

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**DOĞRUSAL VE DOĞRUSAL OLMAYAN METOTLARLA BİR ADIM İLERİ
RÜZGAR ŞİDDETİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

İrem Damla NACAR

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Dr. Öğr. Üyesi Burak Barutçu

EYLÜL, 2019

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**DOĞRUSAL VE DOĞRUSAL OLMAYAN METOTLARLA BİR ADIM İLERİ
RÜZGAR ŞİDDETİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

İrem Damla NACAR

(301151012)

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Dr. Öğr. Üyesi Burak Barutçu

EYLÜL, 2019

İTÜ, Enerji Enstitüsü'nün 301151012 numaralı Yüksek Lisans Öğrencisi İrem Damla NACAR, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DOĞRUSAL VE DOĞRUSAL OLMAYAN METOTLARLA BİR ADIM İLERİ RÜZGAR ŞİDDETİ ÖNGÖRÜSÜ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Burak Barutçu**

İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Şükran Sibel Menteş**

İstanbul Teknik Üniversitesi

Prof. Dr. Zafer Aslan

İstanbul Aydın Üniversitesi

Teslim Tarihi : **20 Eylül 2019**

Savunma Tarihi : **28 Ağustos 2019**

ÖNSÖZ

Bu çalışmanın gerçekleştirilmesi süresince engin bilgi birikimini benimle paylaşan sayın tez danışmanım Burak Barutçu'ya teşekkür ederim.

Ağustos 2019

İrem Damla Nacar
(Kontrol ve Otomasyon Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ	1
1.1 Dünya’da Yenilenebilir Enerjinin ve Rüzgar Enerjisinin Genel Durumu	3
1.2 Türkiye’de Yenilenebilir Enerjinin ve Rüzgar Enerjisinin Genel Durumu	6
1.3 Rüzgar Şiddeti Öngörüsünün Önemi	10
1.4 Literatür Araştırması	11
2. YÖNTEM.....	17
2.1 Zaman Serisi ve Durağanlık Tanımları	17
2.2 Öngörü Yöntemleri	18
2.2.1 Doğrusal modeller: Box-Jenkins Modelleri.....	19
2.2.1.1 Otoregresif (AR) model	21
2.2.1.2 Hareketli ortalama (MA) modeli.....	21
2.2.1.3 Otoregresif hareketli ortalama (ARMA) modeli.....	22
2.2.1.4 Bütünleşik otoregresif hareketli ortalama (ARIMA) modeli	23
2.2.1.5 Otoregresif eksojen (ARX) model	24
2.2.1.6 Otoregresif hareketli ortalama eksojen (ARMAX) modeli.....	25
2.2.1.7 Doğrusal modellerde mertebenin belirlenmesi	26
2.2.2 Doğrusal olmayan modeller: Yapay sinir ağları	26
2.2.2.1 İleri beslemeli yapay sinir ağı (FFN)	30
2.2.2.2 Radyal tabanlı fonksiyon ağları (RBFN)	35
2.2.2.3 Genelleştirilmiş regresyon sinir ağları (GRNN)	37
2.3 Model Performanslarının Değerlendirmesi	38

3. BENZETİM ÇALIŞMASI.....	41
3.1 Doğrusal Modeller.....	42
AR Modeli.....	42
ARMA Modeli	43
ARIMA Modeli	44
ARX Modeli.....	47
ARMAX Modeli	48
3.2 Doğrusal Olmayan Modeller	50
FFN Modeli	50
RBFN Modeli.....	51
GRNN Modeli	53
4. SONUÇ VE ÖNERİLER.....	55
KAYNAKLAR.....	59
ÖZGEÇMİŞ	67

KISALTMALAR

ACF	: Autocorrelation Function
ACVF	: Autocovariance Function
AE	: Absolute Error
AIC	: Akaike Information Criterion
ANN	: Artificial Neural Network
ANFIS	: Adaptive Network-Based Fuzzy Inference System
AR	: Auto Regressive
ARMA	: Auto Regressive Moving Average
ARIMA	: Auto Regressive Integrated Moving Average
ARX	: Auto Regressive with Exogenous Input
ARMAX	: Auto Regressive Moving Average with Exogenous Input
BIC	: Bayesian Information Criterion
BNEF	: Bloomberg New Energy Finance
BPA	: Back Propagation Algorithm
EBP	: Error Backpropagation Algorithm
EIA	: Energy Information Administration
EİE	: Elektrik İşleri Etüt İdaresi
ESS	: Error Sum of Squares
FFN	: Feed-forward Neural Network
FIS	: Fuzzy Inference Systems
FPE	: Final Prediction Error
GRNN	: Generalized Regression Neural Network
GWEC	: Global Wind Energy Council
MA	: Moving Average
MAE	: Mean-Absolute Error
MBE	: Mean-Bias Error
MLP	: Multi-layer Perceptron
MSE	: Mean-Square Error

NWP	: Numerical Weather Prediction
OAEC	: Organization of Arab Petroleum Exporting Countries
RBFN	: Radial Basis Function Neural Network
ReLU	: Rectified Linear Units
REPA	: Türkiye Rüzgar Enerjisi Potansiyel Atlası
RES	: Rüzgar Enerjisi Santrali
RMSE	: Root-Mean-Square Error
RNN	: Recurrent Neural Network
SVM	: Support Vector Machines
TSS	: Total Sum of Squares
TÜREB	: Türkiye Rüzgar Enerjisi Birliği

SEMBOLLER

B	: Geri kaydırma operatörü
b	: Bias değeri
d	: ARIMA modeli için fark alma derecesi
d_t	: Doğrusal deterministik zaman serisi
E	: Uygunluk değeri
e_p	: Hata ifadesi
e_t	: Beyaz gürültü
J	: Jakobiyen matrisi
$L(w)$	: Kayıp fonksiyonu
N	: Sinir ağı için eğitim veri setinin eleman sayısı
n_a	: ARX ve ARMAX modellerinde AR mertebesi
n_b	: Eksojen giriş mertebesi
n_c	: ARMAX modelinde MA mertebesi
n_k	: Örnek gecikmesi
p	: AR mertebesi
q	: MA mertebesi
s_j	: Ağırlıklandırılmış toplamın değeri
u_t	: Beyaz gürültünün geçmiş değerlerinin doğrusal kombinasyonu
w_{nj}	: Nöron için ilgili girişin ağırlığı
x_c	: Hesaplanan değer
x_m	: Gözlem (ölçüm) değeri
$\bar{x}_m$	: Gözlem (ölçüm) değerleri ortalaması
x_N	: Normalizasyon değeri
x_n	: Nöron girişi
x_p	: Zaman serisinin önceki değerleri
y	: Nöron çıkışı
z	: Bağımlı değişken

