.

Nöronun tepki değerine "aktivasyon" değeri de denir.

Prototip vektörüne genellikle nöronun “merkezi” de denir çünkü çan eğrisinin ortasındaki değerdir.

Çıkış Düğümleri

Ağın çıkışı, sınıflandırılmaya çalışılan her kategori için bir tane olmak üzere bir dizi düğümden oluşur. Her çıkış düğümü, ilişkili kategori için bir tür skor hesaplar. Tipik olarak, giriş en yüksek puanı alan kategoriye atanarak bir sınıflandırma kararı verilir. Skor, her RBF nöronundan aktivasyon değerlerinin ağırlıklı bir toplamı alınarak hesaplanır. Ağırlıklı toplamla, bir çıkış düğümünün bir RBF nöronlarının her biri ile bir ağırlık değeri ilişkilendirdiğini ve toplam yanıtı eklemeye önce nöronun aktivasyonunu bu ağırlıkla çarptığını kastediyoruz.


Her çıkış düğümü farklı bir kategorinin skorunu hesapladığından, her çıkış düğümü kendi ağırlık kümesine sahiptir. Çıkış düğümü tipik olarak kategorisine ait RBF nöronlarına pozitif, diğerlerine negatif ağırlık verecektir.

RBF Nöron Aktivasyon Fonksiyonu

Her RBF nöronu, girdi ve prototip vektörü (eğitim setinden alınan) arasındaki benzerliğin bir ölçüsünü hesaplar. Prototipe daha çok benzeyen giriş vektörleri 1'e daha yakın bir sonuç döndürür. Benzerlik fonksiyonlarının farklı olası seçenekleri vardır, ancak en popüler olanı Gaussian'a dayanır. Denklem 2.10'da, tek boyutlu girdiye sahip bir Gaussian denklemi verilmiştir.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.10)$$

X'in giriş olduğu yerde, μ ortalamadır ve σ standart sapmadır. Bu, şekil 2.11'de gösterilen ortalamaya göre ortalanmış μ çan eğrisini üretir (aşağıdaki grafikte ortalama 5 ve $\sigma=1$ 'dir)



Şekil 2.11 : Ortalama dağılım.

RBF nöron aktivasyon fonksiyonu biraz farklıdır ve tipik olarak denklem 2.11' de verilmiştir.

$$\phi(x) = e^{-\beta \|x-\mu\|^2} \quad (2.11)$$

Gauss dağılımında μ , dağılımın ortalamasını ifade eder. Burada çan eğrisinin merkezinde bulunan prototip vektörüdür. Şekil 2.12'de $\mu=0$ olan noktada farklı β değerleri için RBF nöron aktivasyonu (Gauss Dağılımı) gösterilmiştir.



Şekil 2.12 : RBF nöron aktivasyonu (Gauss Dağılımı).

3. MODELLEME

Kullanılan dört adet yöntemin detaylarına daha önceki bölümlerde yer verilmiştir. Bu yöntemler kullanılarak ilgili modeller MATLAB programı vasıtası ile gerçekleştirilmiştir. Modelleme yapılırken Hatay ilinde kurulu olan 1 MW kapasiteli PV santralinden toplanan güneş ışınımı, rüzgar hızı ve ortam sıcaklığı verileri kullanılmıştır. Veriler 2018 yılına ait olup bir yılın tüm ay ve günlerini kapsayacak şekilde kaydedilmiştir. Verilerin örnekleme sıklığı 15 dakikadır. Toplanan üç adet farklı parametre (güneş ışınımı, rüzgar hızı, ortam sıcaklığı) giriş parametreleri olarak kullanılmış, çıkışta ise fotovoltaik panelin yüzey sıcaklığı giriş parametrelerine bağlı olarak hesaplanmıştır. Hesaplanan değerler daha önce açıklanan başarımlar ölçümünde kullanılan hata kriterlerine göre kıyaslanarak modelin güvenilirliği değerlendirilmiştir.

Böylelikle hesaplanan hatalara göre model başarımları yorumlanarak hangi modelin yapılan çalışmada en iyi sonuç verdiği ortaya konulabilir. Bu bağlamda 4. Bölüm'de her modele ait hesaplanan hata değerlerine ait bir çizelge verilmiştir. Bu çizelgede hesaplanan değerlere göre fotovoltaik panel sıcaklığının üç farklı giriş parametre göre tahmin edilmesinde kullanılan dört farklı yöntemden en iyi başarımları gösteren modelin hangi model olduğu belirlenmiştir.

3.1. Model Başarımlarının Değerlendirmesinde Dikkate Alınan Kriterler

Model performansının değerlendirilmesinde literatürde kabul görmüş tek bir metrik bulunmamaktadır [105]. Bu tez çalışmasında önerilen yöntemin performansını değerlendirmek için determinasyon katsayısı (R^2), ortalama mutlak hata (ing. Mean-Absolute Error, MAE), bağıl ortalama mutlak hata (ing. Relative Mean-Absolute Error, rMAE), ortalama karesel hatanın karekökü (ing. Root Mean Square Error, RMSE), bağıl ortalama karesel hatanın karekökü (ing. Relative Root Mean Square Error, rRMSE), ortalama sapma (ing. Mean Bias Error, MBE) ve bağıl ortalama sapma (ing. Relative Mean Bias Error, rMBE) gibi ölçütler kullanılmıştır. Bu metriklere ait matematiksel ifadeler ise aşağıda gösterilen denklemlerde verilmektedir. Aşağıda

matematiksel ifadeleri verilen metriklerin her biri, bu tez çalışmasında kullanılan her bir yöntemin başarımını ölçmek için kullanılmıştır.

- *Determinasyon Katsayısı (R^2):*

$$R^2 = 1 - \frac{ESS}{TSS} \quad (3.1)$$

$$ESS = \sum_i^n [x_c - x_m]^2 \quad (3.2)$$

$$TSS = \sum_i^n [x_m]^2 \quad (3.3)$$

Denklem 3.3’de TSS; kareler toplamını, denklem 3.2 ESS; hataların kareler toplamını ifade etmektedir.

- *Mutlak Hata*

$$AE = |x_c - x_m| \quad (3.4)$$

- *Ortalama Sapma*

$$MBE = \langle \sum AE \rangle \quad (3.5)$$

- *Ortalama Mutlak Hata*

$$MAE = \langle |x_c - x_m| \rangle \quad (3.6)$$

- *RMS Hata*

$$RMSE = \sqrt{\langle AE^2 \rangle} \quad (3.7)$$

Aynı ölçeğe sahip olmaya modellerde kıyas yapabilmek için tanımlanan hata kriterlerinin normalize edilmesi gerekmektedir.

$$x_N = aralık(x_m) = max(x_m) - min(x_m) \quad (3.8)$$

- *Bağıl Ortalama Mutlak Hata (relative Mean-Absolute Error, rMAE)*

$$rMAE = \frac{MAE}{x_N} \quad (3.9)$$

- *Bağıl RMS Hata (relative Root-Mean-Squared Error, rRMSE)*

$$rMSE = \frac{RMSE}{x_N} \quad (3.10)$$

- *Bağıl Ortalama Sapma (relative Mean-Bias Error, rMBE)*


$$rMBE = \frac{MBE}{x_N} \quad (3.11)$$

3.2. Regresyon Modeli

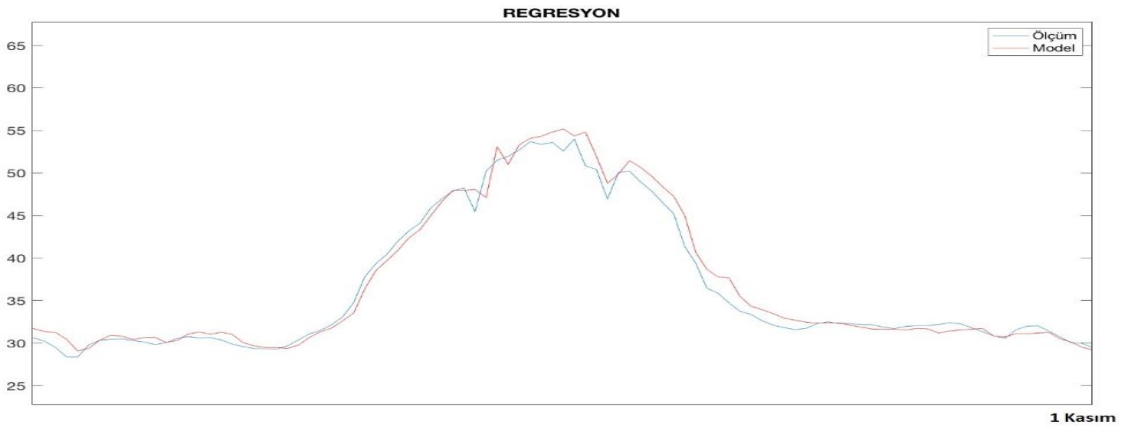
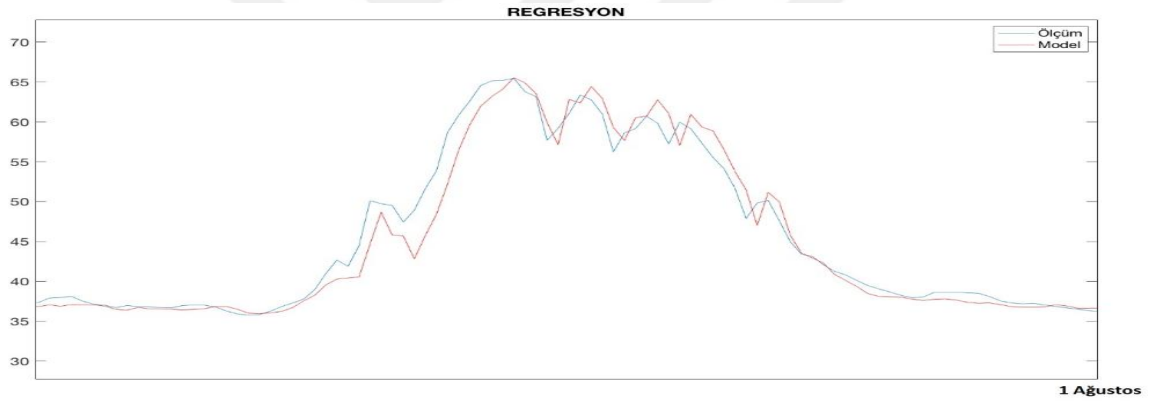
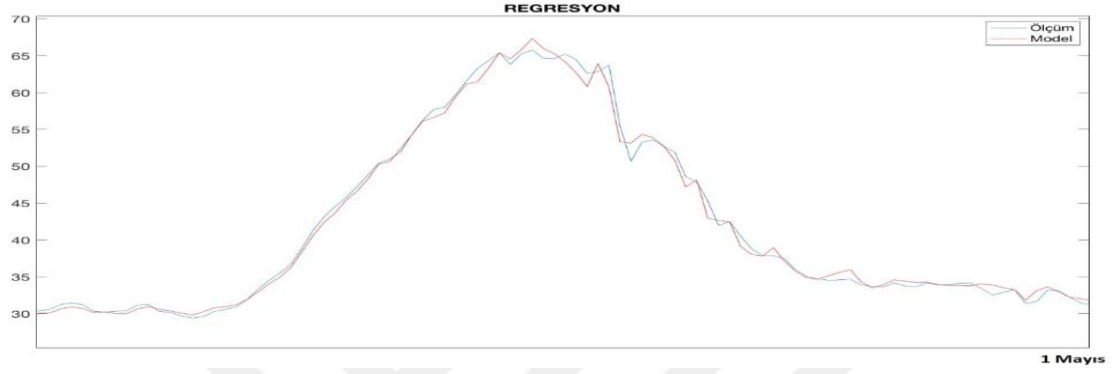
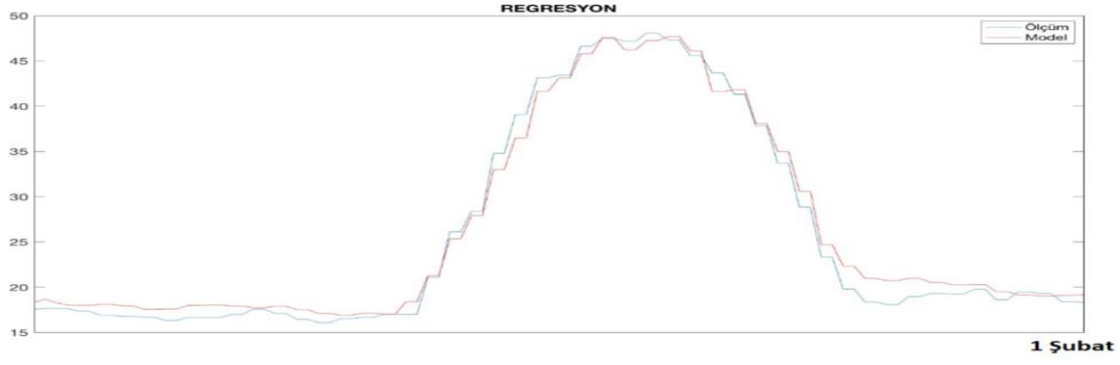
Bu tez çalışmasında Hatay ilinde bulunan 1MW kurulu güce sahip fotovoltaik enerji santralinin 2018 yılına ait güneş ışınımı, ortam sıcaklığı ve rüzgâr hızı parametreleri kullanılarak çoklu regresyon modeli denenmiştir. Geliştirilen en uygun model katsayıları;

$$T_m(\hat{Y}) = 0.0157G - 0.6641W + 1.0469T_a + 8.3302 \quad (3.12)$$

Burada T_m ; tahmin edilen fotovoltaik panel yüzey sıcaklığını, G; güneş ışınımını, W; rüzgar hızını, T_a ; ortam sıcaklığını ifade etmektedir. Modelde görüldüğü üzere rüzgar hızının panel yüzey sıcaklığına etkisi negatif yönlüdür. Diğer iki parametre olan ortam sıcaklığı ve güneş ışınımının etkisi ise pozitif yönlüdür. Bu model için $R^2 = 0.9979$, MAE = 1.257 ve MBE = 0.8482'dir. Bu sonuçlara göre model öngörü başarısı yüksektir. Bu modelin yanıtı şekil 3.1'de görülmektedir.



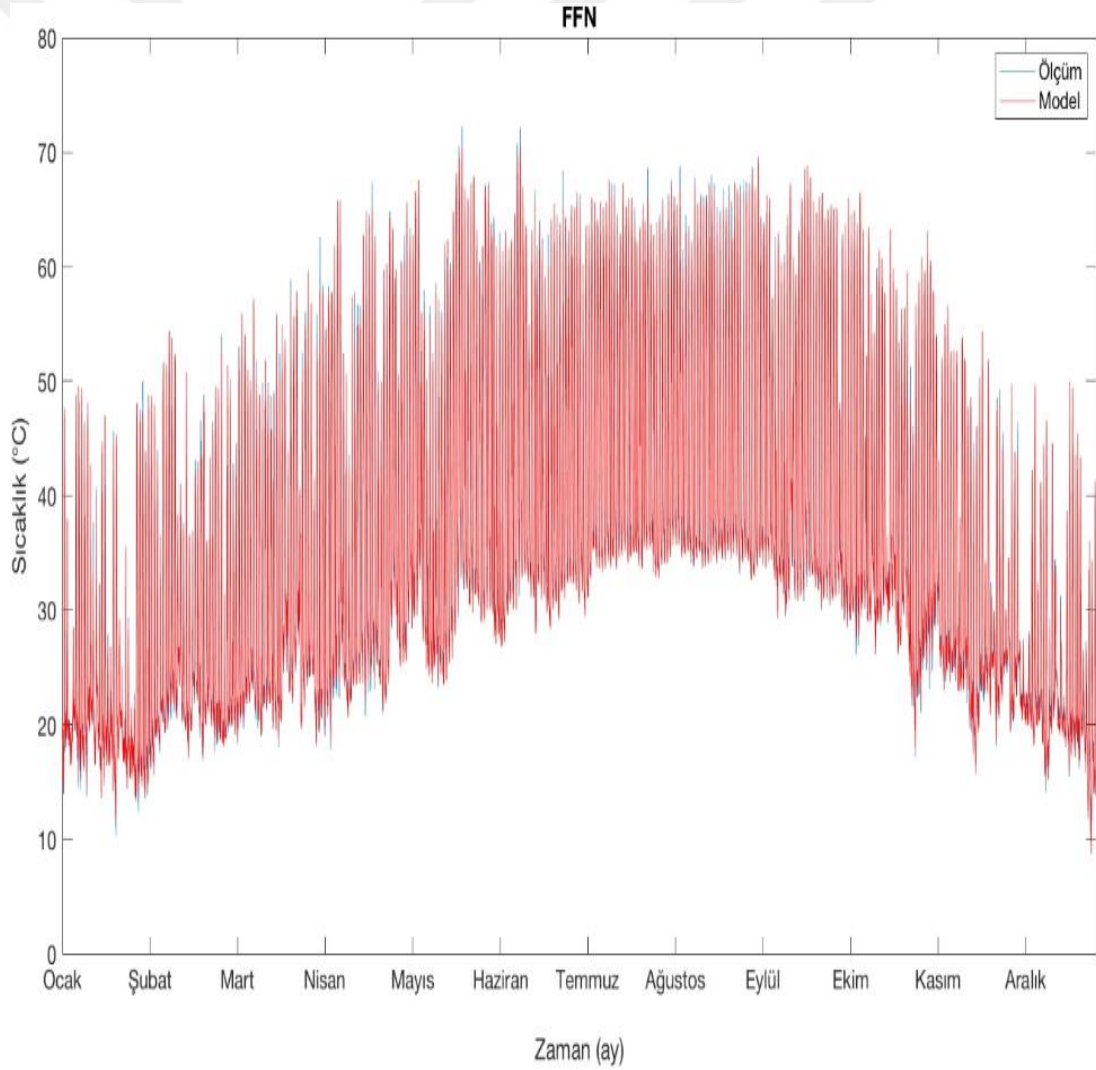
Şekil 3.1 : Regresyon modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği.