$\phi(\mathbf{B})$	: AR operatörü
$\phi(.)$	: Aktivasyon fonksiyonu
$\mathbf{a}_t$	: Rastlantısal hata terimi
β	: Genişlik parametresi
$\gamma_x(\mathbf{h})$	: Otokovaryans fonksiyonu
$\gamma_x(\mathbf{r}, \mathbf{s})$	: Kovaryans fonksiyonu
θ	: Parametre vektörü
$\theta(\mathbf{B})$	: MA operatörü
λ	: Kombinasyon katsayısı
μ	: RBF nöronları için prototip
$\mu_x(\mathbf{t})$	: Ortalama fonksiyonu
$\rho_x(\mathbf{h})$	: Otokorelasyon fonksiyonu
∇	: Fark operatörü
$\langle \rangle$	: Ortalama değer operatörü

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 1.1: Türkiye’deki potansiyel rüzgar enerjisi.....	10
Çizelge 2.1: Örnek model yapıları.....	20
Çizelge 2.2: Önemli aktivasyon fonksiyonları.	28
Çizelge 4.1: En iyi başarımları gösteren modeller ve hata kriterleri.	57

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1:	1965-2016 yılları arasında Dünya’da kaynaklara göre bağıl enerji tüketimi	2
Şekil 1.2:	1850-2017 yılları arası Dünya’daki enerji tüketiminin kaynaklara göre dağılımı	2
Şekil 1.3:	1965-2016 yılları arası Dünya’daki yenilenebilir enerji tüketiminin kaynaklara göre dağılımı.....	3
Şekil 1.4:	Dünya’da 2001-2017 yılları arasındaki rüzgar enerjisinin kurulu gücü .	5
Şekil 1.5:	Kişi başına düşen rüzgar enerjisi kurulu gücünün ülkelere göre sıralaması.....	6
Şekil 1.6:	Türkiye’de üretilen elektrik enerjisinin kaynaklara göre dağılımı.....	7
Şekil 1.7:	Türkiye’nin yerli ve ithal kaynak bazında kurulu gücü	7
Şekil 1.8:	Türkiye’de kaynaklara göre elektrik enerjisi kurulu gücü	8
Şekil 1.9:	2008-2018 yılları arasında Türkiye’deki rüzgar enerjisi santrallerinin kurulu güç değerleri ve bağıl artışı.....	8
Şekil 1.10:	Türkiye’nin rüzgâr enerjisindeki kurulu gücünün bölgelere göre dağılımı	9
Şekil 2.1:	Gürültüyle sürülen model yapısı blok diyagramı	20
Şekil 2.2:	ARX model yapısı blok diyagramı	24
Şekil 2.3:	ARMAX model yapısı blok diyagramı	25
Şekil 2.4:	Bir nöronun yapısı.....	27
Şekil 2.5:	FFN ağ yapısı	30
Şekil 2.6:	EBP algoritmasının şematik ifadesi	32
Şekil 2.7:	RBF ağ yapısı.....	35
Şekil 2.8:	RBF nöronu aktivasyon değerleri	36
Şekil 2.9:	Değişen genişlik parametresine göre Gauss fonksiyonu.....	37
Şekil 2.10:	GRNN ağ yapısı	38
Şekil 3.1:	AR(19) modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği	42
Şekil 3.2:	En iyi AR modeli için korelasyon grafiği	43
Şekil 3.3:	ARMA(19,1) modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği	43
Şekil 3.4:	En iyi ARMA modeli için korelasyon grafiği.....	44
Şekil 3.5:	d=1 iken en iyi ARIMA modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği	45
Şekil 3.6:	d=2 iken en iyi ARIMA modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	45
Şekil 3.7:	d=1 iken en iyi ARIMA modeli için korelasyon grafiği.....	46
Şekil 3.8:	d=2 iken en iyi ARIMA modeli için korelasyon grafiği.....	46

Şekil 3.9:	En iyi ARX modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	47
Şekil 3.10:	En iyi ARX modeli için korelasyon grafiği	48
Şekil 3.11:	En iyi ARMAX modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	49
Şekil 3.12:	En iyi ARMAX modeli için korelasyon grafiği	49
Şekil 3.13:	En iyi FFN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	50
Şekil 3.14:	En iyi FFN modeli için korelasyon grafiği.....	51
Şekil 3.15:	En iyi RBFN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	52
Şekil 3.16:	En iyi RBFN modeli için korelasyon grafiği	52
Şekil 3.17:	En iyi GRNN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.	53
Şekil 3.18:	En iyi GRNN modeli için korelasyon grafiği.....	54

DOĞRUSAL VE DOĞRUSAL OLMAYAN METOTLARLA BİR ADIM İLERİ RÜZGAR ŞİDDETİ ÖNGÖRÜSÜ ÖZET

Rüzgar, bol bulunan ve temiz bir enerji kaynağı olması, kurulan rüzgar enerjisi sistemlerinin işletme maliyetlerinin düşük olması, alternatiflerine göre aynı miktarda enerji üretimini daha küçük bir alanda gerçekleştirebilmesi gibi avantajları sayesinde yenilenebilir enerji kaynakları arasında ön plana çıkmaktadır. Son yıllarda yaşanan teknolojik gelişmelerin beraberinde rüzgar enerjisi sistemleri Dünya’da gün geçtikçe daha fazla yer edinmektedir. Ancak rüzgar enerjisi üretiminin temel faktörlerinden olan rüzgar şiddetinin pek çok parametreden etkilenen, belirsiz ve kesikli yapıda olması rüzgarın enerji sistemlerinde kullanılması konusunda zorluk yaratmaktadır. Bu sorun doğrultusunda yürütülen çalışmalarda, rüzgar şiddetinin öngörüsünün yapılması konusuna ağırlık verilmiştir.

Bu çalışmada doğrusal ve doğrusal olmayan toplam 8 adet modelden faydalanılarak bir adım ileri rüzgar şiddeti öngörüsü yapılması ve bu öngörünün doğruluğunun değerlendirilmesi amaçlanmıştır. Bu modeller doğrusal ve doğrusal olmayan modeller olarak iki grupta ele alınan; eksojen modelleri de kapsayan Box-Jenkins modelleri ve yapay sinir ağı modelleridir. Modellerin öngörü sonuçları arasında karşılaştırmanın yapılabilmesi amacıyla yaygın olarak kullanılan R^2 , MAE, MBE, RMSE gibi hata kriterlerinden faydalanılmıştır.

Oluşturulan bütün modeller içinde öngörü performansı en iyi olan model ARX olarak belirlenmiştir. ARMAX modeliyle yapılan öngörü ARMA modelinden daha yüksek başarıma sahip olmuştur. Eldeki rüzgar verisi için eksojen giriş kullanarak öngörü yapılmasının daha uygun olduğu; hareketli ortalama (MA) terimlerinin ise bu veri için anlamlı bir katkı sağlamadığı görülmüştür. Öngörüde en başarısız olan model ise GRNN olarak belirlenmiştir. Doğrusal olmayan sistemlerdeki başarısı ve gürültü toleransının yüksek olması gibi sebeplerle yüksek bir öngörü performansı göstermesi beklenen yapay sinir ağıları modelleri ise eksojen modellerin gerisinde kalmıştır.