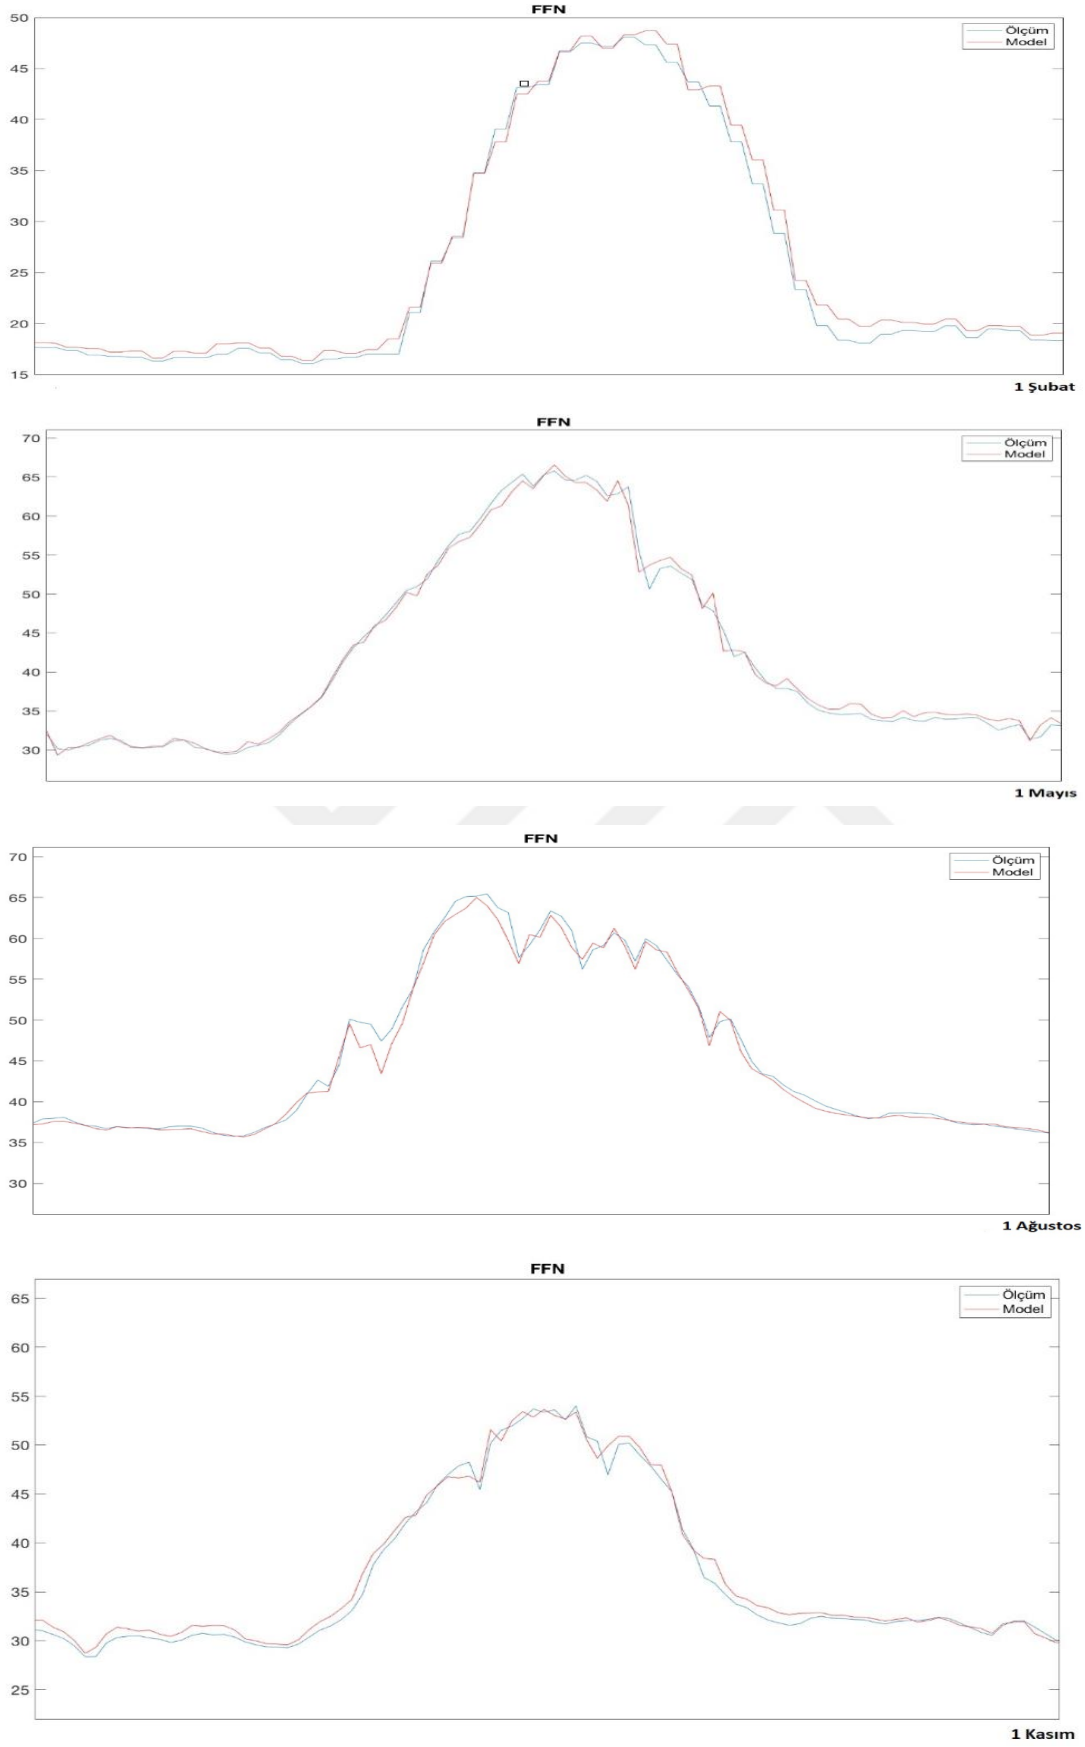
Şekil 3.2 : Regresyon modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği.

3.3. İleri Beslemeli Sinir Ağı Modeli

On beş dakika arayla alınmış fotovoltaik panel yüzey sıcaklığı verileri beşerli gruplara bölünmüştür. Her grubun ilk dört verisi modeli eğitmek için, kalan tek veri ise modeli test etmek için kullanılmıştır. Bu işlem diğer sinir ağı modelleri içinde (RBFN,GRNN) gerçekleştirilmiştir. Tüm sinir ağı modelleri için gizli tabakadaki nöron sayısı 5 ile başlamış 20 nörona kadar teker teker artırılarak deneme işlemi gerçekleştirilmiştir. Giriş nodları 1’den 50’ye kadar artırılarak denemeler yapılmıştır. En iyi çıkan modelin yanıtı şekil 3.2’de görülmektedir. Bu model için $R^2 = 0.9992$, $MAE = 0.7039$ ve $MBE = 0.0165$ ’dir.