ONE STEP AHEAD WIND SPEED PREDICTION WITH LINEAR AND NONLINEAR METHODS SUMMARY

Wind energy, due to the abundance of the resource and low operating costs of installed systems, is one of the most exploited renewable energy sources. Wind farms operate without producing carbon dioxide (CO_2) and require relatively small terrain for the same amount of power compared to its alternatives. Besides, like other renewable energy sources, using wind energy has critical significance to increase energy security for the country. Wind energy has become one of the fastest growing renewable energy resources for electricity generation in recent years due to these advantages.

Wind speed is the major factor that affects the wind power generation. However, it is affected by number of parameters such as pressure gradient, local weather conditions, frictional forces, Coriolis Effect. Electricity production from wind confronts many problems related to its uncertain and intermittent nature. In line with the problem, prediction is the key factor for scheduling maintenance of a wind farm, taking preventive actions for extreme wind speeds, integrating wind power in a conventional power grid, ensuring power supply quality while operation costs can easily increase with underachieved prediction. Thus, achieving accurate wind speed prediction is noteworthy research area tha wide variety of methods have been studied such as since it is known each method has different advantages and limitations.

Accordingly, in the study, it was aimed to make one-step ahead prediction by using proposed linear and non-linear methods and to evaluate the accuracy of the prediction. Linear prediction models which are also called Box-Jenkins models includes AR model, ARMA model, ARIMA model, ARX model which is simply AR model with exogeneous input and lastly ARMAX model which is ARMA model with exogeneous input. Feed-forward Network, Radial Basis Function Network, and Generalized Regression Network that are the structures of artificial neural networks, were examined in non-linear models category. All of the one-step ahead wind speed prediction models are derived from raw wind speed data that was collected from

Atatürk Havalimanı at 10 meters of the year 2005. Data has one minute sampling period and was obtained via Automated Weather Observing System (AWOS).

Autoregressive (AR) model predicts the variable of interest (in this case, wind speed) using a linear combination of past values of the variable. Moving Average (MA) model, in a similar way, predicts the wind speed value using past prediction errors in a model. With combining these two models, Autoregressive Moving Average (ARMA) model is obtained. These three models are exploited under the assumption of the time series is stationary. However, mostly time series may contain trends and seasonality which make the series non-stationary. In this case, differencing is used for making time series stationary. This operation is simply the replacement of data by the difference between its previous values and data itself. Letter I represents differencing in Autoregressive Integrated Moving Average (ARIMA) model. After differencing the time series, prediction is performed as ARMA model.

In addition to conventional AR ve ARMA model, by exploiting exogenous input to make prediction, two models are obtained and investigated: ARX and ARMAX models. These models are used shifted wind speed data as exogeneous input. It should be expressed that exogeneous models have the same time series stationarity requirements. In the study, model orders were increased at a certain value and calculations were made for all of the aforementioned Box-Jenkins models to find best predictive model of each structure.

Artificial neural network is frequently used nonlinear prediction tool because of having noise tolerance, its ease of use, and its capability of handling complex nonlinear characteristics. Its main difference from conventional Box-Jenkins methods is its adaptivity. Each time data are passed through the network, error between actual and predicted value is calculated and it is reduced by adjusting the weights until it comes to an acceptable level. This process is called learning and the artificial neural network models that were investigated in the study are in the category of supervised learning. Supervised learning is the task for mapping an input to an output by using example data set which consists of input-output pairs. For each ANN model, one-fourth of the wind speed data was separated for testing of the network such that successive three data goes to train set and fourth data goes to test set. After the network is trained, each model is used for making prediction. Neural networks include input, output and hidden layers that are the groups of input, output

and hidden neurons as their names referred. Feed-forward network architecture was constructed such as having one layer of each. Trials were conducted by changing the number of input neurons and hidden neurons, the FFN model with the best prediction performance was found. RBFN have input layer, RBF neuron layer and output layer in addition to one width parameter to adjust. The best model of this architecture was found by changing the number of embedding dimension and width parameter value. Similarly, best GRNN model was found by changing these two parameters.

Once the model parameters are obtained for each proposed methods and predictions are performed, in order to assess the prediction performance, R^2 , MAE, MBE, RMSE are used as metrics in the study. At the conclusion, the comparison table with performance metrics of the best models of each model family and order of these models are given. Graphs that involves actual and predicted value of the best model and correlation graph were drawn for each model.

Results show that among all predictive models, ARX has the best prediction performance with $R_1^2 = 0,999883$. ARMAX models give better results than ARMA models. Prediction using exogenous input is more suitable for used wind dataset; and the sliding average (MA) model did not provide a significant contribution for the dataset. It is deduced that despite all the advantages of handling a nonlinear problem, exogenous models should be considered as an alternative to ANNs in prediction problems.


Further studies might assess the wind speed prediction performance when prediction horizon is bigger than one as in this study. Additively, to consolidate the outputs of this study, a study might be conducted for wind speed data that is collected from terrains with different topographic factors. Last but not least, wind speed data that has different sampling periods can be used to research prediction performance of proposed models.

1. GİRİŞ


İnsanoğlu binlerce yıldır Dünya'nın en eski enerji formları olarak isimlendirilebilecek güneş, rüzgar, su ile çalışan basit makineleri kullanarak tahıl öğütmek, odun kesmek, demir dövmek, su pompalamak gibi günlük hayattaki çoğu ihtiyacını karşılayabilmekteydi. Makine ve gemi yapımında, demirin eritilmesinde, tuğla yapımında, inşaatta vb. temel yakıt olarak kullanılan odunun azalması ise kömür kullanımını gündeme getirdi. 17. yüzyılın sonlarında kömür kullanımının artmasını 18. yüzyılın ikinci yarısından itibaren kömür maliyetlerinin düşürülmesi takip etti. Buhar makinelerinin veriminin artmasını sağlayan çalışmalar ve kullanımlarının yenilenebilir kaynakların aksine coğrafi kısıtları olmayışı (su gücü için nehirlerle yakın konumlanma vb.) gibi faktörler yakıt olarak kömürden faydalanan bu makinelerinin yaygınlaşmasında belirleyici rol oynadı. Bunun gibi teknolojik gelişmeler ışığında mevcut buhar makineleriyle daha büyük sistemlerin enerjilendirilmesinin mümkün olmasıyla ve Sanayi Devrimi'nin yaşanmasıyla birlikte kömürün 19. yüzyılın başlarında ana enerji kaynağı haline gelmesi kaçınılmaz olmuştur. İngiltere'de başlayan bu değişim dünyada da hızla yayılmış ve yenilenebilir enerji kaynakları yerini yenilenemez fosil yakıtlara bırakmaya başlamıştır.