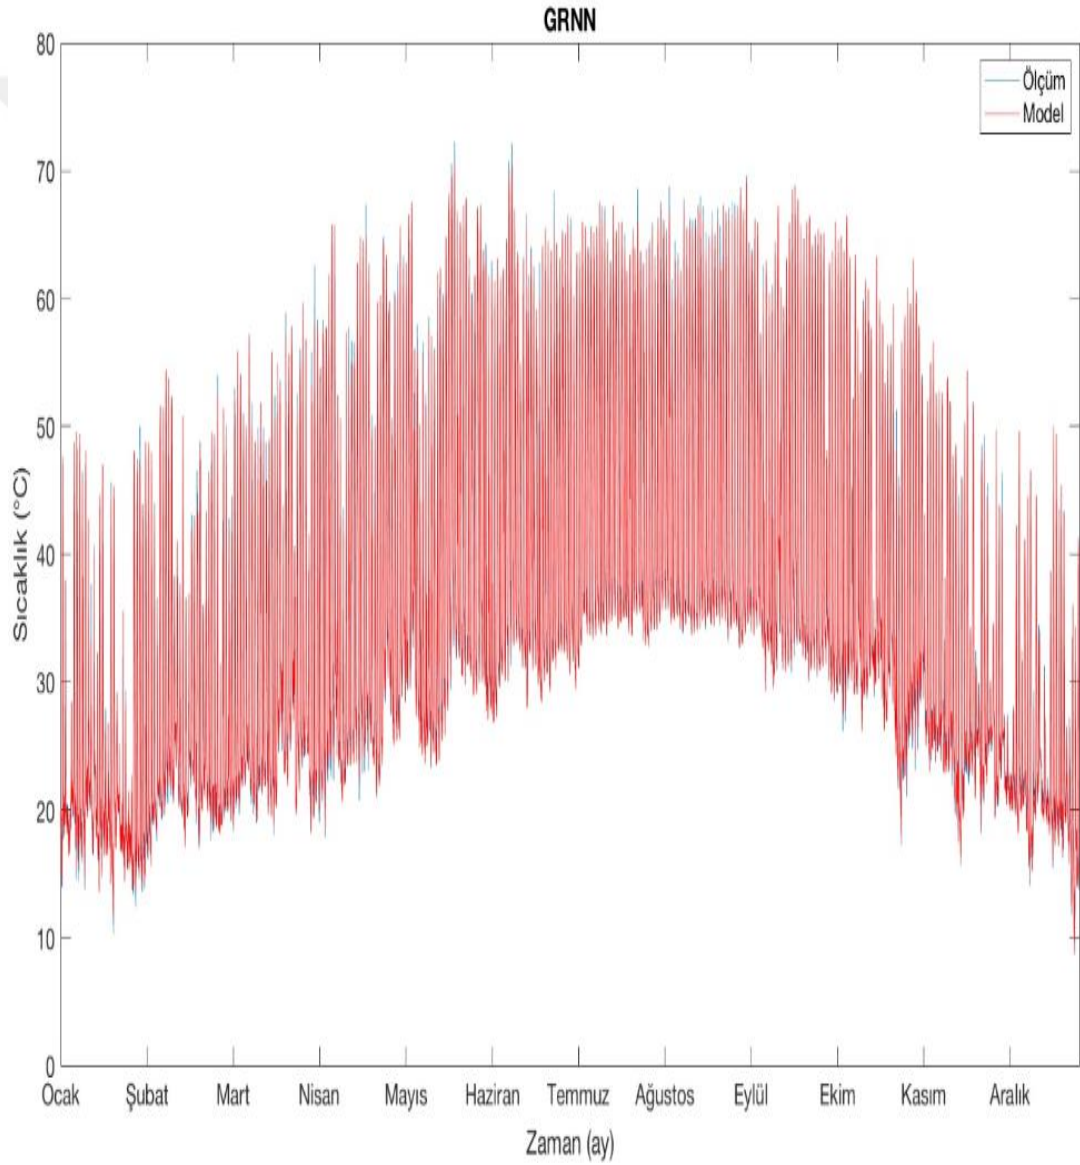
Şekil 3.3 : FFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği.



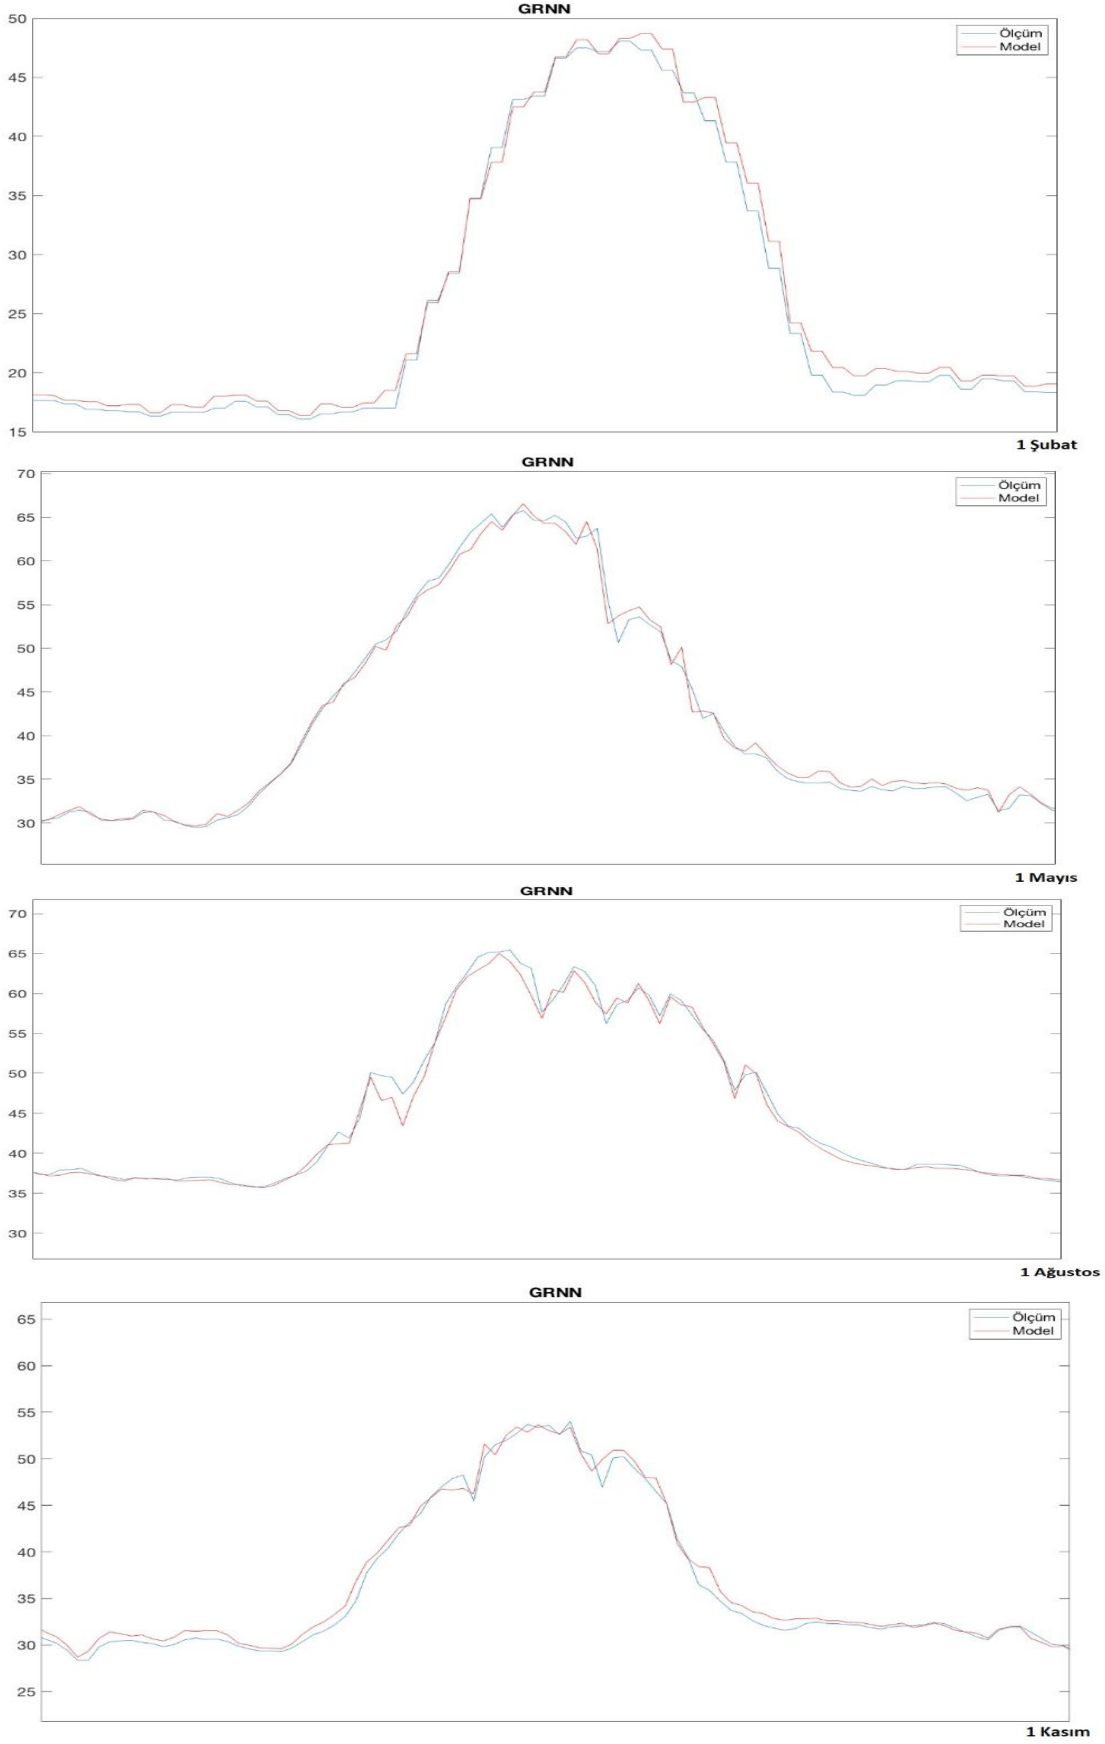
Şekil 3.4 : FFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği.