Elektrik enerjisinin günlük hayatta kullanımı 1800'lerin sonuna yaklaşıldığında başlamıştı. Artan nüfusla birlikte enerji talebinin de artarak ilerlediği bu süreçte 1870'lerden sonra enerji kaynağı olarak kömürün arkasından petrol ve türevleri büyük önem kazandı. 1900'lerin ortasına gelindiğinde kömür hala ana enerji kaynağıydı ancak bu dönemden 20. yüzyılın sonuna kadar petrolün birincil enerji kaynağı kullanımı içindeki oranı Şekil 1.1'de verildiği üzere kömür kullanımına nazaran artış eğilimi göstermiştir. Petrol kullanımındaki artış 1973'te patlak veren Petrol Krizi'yle birlikte Petrol İhraç Eden Arap Ülkeleri Birliği (OAPEC) tarafından Amerika ve Hollanda'ya petrol sevkiyatlarına uygulanan ambargo sonucunda istemsiz bir şekilde ivmesini kaybetti. OAPEC ülkeleri petrol üretimlerini azalttı; bu tarihe kadar stabil olan petrol fiyatlarının birkaç yıl içerisinde 2 kattan fazla artmasını

barındıran süreçte Hollanda ve Amerika petrole bağımlılıklarından ötürü enerji maliyetlerini düşürmek için alternatif arayışlarına yöneldi. Krizi takip eden 15 yıllık süreçte yenilenebilir enerjiye ve özellikle rüzgar enerjisine duyulan ilgi yeniden artmıştır ve araştırma-geliştirme faaliyetleri gelişmiş ülkelerde devlet teşviğiyle birlikte ivme kazandığından ötürü ticari rüzgar türbini pazarı tarımsal ve evsel uygulamalardan (1-25 kW) şebekeye bağlı rüzgar santrali uygulamalarına (50-600 kW) evrildi [1]. 1850’den günümüze kadar olan kaynaklara göre enerji tüketimi grafiği Şekil 1.2’de verilmiştir.




Şekil 1.1: 1965-2016 yılları arasında Dünya’da kaynaklara göre bağlı enerji tüketimi.



Şekil 1.2: 1850-2017 yılları arası Dünya’daki enerji tüketiminin kaynaklara göre dağılımı.

1.1 Dünya’da Yenilenebilir Enerjinin ve Rüzgar Enerjisinin Genel Durumu

Elektrik tüketimi miktarının ve kullanılan enerji kaynaklarının bir ülkenin dışa bağımlılığı konusundaki belirleyici rolü ve gelişmişlik düzeyinin göstergesi olması sebebiyle, ülke ekonomisiyle direkt ilişkilendirilen önemli faktörlerdendir. Hidrolik, rüzgâr, güneş, jeotermal ve biyokütle gibi temiz ve yenilenebilir kaynakların kullanımının artırılması dışa bağımlılığı azaltacağından ve enerji arz güvenliğini sağlamanın direkt bir yolu olduğundan günümüzde devletler enerji politikalarını yenilenebilir kaynakların kullanımını merkeze almaya gayret göstererek belirlemektedir. Bunun yanında fosil yakıtların tükeniyor olması, fiyatlandırmasındaki dalgalanmalar, kullanımından doğan çevresel sorunların yarattığı kaygı da bu yönde adımlar atılmasına teşvik edici olmaktadır. Genellikle değişken doğası olan yenilenebilir kaynakların verimli bir şekilde şebeke entegrasyonunu mümkün kılan teknolojik gelişmelerle birlikte, kullanımları günümüz enerji sistemlerinde yerini sağlamlaştırmıştır. Yenilenebilir kaynaklar yıllık ortalama %9,8 büyüme payına sahip olarak dünyada en hızlı büyüyen enerji kaynaklarıdır [2]. 1965-2016 yılları arasındaki kaynaklara göre Dünya’daki yenilenebilir enerji tüketimi grafiği Şekil 1.3’te verilmiştir.




Şekil 1.3: 1965-2016 yılları arası Dünya’daki yenilenebilir enerji tüketiminin kaynaklara göre dağılımı.

Bahsedilen teşvik edici sebepler doğrultusunda pek çok ülke Kyoto Protokolü (1997) ve Paris Anlaşması (2015) gibi uluslararası anlaşmalara taraf olarak enerji kaynağı olarak fosil yakıtlardan uzaklaşıp yerine yenilenebilir enerji kaynaklarına yönelmeyi

hedeflediğini beyan etmekte ve bu amacı gerçekleştirmeye yönelik çalışmalarını sürdürmektedir. Artan sera etkisine yönelik tedbirler almak ve dolayısıyla küresel iklim değişikliğiyle mücadele etmek maksadıyla bir araya gelen 169 ülke Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi'ne ek bir anlaşma olan Kyoto Protokolü'nü imzalamıştır. Protokolün yürürlüğe girmesinin koşulu 1990 yılındaki sera gazı emisyonlarının en az %55'inden sorumlu olan 55 ülkenin protokolü onaylaması olduğundan protokol ancak 2005'te Rusya'nın katılımıyla birlikte yasal açıdan bağlayıcı olarak yürürlüğe girebilmiştir [3]. 2009 yılı itibarıyla imza atmış ülkelerin sayısı Türkiye'nin de katılımıyla 184'e ulaşmıştır. Katılım gösteren sanayileşmiş ülkeler sera gazı emisyonunu azaltacaklarını; azaltamadıkları takdirde salınım ticareti yoluyla haklarını arttırmayı kabul etmiştir. Bu ülkeler birinci taahhüt döneminde başta karbondioksit (CO_2) ve metan (CH_4) olmak üzere, atmosfere saldıkları sera gazlarının 2012 yılına kadar, 1990 yılındaki düzeyinin toplam %5,2 altına düşürülmesini kabul etmişken; ikinci taahhüt döneminde ise 2020'de bu düzeyin en az %18 altına düşülmesi bu ülkeler tarafından kararlaştırılmıştır [4].

Rüzgar enerjisi temiz, elektrik üretim maliyeti teknolojik gelişmelerle birlikte günden güne düşürülebilen, alternatiflerine göre büyük araziler gerektirmeyen bir kaynak olması gibi olumlu özellikleriyle diğer yenilenebilir enerji türlerinden ayrılıp öne çıkmaktadır. Dünya geneline bakıldığında 2000-2016 yılları arasında kullanım oranı olarak en büyük büyüme ivmesini gösteren enerji türünün rüzgar enerjisi olması bunu kanıtlar niteliktedir [5]. 2001-2017 yılları arasındaki kümülatif rüzgar enerjisi kurulu gücü grafiği GW cinsinden Şekil 1.4'te verilmiştir. Küresel Rüzgar Enerjisi Konseyi (GWEC)'nin verilerine göre 2018'in sonunda, 2017'nin sonuna kıyasla %9,6 artış göstererek 591 GW'a ulaşan kurulu rüzgar enerjisi kapasitesi 2001'de 24 GW mertebelerindeydi [5].

Uygun coğrafya ve iklim koşullarına sahip olduğunda bir ülkenin enerji talebini karşılamada rüzgar enerjisinin payı tartışılmaz olduğundan ötürü pek çok ülke rüzgar enerjisi yatırımlarını artırmaktadır. Rüzgar enerjisinin ticarileşmesinde 1970'lerde öncü konumunda olan ve günümüzde de kullandığı enerji kaynakları arasında en büyük paya rüzgarın sahip olduğu ülke Danimarka'da rüzgar enerjisinden faydalanılarak elde edilen elektriğin ülkenin toplam elektrik tüketimindeki payı 2013 ve 2014'te sırasıyla %33 ve %39 iken, 2017'de %43,6'ya yükselmiştir [6].




Şekil 1.4: Dünya’da 2001-2017 yılları arasındaki rüzgar enerjisinin kurulu gücü.

Danimarka’nın 2035’e kadar elektrik ve ısıtma sektörlerindeki ihtiyacının %100’ünü yenilenebilir enerjiden sağlama hedefinin yanısıra kısa vadede amacı 2020’ye kadar elektrik tüketiminde rüzgar enerjisinin payını %50’ye çıkarabilmektir [7]. Benzer şekilde İskoçya’nın 2018 Kasım ayında ürettiği rüzgar enerjisi ülkedeki aylık enerji talebinin %109’una karşılık düşecek seviyedeydi [8]. Almanya’da nükleer enerjiye olan karşıtlık nedeniyle rüzgar enerjisine büyük yatırımlar yapılmaktadır; Almanya 2013 yılı sonunda 34.658 MW olan kurulu gücünü 2017 yılı sonunda 56,164 MW’a çıkartmıştır [9]. Günümüzde Dünya’daki en yüksek kurulu rüzgar gücüne sahip Çin Halk Cumhuriyeti yaptığı büyük ölçekli yatırımlara rağmen 2010 yılında elektriğinin %80’ini kömürden elde eden bir ülke olarak 2017 yılında bunu %60’a düşürebilmiştir [10]. 2016’da belirlediği Beş Yıllık Plan’a göre toplam yenilenebilir güç kapasitesini artırma hedefinin yanısıra 2016’da yaklaşık 149 GW olan kurulu rüzgar gücünü de 210 GW’a çıkarmayı amaçlamaktadır [11]. ABD Enerji Enformasyon İdaresi (EIA) verilerine göre yenilenebilir enerji kaynaklarının kullanımındaki trende bakıldığında 2040’a gelindiğinde dünyada en büyük büyümenin sırasıyla rüzgar ve güneş enerjisi kullanımında görülmesi beklenmektedir [12].

Dünyadaki rüzgar kurulu güç miktarlarına bakıldığında Çin Halk Cumhuriyeti ve Amerika Birleşik Devletleri’nin ilk iki sırada olması kurulu gücün ülkedeki enerji talebiyle ve dolayısıyla ülkenin büyüklüğü ve gelişmişlik düzeyiyle doğrudan ilgisi olduğunu destekleyici niteliktedir. 2015 verileri kullanılarak ülkelerdeki kişi başına

düşen Watt cinsinden kurulu rüzgar enerjisi hesaplandığında elde edilen grafik Şekil 1.5'te verilmiştir. Bu grafikte Danimarka, İsveç gibi ülkeler ilk sıralarda iken Amerika Birleşik Devletleri 10., Çin Halk Cumhuriyeti ise 20. sırada yerini almıştır.




Şekil 1.5: Kişi başına düşen rüzgar enerjisi kurulu gücünün ülkelere göre sıralaması.

1.2 Türkiye’de Yenilenebilir Enerjinin ve Rüzgar Enerjisinin Genel Durumu


Artan nüfusla birlikte artan kentleşme ve sanayileşme sonucunda Türkiye’de 2002-2016 yılları arasında elektrik enerjisi tüketiminde yıllık ortalama %5,4 artış görülmüştür [13]. 2019 itibarıyla sonrasındaki 20 yıllık dönem için ise referans senaryoya göre yıllık ortalama %3,36 artış öngörülmektedir [14]. Bu tablo Türkiye’de hızla artan enerji talebini karşılamak için yapılan yatırımların artarak devam etmesi gerektiğini göstermektedir.

Türkiye’de üretilen elektrik enerjisinin 2014-2016 yılları arasında kaynaklara göre dağılımını veren Şekil 1.6 incelendiğinde üretimdeki en büyük paya termik santrallerin sahip olduğu görülür. Yıllar içerisinde fosil yakıt kullanımı azalsa da günümüzde hala açık farkla en çok kullanılan kaynaktır; yenilebilir kaynaklara yönelim ise yavaş ama istikrarlı bir şekilde artmıştır. Şekil 1.7’ye bakıldığında ise 2016 sonu itibarıyla yerli kaynak kullanımını esas alan kurulu güç miktarının toplamdaki payı %56,6 iken ithal kaynaklardan yakıt sağlayan santrallerin kurulu gücü ise %43,4’dür. Geçen yıllara rağmen ithal enerji bağımlılığında ciddi bir azaltıma gidilememesi Türkiye’nin ekonomik ve siyasal bağımsızlığının önünde


ciddi bir engel olarak durmaktadır. Ülkenin 2023 yılı için yenilenebilir enerji kaynaklarının elektrik üretimindeki payının en az %30'a yükseltilmesini hedef olarak belirlemesi [15] de gözönüne alındığında halihazırda enerji ihtiyacının önemli bir kısmını ithalatla ve fosil kaynaklarla sağlayan Türkiye'nin mevcut tabloyu değiştirebilmesi için sahip olduğu yenilenebilir enerji potansiyeli doğrultusunda adımlar atması gerekmektedir. Enerji kaynaklarına göre kurulu güç değerlerini veren Şekil 1.8'e bakıldığında, 2002-2016 döneminde ülkedeki kurulu gücünü özellikle 2010'dan sonra ciddi bir şekilde arttıran rüzgar göze çarpmaktadır. Kayda değer bir başka artış olan jeotermal kaynaklı kurulu güç değeri ise 2012'den 2016'ya yaklaşık beş katına ulaşmıştır.



Şekil 1.6: Türkiye'de üretilen elektrik enerjisinin kaynaklara göre dağılımı.




Şekil 1.7: Türkiye'nin yerli ve ithal kaynak bazında kurulu gücü.




Şekil 1.8: Türkiye’de kaynaklara göre elektrik enerjisi kurulu gücü.

Ülkemizde rüzgar enerjisinin durumu detaylı incelenecek olursa, ilk rüzgar santralinin kurulu gücü 1,5 MW olup 1998 yılında İzmir’de kuruldu. 2005’e kadar ülkede rüzgar enerjisi alanında ciddi gelişmeler yaşanmadı ancak bu yılda yürürlüğe giren 5346 Sayılı Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun, Türkiye Rüzgar Enerjisi Potansiyel Atlası (REPA)’nın yayımlanması, elektriğe alım garantisinin getirilmesi ve teknolojinin ilerlemesi ile birlikte ciddi ilerlemeler kaydedildi [16]. Şekil 1.9’da Türkiye’deki rüzgar enerjisi santrallerinin kurulu gücünün yıllara göre artışı verilmiştir. 2017 yılında işletmeye eklenen 766 MW’lık rüzgar gücüyle birlikte ülkedeki toplam kapasite 6.872 MW olmuştur. 2014-2017 arası dönemde ise ortalama yıllık %22,46’lık bir kurulu güç artışı gerçekleştirilmiştir.