3.4. Genelleştirilmiş Regresyon Sinir Ağı Modeli

On beş dakika arayla alınmış fotovoltaik panel yüzey sıcaklığı verileri beşerli gruplara bölünmüştür. Her grubun ilk dört verisi modeli eğitmek için, kalan tek veri ise modeli test etmek için kullanılmıştır. Bu modelde de aktivasyon fonksiyonu olarak Gauss fonksiyonu seçilmiştir. Bu ağ modeli de RBF’de olduğu gibi sabit olduğundan, katman sayılarıyla alakalı her hangi bir belirleme yapılmamıştır. Gömme boyutu 1’den 200’e kadar teker teker artırılarak model eğitilmiştir. En iyi çıkan modelin yanıtı şekil 3.3’de görülmektedir. Bu model için $R^2 = 0.9988$, $MAE = 0.8760$ ve $MBE = 0.0118$ ’dir.




Şekil 3.5 : GRNN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği.



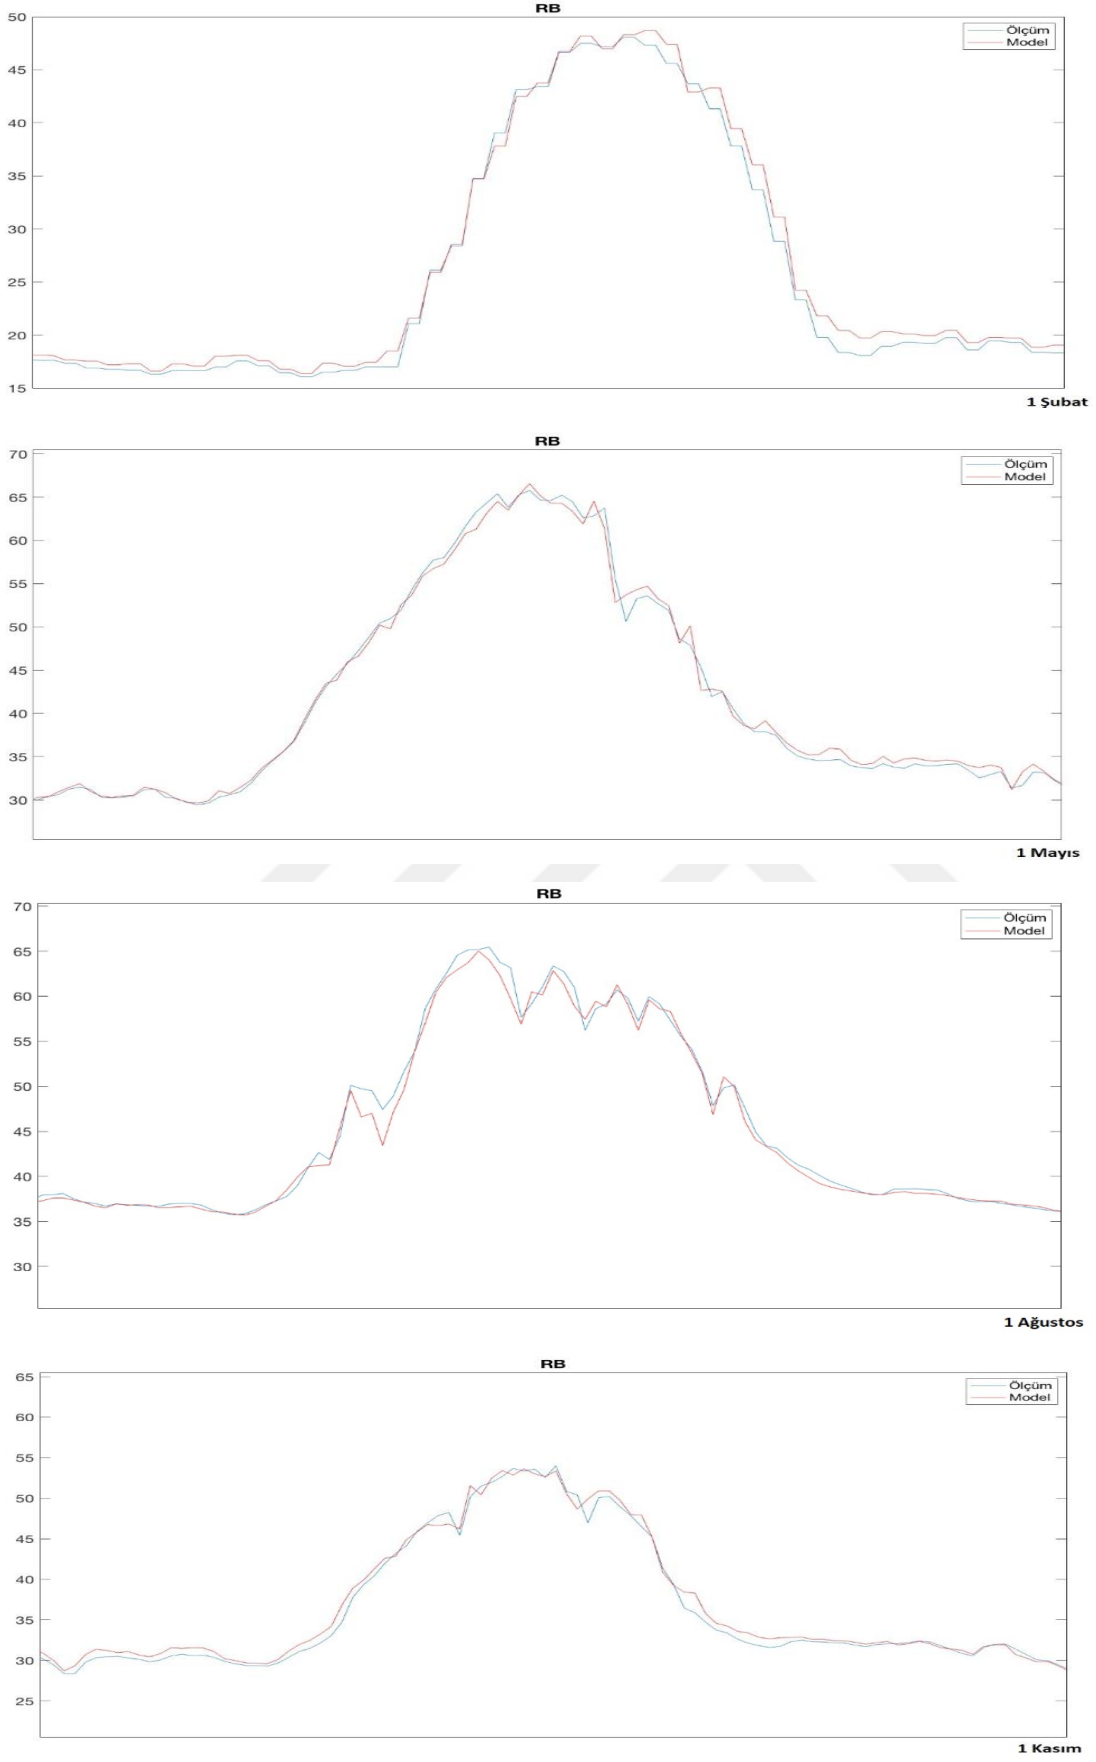
Şekil 3.6 : GRNN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği.

3.5. Radyal Tabanlı Fonksiyon Ağı Modeli

On beş dakika arayla alınmış fotovoltaik panel yüzey sıcaklığı verileri beşerli gruplara bölünmüştür. Her grubun ilk dört verisi modeli eğitmek için, kalan tek veri ise modeli test etmek için kullanılmıştır. Bu ağ yapısında bir adet RBF katmanı bulunmaktadır. Sabit bir ağ modeli olduğundan katman sayılarına dair herhangi bir ayarlama yapılmamıştır. Aktivasyon fonksiyonu olarak Gauss fonksiyonu seçilmiştir. En iyi çıkan modelin yanıtı şekil 3.4’de görülmektedir. Bu model için $R^2 = 0.9983$, $MAE = 0.6867$ ve $MBE = -0.0564$ ’dir.



Şekil 3.7 : RBFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin zamana bağlı grafiği.



Şekil 3.6 : RBFN modeli için ölçüm değerleri ve modelle hesaplanan değerlerin dört mevsime ait birer gün için zamana bağlı grafiği.

4. BULGULAR

Bu tez çalışmasında Hatay ilinde bulunan 1 MW kurulu güç kapasitesine sahip fotovoltaik enerji santraline ait 15'er dakikalık örnekleme ile toplanan rüzgâr hızı, güneş ışınımı ve ortam sıcaklığı verileri kullanılarak fotovoltaik panel yüzey sıcaklığı tahmini yapılmıştır. Tahmini gerçekleştirmek için; çoklu regresyon analizi, ileri beslemeli yapay sinir ağı, genelleştirilmiş regresyon sinir ağı ve radyal tabanlı fonksiyon sinir ağı olmak üzere 4 farklı yöntemle başvurulmuştur. Bu yöntemler MATLAB programı vasıtasıyla gerçekleştirilmiştir.

FFN için giriş nodları 1'den 50'ye kadar artırılarak denemeler yapılmıştır. Gizli tabakadaki nöron sayısı 5 ile başlamış 20 nörona kadar teker teker artırılarak deneme işlemi gerçekleştirilmiştir. RBFN modeli için genişlik parametresi 1'den 30'a kadar değiştirilerek model oluşturulmuştur. Yine GRNN modeli için genişlik parametresi 1'den 30'a kadar değiştirilerek model oluşturulmuştur. Geliştirilen modellere ait hata kriterleri Çizelge 5.1'de gösterilmiştir.

Çizelge 4.1 : Model hata kriterleri.

	FNN	GRNN	RBFN	Regresyon
R²	0.999280	0.998826	0.998312	0.9979
MAE	0.703980	0.876087	0.686734	1.257
rMAE	0.011611	0.014234	0.017243	0.0174
RMSE	0.011611	1.278	0.995815	1.727
rRMSE	0.0116523	0.020780	0.025004	0.0239
MBE	0.016523	0.011884	0.056421	0.8482
rMBE	0.000018	0.000193	0.001417	0.0117

R² değeri 0 ile 1 arasında değer almaktadır. R² değerinin büyük olması modelin başarısının yüksek olduğunu gösterir. Çizelge 5.1 incelendiğinde en yüksek R² değerine sahip model FFN'dir. Yine düşük RMSE değeri modelin başarısını göstermektedir. Buna göre en düşük RMSE değerine sahip FFN modeli en yüksek başarıyı göstermiştir denilebilir. En yüksek RMSE değerine sahip ve en düşük R² değerine sahip model ise regresyon modelidir. Dolayısıyla 3 adet yapay sinir ağı

yöntemi de kullanılarak elde edilen modeller regresyon yöntemi kullanılarak elde edilen modele göre başarımı yüksek çıkmıştır. Bu yüzden, regresyon yönteminin yerine yapay sinir ağları yöntemlerini kullanmak daha elverişli denilebilir.

Multiple regresyon modeli kurularak elde edilen, $T_m(\hat{Y}) = 0.0157G - 0.6641W + 1.0469T_a + 8.3302$ denklemde rüzgar hızının panel yüzey sıcaklığına etkisi negatiftir. Bu da rüzgar hızının enerji üretimi için olumlu olduğu sonucunu doğurur. Ortam sıcaklığının yüksek olması da doğrudan fotovoltaiik panellerin sıcaklığının artmasına neden olduğundan enerji üretimine negatif etki yapar. Fotovoltaiik sistemlerin elektrik üretmesini sağlayan güneş ışınımının ise bir yandan da fotovoltaiik panelin sıcaklığını arttırması dolayısıyla, dolaylı olarak enerji üretiminin düşmesine sebep olduğu görülmektedir. Ancak denklem incelendiğinde ışınım katsayısının “0.0157” olmasından dolayı bu etkinin ne kadar küçük olduğu sonucuna varabiliriz. Işınımın panel yüzey sıcaklığı üzerinde ciddi bir etkisinin olmadığı sonucuna varılabilir.

$T_m(\hat{Y}) = 0.0157G - 0.6641W + 1.0469T_a + 8.3302$ denkleminde rüzgar hızının katsayısını “-0,6641” olarak görmekteyiz. Rüzgar hızının beklenildiği üzere panel yüzey sıcaklığını düşürücü bir etki yarattığı gözükmektedir. Rüzgar hızının, panel yüzey sıcaklığını düşürücü etkisi; ortam sıcaklığının, panel yüzey sıcaklığını artırıcı etkisi ile kıyaslandığında, ortam sıcaklığının, sıcaklık arttırıcı etkisinin yarısından fazla bir sıcaklık düşürücü etkiye sahiptir. Dolayısıyla rüzgar hızının enerji üretimine olumlu bir katkı yaptığını söylemek mümkün hale gelir.

Rüzgâr hızı, güneş ışınımı ve ortam sıcaklığı değişkenleri kullanılarak fotovoltaiik panel yüzey sıcaklığı tahmininin yapıldığı bu çalışma ışığında, farklı bölgelerden elde edilecek veriler kullanılarak benzer bir çalışma gerçekleştirilebilir. Böylelikle farklı coğrafi bölgelerdeki modellerin bu çalışmadaki modellerle ilişkisi incelenebilir. Ayrıca toprak sıcaklığı ve nem gibi veriler de toplanarak modele eklenebilir. Bu da daha fazla değişkenle daha güçlü bir model oluşturulmasını sağlayabilir.

KAYNAKLAR

- [1] **Edenhofer, O.** (2011). et al., Renewable energy sources and climate change mitigation: Special report of the intergovernmental panel on climate change.: Cambridge University Press.
- [2] **Abbasi, T. and S. Abbasi** (2011). Renewable energy sources: Their impact on global warming and pollution. : PHI Learning Pvt. Ltd.
- [3] **Kaygusuz, K.** (2012). Energy for sustainable development: A case of developing countries. *Renewable and Sustainable Energy Reviews*, 16(2): p. 1116-1126.
- [4] **Asumadu-Sarkodie, S. and P.A. Owusu** (2016). Feasibility of biomass heating system in Middle East Technical University, Northern Cyprus Campus. *Cogent Engineering*, 3(1): p. 1134304.
- [5] **Url-1**, <https://www.ren21.net/what-are-the-current-trends-in-renewable-energy/>. 20.03.20.
- [6] **Rizzi, F., N.J. van Eck, and M. Frey**, (2014). The production of scientific knowledge on renewable energies: Worldwide trends, dynamics and challenges and implications for management. *Renewable Energy*. 62: p. 657-671.
- [7] **Momete, D.C.** (2018). Analysis of the potential of clean energy deployment in the European Union. *IEEE Access*, 6: p. 54811-54822.
- [8] **Qazi, A.** (2019). et al., Towards sustainable energy: a systematic review of renewable energy sources, technologies, and public opinions. *IEEE Access*, 7: p. 63837-63851.
- [9] **Xu, Q.** (2013). et al., Energy sources, Part A: recovery, utilization, and environmental effects. *Energy Sources*, 35: p. 848-858.
- [10] **Saleh, A.M., A.B. Haris, and N.B. Ahmad**, (2014). Towards a UTAUT-based model for the intention to use solar water heaters by Libyan households. *International Journal of Energy Economics and Policy*, 4(1): p. 26-31.
- [11] **Qu, M.** (2011). et al., Chinese university students' knowledge and attitudes regarding forest bio-energy. *Renewable and Sustainable Energy Reviews*, 15(8): p. 3649-3657.
- [12] **Lucas, H., S. Pinnington, and L.F. Cabeza**, (2018). Education and training gaps in the renewable energy sector. *Solar Energy*, 173: p. 449-455.
- [13] **Trop, P. and D. Goricanec**, (2016). Comparisons between energy carriers' productions for exploiting renewable energy sources. *Energy*, 108: p. 155-161.