Şekil 1.9: 2008-2018 yılları arasında Türkiye’deki rüzgar enerjisi santrallerinin kurulu güç değerleri ve bağıl artışı.



Şekil 1.10: Türkiye'nin rüzgâr enerjisindeki kurulu gücünün bölgelere göre dağılımı.

2018 yılı Türkiye Rüzgar Enerjisi Birliği (TÜREB) istatistik raporu verilerine göre işletmede olan santrallere bölgesel bazda bakıldığında başta Ege bölgesi, sonrasında Marmara bölgesi olmak üzere ülkede toplam 171 adet rüzgâr enerjisi santrali mevcuttur [17]. Türkiye'nin rüzgâr enerjisindeki kurulu gücünün bölgelere göre dağılım grafiği Şekil 1.10'da verilmiştir. İl bazındaysa İzmir, Balıkesir ve Manisa illeri toplam güçte sırasıyla %19,64, %15,39, %9,55 pay sahibidir.

Bloomberg New Energy Finance (BNEF)'in 2014 tarihli analizi, Türkiye'nin 2030 yılında elektrik üretiminin %47'sini yenilenebilir enerji kaynaklarından sağlayabilmesinin mümkün olduğunu; rüzgâr enerjisi kurulu gücünün 2023 yılında 14 GW'a, 2030 yılında ise 27 GW'a ve benzer şekilde 2030 yılına gelindiğinde güneş enerjisi kurulu gücünün 24 GW'a yükselebileceğini göstermektedir [18]. Elektrik İşleri Etüt İdaresi (EİE) Rüzgar Ölçüm İstasyonları'ndan alınan veriler doğrultusunda oluşturulan REPA, potansiyel değerlendirmesi yapılabilmesi amacıyla hizmet eden parametrelerden birisi olan ortalama rüzgar şiddetlerine erişilmesine olanak sağlamıştır. Potansiyel rüzgar enerjisi santrali (RES) bölgesinin finansal açıdan tercih edilebilir olması için o bölgede 7 m/s ve üzeri rüzgar şiddetine ihtiyaç duyulması gözönüne alınarak oluşturulan Çizelge 1.1 aşağıda verilmiştir. Belirlenen

47.849 MW'lık kapasitenin 37.836 MW'ı karasal alanlarda, 10.013 MW'ı deniz üstü alanlardadır.

Sanayi Devrimi'nden itibaren küresel emisyonun %0,7'sinden sorumlu olan Türkiye'nin [19] önceki bölümde bahsedilen Kyoto Protokolü ile vaat ettikleri arasında 2030'a kadar sera gazı emisyon miktarını referans senaryoya göre %21'e kadar azaltmak, iletim ve dağıtım kayıplarını %15'e kadar düşürmek, 2030'a kadar rüzgar enerjisinden elektrik üretim kapasitesini (kurulu gücü) 16 GW'a çıkarmak gibi maddeler yer almaktadır. 2017 sonu itibariyle ülkedeki toplam RES kurulu gücü 7 GW civarındadır ve lisansı verilmiş olan toplam 10 GW'ı aşan kurulu güçte RES projesi bulunmaktadır [20].

Çizelge 1.1 : Türkiye'deki potansiyel rüzgar enerjisi.

50 m'de yıllık ortalama rüzgar şiddeti (m/s)	Kapasite (MW)
7.0-7.5	29.259,36
7.5-8.0	12.994,32
8.0-9.0	5.399,92
> 9.0	194,84

1.3 Rüzgar Şiddeti Öngörüsünün Önemi

Rüzgar çok sayıda faktörden etkilenebilen değişken ve belirsiz doğası olan bir enerji kaynağıdır. Bu nedenle kaotik ve rastgele salınım gösteren rüzgar şiddeti de, rüzgar enerjisinden elektrik üretiminin değişken miktarlarda olmasına sebep olmaktadır. Bu durum, üretim konusunda yapılacak herhangi bir tahmini de zorlaştırmaktadır. Özellikle rüzgar şiddeti öngörüsü, rüzgar santrallerinin potansiyel enerji üretimi öngörüsüne olanak tanıyıp finansal faydalar sunmasının yanısıra, üretimin ve dağıtımının planlanmasında yani şebeke operasyonlarının yönetilmesinde, enerji kalitesinin iyileştirilmesinde, santralin işletme ve bakımında da önemli bir yer kaplamaktadır [21-27]. İşletmedeki önemi, türbin için istenmeyen bir durum olan cut-off şiddetinden yüksek esecek rüzgarın zamanının önceden belirlenmesine ve koruyucu tedbirler alınabilmesine olanak tanınması gibi durumlardan ileri gelir [28]. Bunun yanında, bakım zamanlarının planlanmasında kaynağın uygunluğunu

değerlendirerek üretim kaybının minimumda tutulabileceği zaman penceresinin ayarlanabilmesi için de iyi yapılan bir rüzgar şiddeti öngörüsüne ihtiyaç duyulur [29]. Düşük başarımlı bir öngörü, rüzgar çiftliğinin işletme maliyetlerini kolayca artırabilir [30, 31]. Özetle, bir enerji kaynağı olarak rüzgarın ekonomik, verimli ve güvenilir bir biçimde değerlendirilmesi ve rüzgardan maksimum ölçüde faydalanılabilmesi ihtiyacı daha gelişmiş rüzgar şiddeti öngörüsü teknikleri üzerine çalışmalar yürütülmesi için teşvik edici olmuştur.

Rüzgar şiddeti öngörüsünün yapılması elektrik arz-talep dengesinin rüzgardaki salınımlardan etkilenmeyip düzgün bir şekilde sağlanmasında kritik bir yardımcı konumundadır. Bu değişkenliğin elektrik piyasasında yaratabileceği olumsuzlukları telafi etmek için RES sahiplerinin elektrik piyasasına iletim-dağıtım şirketleri ve enerji ticareti ile uğraşanlar tarafından kullanılmak üzere sbu doğrultuda hesaplayacakları enerji üretim tahminlerini sunması gerekmektedir [32].

1.4 Literatür Araştırması

Rüzgarın geniş ölçekli elektrik enerjisi üretiminde kullanılmasıyla birlikte öngörü doğruluğunun artırılması ihtiyacı doğmuştur. Bu amaç doğrultusunda yaklaşık son 20 yılda rüzgar şiddeti öngörüsü hatasının düşürülmesi amacıyla gerçekleştirilen çok sayıda çalışma bulunmaktadır. Konu rüzgar enerjisi üretimi iken özellikle kısa zaman aralıkları için doğruluğu yüksek bir öngörü yapılabilmesi gerektiğinden, bu öngörü tarihi çok daha eskiye dayanan hava durumu tahminleri için şiddet öngörüsü yapılmasından yöntemsel olarak ayrılmaktadır [33].