- [14] **Fornara, F.**, (2016). et al., Predicting intention to improve household energy efficiency: The role of value-belief-norm theory, normative and informational influence, and specific attitude. *Journal of Environmental Psychology*, 45: p. 1-10.
- [15] **Int. Energy Agency, P.** (2018). France, International Energy Statistics.
- [16] **Kousksou, T.** (2014). et al., Energy storage: Applications and challenges. *Solar Energy Materials and Solar Cells*, 120: p. 59-80.
- [17] **Stigka, E.K., J.A. Paravantis, and G.K. Mihalakakou**, (2014). Social acceptance of renewable energy sources: A review of contingent valuation applications. *Renewable and Sustainable Energy Reviews*, 32: p. 100-106.
- [18] **Tsagarakis, K.P.** (2018). et al., Clean vs. Green: redefining renewable energy. Evidence from Latvia, Lithuania, and Romania. *Renewable energy*, 121: p. 412-419.
- [19] **Borovik, M.R. and J.D. Albers**, (2018). Participation in the Illinois solar renewable energy market. *The Electricity Journal*, 31(2): p. 33-39.
- [20] **Zografakis, N.** (2010). et al., Assessment of public acceptance and willingness to pay for renewable energy sources in Crete. *Renewable and Sustainable Energy Reviews*, 14(3): p. 1088-1095.
- [21] **Bayulgen, O. and S. Benegal**, (2019). Green Priorities: How economic frames affect perceptions of renewable energy in the United States. *Energy Research & Social Science*, 47: p. 28-36.
- [22] **Keramitsoglou, K.M.** (2016). et al., Clean, not green: The effective representation of renewable energy. *Renewable and Sustainable Energy Reviews*, 59: p. 1332-1337.
- [23] **Bhowmik, C.** (2017). et al., Optimal green energy planning for sustainable development: A review. *Renewable and Sustainable Energy Reviews*, 71: p. 796-813.
- [24] **Kardooni, R., S.B. Yusoff, and F.B. Kari**, (2016). Renewable energy technology acceptance in Peninsular Malaysia. *Energy policy*, 88: p. 1-10.
- [25] **Metz, B.** (2007). et al., Contribution of working group III to the fourth assessment report of the intergovernmental panel on climate change. *IPCC Fourth Assessment Report (AR4)*,
- [26] **Zabihian, F. and A. Fung**, (2009). Fuel and GHG emission reduction potentials by fuel switching and technology improvement in the Iranian electricity generation sector. *International Journal of Engineering (IJE)*, 3(2): p. 159.
- [27] **Sharvini, S.R.** (2018). et al., Energy consumption trends and their linkages with renewable energy policies in East and Southeast Asian countries: Challenges and opportunities. *Sustainable Environment Research*, 28(6): p. 257-266.
- [28] **Shafiullah, G.** (2012). et al., Prospects of renewable energy—a feasibility study in the Australian context. *Renewable Energy*, 39(1): p. 183-197.

- [29] **Andreas, J.-J., C. Burns, and J. Touza**, (2017). Renewable energy as a luxury? A qualitative comparative analysis of the role of the economy in the EU's renewable energy transitions during the 'double crisis'. *Ecological Economics*, 142: p. 81-90.
- [30] **Shakeel, S.R., J. Takala, and W. Shakeel**, (2016). Renewable energy sources in power generation in Pakistan. *Renewable and Sustainable Energy Reviews*, 64: p. 421-434.
- [31] **Afsharzade, N.** (2016). et al., Renewable energy development in rural areas of Iran. *Renewable and Sustainable Energy Reviews*, 65: p. 743-755.
- [32] **Int. Renew. Energy Agency**, (2018). A.D. and U.A. Emirates, Renewable Capacity Highlights.
- [33] **Xue, H.S.** (2016). Experimental investigation of a domestic solar water heater with solar collector coupled phase-change energy storage. *Renewable Energy*, 86: p. 257-261.
- [34] **Aydin, E., P. Eichholtz, and E. Yönder**, (2018). The economics of residential solar water heaters in emerging economies: The case of Turkey. *Energy Economics*, 75: p. 285-299.
- [35] **Tijani, I.B.** (2018). et al., Development of an automatic solar-powered domestic water cooling system with multi-stage Peltier devices. *Renewable energy*, 128: p. 416-431.
- [36] **Al-Marri, W., A. Al-Habaibeh, and M. Watkins**, (2018). An investigation into domestic energy consumption behaviour and public awareness of renewable energy in Qatar. *Sustainable cities and society*, 41: p. 639-646.
- [37] **Rogers, J., M. McManus, and S. Cooper**, (2013). Potential for reliance on solar water heating throughout the summer in northern cloudy climates. *Energy and buildings*, 66: p. 128-135.
- [38] **Tévar, G.** (2019). et al., Influence of rooftop PV generation on net demand, losses and network congestions: A case study. *International Journal of Electrical Power & Energy Systems*, 106: p. 68-86.
- [39] **Joshi, S.B. and A. Jani**, (2015). Design, development and testing of a small scale hybrid solar cooker. *Solar Energy*, 122: p. 148-155.
- [40] **Enteria, N., H. Awbi, and H. Yoshino**, (2015). Application of renewable energy sources and new building technologies for the Philippine single family detached house. *International Journal of Energy and Environmental Engineering*, 6(3): p. 267-294.
- [41] **Enteria, N.** (2016). et al., Benefits of utilizing on-site and off-site renewable energy sources for the single family detached house. *International Journal of Energy and Environmental Engineering*, 7(2): p. 145-166.
- [42] **Alam, S., S. Kaushik, and S. Garg**, (2009). Assessment of diffuse solar energy under general sky condition using artificial neural network. *Applied Energy*, 86(4): p. 554-564.

- [43] **Jiang, Y.** (2009). Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models. *Energy*, 34(9): p. 1276-1283.
- [44] **Qin, J.** (2011). et al., Estimation of monthly-mean daily global solar radiation based on MODIS and TRMM products. *Applied energy*, 88(7): p. 2480-2489.
- [45] **Adib, R.** (2015). et al., Renewables 2015 global status report. REN21 Secretariat, Paris, France,
- [46] **Zubi, G.** (2019). et al., The unlocked potential of solar home systems; an effective way to overcome domestic energy poverty in developing regions. *Renewable Energy*, 132: p. 1425-1435.
- [47] **Sütterlin, B. and M. Siegrist,** (2017). Public acceptance of renewable energy technologies from an abstract versus concrete perspective and the positive imagery of solar power. *Energy Policy*, 106: p. 356-366.
- [48] **Van Biljon, J.A., P. Kotze, and G. Marsden,** (2006). A model for representing the motivational and cultural factors that influence mobile phone usage variety. University of South Africa.
- [49] **Park, E. and S.J. Kwon,** (2017). What motivations drive sustainable energy-saving behavior?: An examination in South Korea. *Renewable and Sustainable Energy Reviews*, 79: p. 494-502.
- [50] **Çelikler, D. and Z. Aksan,** (2015). The opinions of secondary school students in Turkey regarding renewable energy. *Renewable energy*, 75: p. 649-653.
- [51] **Ribeiro, F.** (2014). et al., Public opinion on renewable energy technologies in Portugal. *Energy*, 69: p. 39-50.
- [52] **Motosu, M. and Y. Maruyama,** (2016). Local acceptance by people with unvoiced opinions living close to a wind farm: A case study from Japan. *Energy Policy*, 91: p. 362-370.
- [53] **Chen, D., C.-y. Cheng, and J. Urpelainen,** (2016). Support for renewable energy in China: A survey experiment with internet users. *Journal of Cleaner Production*, 112: p. 3750-3758.
- [54] **Bush, D. and P. Hoagland,** (2016). Public opinion and the environmental, economic and aesthetic impacts of offshore wind. *Ocean & Coastal Management*, 120: p. 70-79.
- [55] **Denis, G.S. and P. Parker,** (2009). Community energy planning in Canada: The role of renewable energy. *Renewable and Sustainable Energy Reviews*, 13(8): p. 2088-2095.
- [56] **Noblet, C.L.** (2015). et al., Public preferences for investments in renewable energy production and energy efficiency. *Energy Policy*, 87: p. 177-186.
- [57] **Kardooni, R.** (2018). et al., Public opinion on renewable energy technologies and climate change in Peninsular Malaysia. *Renewable energy*, 116: p. 659-668.