Öngörünün ne kadar ilerisi için yapılacağı, kullanılması avantaj sağlayacak modeli belirlemede önemli olduğundan probleme yaklaşımda değerlendirilmesi gereken bir kriterdir. Öngörü ufku baz alınarak yapılacak bir sınıflandırma için literatürde kesin sınırlarla tanımlanmış aralıklar bulunmamaktadır [34].

Öngörü modelleri temel olarak girişlerine göre fiziksel, istatistiksel ve bunların çeşitli kombinasyonlarından oluşan hibrit metotlar olarak gruplanabilir [35]. Bunların yanısıra gri kutu modelleri, yapay sinir ağları (ANN), destek vektör makineleri (SVM), dalgacık dönüşümü metodu vb. gibi çok farklı model yapısı da öngörü amacıyla kullanılmaktadır [36]. Her kategorideki metotların kendisine özgü karakteristikleri ve kısıtları olduğu bilinmektedir [37]. Fiziksel modeller arazi

özellikleri, yükseklik, pürüzlülük, basınç, sıcaklık gibi bazı fiziksel parametrelerin yanında Sayısal Hava Tahmini (NWP) model çıkışlarını da giriş verisi olarak kullanarak rüzgar şiddeti öngörüsü yaparlar [38].

İstatistiksel modeller ise kısa dönemli öngörüye uygunluğu nedeniyle tercih edilmektedir ancak bu modeli kullanırken öngörü ufku arttıkça öngörü hatasının da artacağı gözönünde bulundurulmalıdır [39]. Bu modeller temelde öngörülmesi istenen değişkenin geçmiş değerlerini model girişi olarak kullanır. İstatistiksel modeller fiziksel modellere göre geliştirmesi kolay ve daha düşük maliyetlidir [38]. Öngörü metodları Kalman filtresi [40], otoregresif (AR), hareketli ortalama (MA), otoregresif hareketli ortalama (ARMA), bütünleşik otoregresif hareketli ortalama (ARIMA), otoregresif eksojen (ARX) [41] model gibi zaman serisi modelleri ve yapay zeka temelli metodlar, diğer bir ifadeyle makina öğrenmesi algoritmaları olan yapay sinir ağları, destek vektör makineleri, bulanık çıkarım sistemi (FIS) gibi modellerden oluşur [34].

Bossanyi [42] 1985 yılında enerji üretim öngörüsü yapmak amacıyla ilk rüzgar öngörüsü modelini sunmuştur. Bu çalışmada ölçülen son 6 veriyi giriş olarak kullanan bir Kalman filtresi, takip eden dakikalar için rüzgar şiddeti öngörüsü yapmaktadır. Box-Jenkins metodolojisine dayalı modellere bakıldığında ARIMA modeli rüzgar şiddeti öngörüsünde kullanılan ilk modeldir [34]. Contaxis v.d. [43] oluşturduğu AR model ile 30 dakikadan 5 saate kadar olan belirli zaman aralıkları için rüzgar şiddeti öngörüsü yapmış; bunu hibrit bir dizel/rüzgar sisteminin kontrolü ve kısa dönemli operasyon planlaması için kullanmıştır. Torres v.d. [44] 5 adet farklı topografik özelliklere sahip bölgenin her biri için bir ARMA model kullanarak 9 yıla yaydığı çalışmasında saatlik ortalama rüzgar şiddetinin öngörüsünü yapmıştır. Uygulanan model sayesinde öngörü hataları referans modele göre %20 azaltılabilmektedir. Erdem ve Shi [45] çalışmasında rüzgar şiddeti ve yönünün öngörüsünün iyileştirilmesi amacıyla ARMA modeline dayalı 4 yaklaşım önermiştir. Hodge v.d. [46] oluşturduğu ARIMA modelindeki bazı model değişkenlerinin en iyi değerlerini belirlemek için sistematik bir yaklaşım geliştirmiş ve rüzgar çiftliği verilerini kullanarak oluşturulan bir örnek çalışma yapılan iyileştirmeleri göstermek için kullanılmıştır. Miranda ve Dunn [47] bir saat sonrası için rüzgar şiddeti öngörüsü yaparken rüzgar kaynağını Bayesian yaklaşım kullanarak karakterize edip bu yaklaşımı test ederken AR modelden faydalanmıştır. Miligan v.d. [48]

çalışmasında birden çok ARMA modeli tanımlayarak bir saat sonrası için hem rüzgar şiddetini hem de enerji çıktısını hesaplamıştır. Bu çalışmanın amacı ticari ölçekte kabul görmüş modellere alternatif sunmaktan ziyade farklı zaman periyodları için uygulanan modellerin başarımları arasında kıyaslama yapmak olarak ifade edilmiştir. Castro [49] çalışmasında karşılaştırma yapılabilmesi için aynı geçmiş verisini kullanarak oluşturulan ARMA ve yapay sinir ağının 3 örnek çalışma üzerinden öngörü performanslarını değerlendirmiştir. ARMA modelinin az bir farkla daha iyi öngörü yaptığıının ancak çok daha uzun zaman gerektirdiğinin sonucuna varmıştır.

Makina öğrenmesi yöntemlerinden en yaygın kullanılan modelleri içinde barındıran yapay sinir ağı yaklaşımı aracılığıyla değişkenler arasındaki doğrusal olmayan ilişkiler öğrenme süreci sonucunda ifade edilmektedir [50]. Bu modellerde kurulum daha kolaydır ve detaylıca oluşturulmuş matematiksel ifadelerle ihtiyaç duyulmaz [33]. Rüzgar şiddeti öngörüsü için sıklıkla başvuru olan yapay sinir ağı modellerine örnek çok katmanlı algılayıcılar (MLP), radyal tabanlı fonksiyon ağları (RBFN) [51, 52], uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) [53, 54] ve tekrarlayan sinir ağları (RNN) [55] vb. gibi modeller verilebilir. Bu modeller öngörü yeteneğini iyileştirebilen modeller olsalar da, her durumda zaman serisi modellerinden üstün olabileceklerini söylemek pek mümkün değildir [39].