- [58] **Kim, J., S.Y. Park, and J. Lee**, (2018). Do people really want renewable energy? Who wants renewable energy?: Discrete choice model of reference-dependent preference in South Korea. *Energy Policy*, 120: p. 761-770.
- [59] **Ribeiro, F.** (2018). et al., Modelling perception and attitudes towards renewable energy technologies. *Renewable Energy*, 122: p. 688-697.
- [60] **Ladenburg, J.** (2010). Attitudes towards offshore wind farms—The role of beach visits on attitude and demographic and attitude relations. *Energy Policy*, 38(3): p. 1297-1304.
- [61] **Dimitropoulos, A. and A. Kontoleon**, (2009). Assessing the determinants of local acceptability of wind-farm investment: A choice experiment in the Greek Aegean Islands. *Energy policy*, 37(5): p. 1842-1854.
- [62] **Ganzevles, J., L. Asveld, and P. Osseweijer**, (2015). Extending bioenergy towards smart biomass use Issues of social acceptance at Park Cuijk, The Netherlands. *Energy, Sustainability and Society*, 5(1): p. 1-12.
- [63] **Moula, M.M.E.** (2013). et al., Researching social acceptability of renewable energy technologies in Finland. *International Journal of Sustainable Built Environment*, 2(1): p. 89-98.
- [64] **Nel, P., M.J. Booysen, and B. Van der Merwe**, (2016). Energy perceptions in South Africa: An analysis of behaviour and understanding of electric water heaters. *Energy for sustainable development*, 32: p. 62-70.
- [65] **Botelho, A.** (2016). et al., Public perceptions of environmental friendliness of renewable energy power plants.
- [66] **Schumacher, K.** (2019). et al., Public acceptance of renewable energies and energy autonomy: A comparative study in the French, German and Swiss Upper Rhine region. *Energy policy*, 126: p. 315-332.
- [67] **Fernández, E.F. and F. Almonacid**, (2015). A new procedure for estimating the cell temperature of a high concentrator photovoltaic grid connected system based on atmospheric parameters. *Energy conversion and management*, 103: p. 1031-1039.
- [68] **Fernández, E.F.** (2014). et al., A method for estimating cell temperature at the maximum power point of a HCPV module under actual operating conditions. *Solar Energy Materials and Solar Cells*, 124: p. 159-165.
- [69] **Farivar, G. and B. Asaei**, (2011). A new approach for solar module temperature estimation using the simple diode model. *IEEE transactions on energy conversion*, 26(4): p. 1118-1126.
- [70] **Farivar, G.** (2011). et al. A novel temperature estimation method for solar cells. in 2011 2nd Power Electronics, Drive Systems and Technologies Conference. IEEE.
- [71] **Nishioka, K.** (2018). et al., Accurate measurement and estimation of solar cell temperature in photovoltaic module operating in real environmental conditions. *Japanese Journal of Applied Physics*, 57(8S3): p. 08RG08.

- [72] **Almaktar, M.** (2015). et al., Artificial neural network- based photovoltaic module temperature estimation for tropical climate of Malaysia and its impact on photovoltaic system energy yield. *Progress in Photovoltaics: Research and Applications*, 23(3): p. 302-318.
- [73] **Fernández, F.** (2013). et al. Calculation of cell temperature in a HCPV module using V_{oc} . in 2013 Spanish Conference on Electron Devices. IEEE.
- [74] **Fernández, E.F.** (2014). et al., Calculation of the cell temperature of a high concentrator photovoltaic (HCPV) module: a study and comparison of different methods. *Solar Energy Materials and Solar Cells*, 121: p. 144-151.
- [75] **Almaktar, M.** (2013). et al., Climate-based empirical model for PV module temperature estimation in tropical environment. *Applied Solar Energy*, 49(4): p. 192-201.
- [76] **Hara, S., M. Kasu, and N. Matsui,** (2016). Estimation method of solar cell temperature using meteorological data in mega solar power plant. *IEEE Journal of Photovoltaics*, 6(5): p. 1255-1260.
- [77] **Coskun, C., N. Koçyiğit, and Z. Oktay,** (2016). Estimation of PV module surface temperature using artificial neural networks. *Mugla Journal of Science and Technology*, 2(2): p. 15-18.
- [78] **García, M.A. and J. Balenzategui,** (2004). Estimation of photovoltaic module yearly temperature and performance based on nominal operation cell temperature calculations. *Renewable energy*, 29(12): p. 1997-2010.
- [79] **Du, Y.** (2016). et al., Evaluation of photovoltaic panel temperature in realistic scenarios. *Energy Conversion and Management*, 108: p. 60-67.
- [80] **Mavromatakis, F.** (2014). et al., Measuring and estimating the temperature of photovoltaic modules. *Solar energy*, 110: p. 656-666.
- [81] **Muzathik, A.** (2014). Photovoltaic modules operating temperature estimation using a simple correlation. *International Journal of Energy Engineering*, 4(4): p. 151.
- [82] **Ceylan, I.** (2014). et al., The prediction of photovoltaic module temperature with artificial neural networks. *Case Studies in Thermal Engineering*, 3: p. 11-20.
- [83] **Schwingshackl, C.** (2013). et al., Wind effect on PV module temperature: Analysis of different techniques for an accurate estimation. *Energy Procedia*, 40: p. 77-86.
- [84] **Anderson, J. and P. Philips,** (1981). Regression, discrimination and measurement models for ordered categorical variables. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 30(1): p. 22-31.
- [85] **Aydın, D.** (2014). *Uygulamalı Regresyon Analizi. Kavramlar ve R Hesaplamaları*. Nobel Yayıncılık.
- [86] **de Jong, S. and A. Phatak.** (1997). Partial least squares regression. in *Proceedings of the second international workshop on recent advances in total least squares techniques and error-in-variables modeling*. Society for Industrial and Applied Mathematics.

- [87] **Albayrak, A.S.** (2005) *Mekan Endekslerinin Hesaplanmasında Çok Değişkenli Bir Yaklaşım: Türkiye’de Seçilmiş 19 İlin Tüketici Fiyat Endekslerine Göre Karşılaştırılması*. Zonguldak: 4. İstatistik Kongresi.
- [88] **Elsheikh, A.H.** (2019). et al., Modeling of solar energy systems using artificial neural network: A comprehensive review. *Solar Energy*, 180: p. 622-639.
- [89] **Haykin, S.** (1994). *Neural networks: a comprehensive foundation*: Prentice Hall PTR.
- [90] **Nacar, İ.D.** (2019). Doğrusal Ve Doğrusal Olmayan Metotlarla Bir Adım İleri Rüzgar Şiddeti Öngörüsü. *Enerji Enstitüsü*.
- [91] **Baldi, P. and R. Vershynin,** (2019). The capacity of feedforward neural networks. *Neural networks*, 116: p. 288-311.
- [92] **Chen, M.** (2019). et al., Artificial neural networks-based machine learning for wireless networks: A tutorial. *IEEE Communications Surveys & Tutorials*, 21(4): p. 3039-3071.
- [93] **Spicer, J. and A.N. Sanborn,** (2019). What does the mind learn? A comparison of human and machine learning representations. *Current opinion in neurobiology*, 55: p. 97-102.
- [94] **Breeden, J.L. and E. Leonova.** (2019). When Big Data Isn’t Enough: Solving the long-range forecasting problem in supervised learning. in *2019 International Conference on Modeling, Simulation, Optimization and Numerical Techniques (SMONT 2019)*. Atlantis Press.
- [95] **Géron, A.** (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*: O’Reilly Media.
- [96] **Akbaba, E.C.** (2019). *Using Artificial Neural Network (ANN) Techniques For Solar Irradiation Predictions*. Ankara: Middle East Technical University.
- [97] **Specht, D.F.** (1991). A general regression neural network. *IEEE transactions on neural networks*, 2(6): p. 568-576.
- [98] **Masters, T.** (1993). *Practical neural network recipes in C++*: Morgan Kaufmann.
- [99] **Specht, D.F.** (1993). The general regression neural network-rediscovered. *Neural Networks*, 6(7): p. 1033-1034.
- [100] **Sepehry, N., M. Shamshirsaz, and F. Abdollahi,** (2011). Temperature variation effect compensation in impedance-based structural health monitoring using neural networks. *Journal of Intelligent Material Systems and Structures*, 22(17): p. 1975-1982.
- [101] **Chen, S., C.F. Cowan, and P.M. Grant,** (1991). Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transactions on neural networks*, 2(2): p. 302-309.
- [102] **Schwenker, F., H.A. Kestler, and G. Palm,** (2001). Three learning phases for radial-basis-function networks. *Neural networks*, 14(4-5): p. 439-458.

- [103] **Xie, T., H. Yu, and B. Wilamowski.** (2011). Comparison between traditional neural networks and radial basis function networks. in 2011 IEEE International Symposium on Industrial Electronics. IEEE.
- [104] **McCormick, C.** (2013). Radial Basis Function Network (RBFN) Tutorial. <https://mccormickml.com/2013/08/15/radial-basis-function-network-rbf-tutorial/>
- [105] **Li, G. and J. Shi,** (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7): p. 2313-2320.



ÖZGEÇMİŞ

Ad Soyad : Çağatay Öztürk

E-posta : cagatayozturk@windowlive.com

ÖĞRENİM DURUMU:

- **Lisans** : 2014, Atatürk Üniversitesi, Mühendislik, Elektrik-Elektronik Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Karadeniz Holding – Proje Mühendisi