More ve Deo [56] ileri beslemeli ve yinelemeli sinir ağı tekniği ve ARIMA modelini sırasıyla kullanarak Hindistan için kısa süreli rüzgar şiddeti tahminleri yapmıştır. Çalışma sonuçlarına göre sinir ağı ARIMA modelinden daha iyi bir performans sergilemiştir. Fonte ve Quadrado [57], saatlik ortalama rüzgar şiddetinin öngörüsü için bir 3-katmanlı ileri beslemeli sinir ağı yapısı oluşturmuştur. Giriş seçimleri geçmiş rüzgar şiddeti gözlemlerinin arasındaki korelasyon katsayılarına dayanarak yapılmıştır. Ayrıca modelin meteoroloji verisi kullanmadan da rüzgar öngörüsü yapabileceği ancak düşük bir öngörü doğruluğu sunacağı belirtilmiştir. Liang Wu v.d. [58] çalışmasında rüzgar şiddetinin geçmiş değerlerini kullanarak iki katmanlı yapay sinir ağı aracılığıyla bir öngörü yapmıştır. Bu model kısa dönemli rüzgar şiddeti öngörüsü için geri yayılım algoritmasını kullanmıştır. Bir 15 giriş nöronlu 1 gizli katmanlı olan sinir ağı modeli kullanan Lopez v.d. [59] seçilen arazi için ortalama rüzgar şiddetini %3'lük bir hatayla öngörebildiğinden hareketle güvenilir bir öngörü sunduğunu belirtmiş. Alexiadis v.d. [60] Yunanistan'da bir adanın rüzgar şiddeti öngörüsü için o adanın ve komşusu olan diğer adaların geçmiş rüzgar şiddeti

değerlerini giriş değişkeni olarak kullanarak sinir ağına dayalı bir model geliştirmiştir. 1 saatlik öngörü ufku için referans modele göre %32 iyileştirme sağlanmıştır; farklı bir lokasyon için iki saatlik öngörü ufkunda aynı modelin uygulanması çalışmasında da %27 iyileştirme sağlanmıştır[61]. Sfetsos [62] ARIMA modelleri, geleneksel sinir ağı ve ANFIS kullanarak yaptığı çalışmada en iyi sonuç verenin sinir ağı olduğunu, referans modele göre ortalama %20-40 arası iyileştirme sağlayabildiğini göstermiştir. Daha güncel bir çalışmada ise Sfetsos [63] bir saatlik rüzgar şiddeti öngörüsü yapmak için sinir ağı temelli iki model kullanmıştır. İlk modelde saatlik rüzgar şiddetinin son ölçülen değerleri giriş olarak kullanılıp referans modele göre sadece %3 iyileştirme görülmüştür. İkinci model ise sinir ağı çıkışlarını iteratif bir şekilde giriş olarak kullanmanın yanı sıra 10 dakika aralıklı rüzgar şiddeti zaman serisini de kullanıp %10 iyileştirme yakalamıştır. Potter [64] uyguladığı uyarlamalı ağ tabanlı bulanık çıkarım sistemi ile rüzgarın şiddetini ve yönünü birlikte hesaba katarak 2.5 dakika ilerisi için bir öngörü yapmıştır. Öğrenme algoritması olarak birden fazla metodu kombine ederek kullanan model esnek bir tasarıma sahip olduğundan hızlı salınımlı rüzgar verisine karşı da yüksek başarımlı göstermiştir.

Maqsood v.d [65] çalışmasında içlerinde rüzgar şiddetinin de bulunduğu 3 farklı meteorolojik değişken için 24 saat ötesi öngörüsü yapmak amacıyla çok katmanlı algılayıcı, tekrarlayan sinir ağı, radyal tabanlı ağ fonksiyonu yapılarını önermiştir. Her model her mevsim için ayrı eğitilmiştir ve en iyi sonuç RBF sinir ağı kullanılarak elde edilmiştir. Ancak çalışmada vurgulanan bir diğer nokta bütün modellerin kombinasyonu ile yapılmış olan öngörü neticesinde öngörü doğruluğunun artmış olmasıdır.

Yapay sinir ağları bazı örnekler için geleneksel zaman serisi modellerinden daha iyi performans sergilemeler de yerel minimuma düşme ve parametre seçimine karşı hassas olması gibi nedenlerle istenilen doğruluk seviyesine ulaşamaması da mümkün olmaktadır [66]. Bu modellerin öngörü performansını iyileştirmek için son yıllarda modelin optimal parametrelerinin belirlenmesi için akıllı optimizasyon algoritmaları geliştirilmesine ağırlık verilmektedir.

Yapılacak rüzgar şiddeti öngörüsünün doğruluğu kullanılan zaman serisinin karakteristiklerine, veri ön işleme tekniğine ve öngörü modelinin performansına bağlıdır [67]. Son yıllarda kullanımı artan hibrit modeller ise öngörü doğruluğunu

artırmak için çeşitli modellerin sahip olduğu avantajlardan faydalanılması amacıyla uygulanır [68]. Genellikle optimal sonucu veren öngörü modeli farklı modellerin kombinasyonlarıyla elde edilir [69]. Bu kombinasyonlar fiziksel-istatistiksel yaklaşımlar, birden fazla istatistiksel yöntemin birlikte kullanılması vb. olarak çeşitlendirilebilir [70].

2. YÖNTEM

2.1 Zaman Serisi ve Durağanlık Tanımları

Her biri belirli bir t anında alınmış x_t gözlem değerlerinden oluşan seriye zaman serisi adı verilir [71]. Zaman serisinden çıkarım yapmak için öncelikle varsayıma dayalı olasılık modeli veya model sınıfı, veriyi ifade etmek amacıyla kullanılır. Kullanıma uygun bir model yapısı seçildikten sonra bunu parametrelerin tahmini (kestirimi), modelin veriye uyum iyiliğinin test edilmesi (*ing.* goodness of fit) takip eder.

Zaman serisi modellemede ilk olarak serinin durağanlık koşulunu sağlamasına bakılır. Bir zaman serisinin ortalamasının, varyansının zaman boyunca sabit kalması halinde o seri durağandır denir. Serinin durağanlığı incelenirken veride görsel inceleme yapmanın yanısıra oluşturulacak olan otokorelasyon fonksiyonunun davranışından da faydalanılabilir [72].

$E(x_t^2) < \infty$ olan durağan zaman serisi x_t 'nin ortalama fonksiyonu ve kovaryans fonksiyonu sırasıyla Denklem 2.1'de verilmiştir.

$$\mu_x(t) = E(x_t) \quad (2.1.a)$$

$$\gamma_x(r, s) = Cov(x_r, x_s) = E[(X_r - \mu_x(r))(X_s - \mu_x(s))] \quad (2.1.b)$$

Buradan hareketle x_t 'nin h gecikme için otokovaryans fonksiyonu (ACVF) ve otokorelasyon fonksiyonu (ACF) sırasıyla Denklem 2.2'deki gibidir.

$$\gamma_x(h) = Cov(x_{t+h}, x_t) \quad (2.2.a)$$

$$\rho_x(h) \equiv \frac{\gamma_x(h)}{\gamma_x(0)} = Cor(x_{t+h}, x_t) \quad (2.2.b)$$

Bu tanımlamalar ışığında korelogram incelenirken seride gecikmeler arasındaki ilişkiler önemli (güven aralığını aşacak şekilde) ise, otokorelasyon fonksiyonunun

değerleri artan gecikmeler için ağır bir şekilde küçülüyorsa serinin durağan olmadığı sonucuna varılabilir [71].

Durağan olmayan zaman serilerinden trendin çıkarılması için fark alma işlemi uygulanması yaygın kullanılan bir yöntemdir. d kere farkı alındıktan sonra durağan hale gelen serilere fark durağan serileri denir. ∇ fark operatörü, B ise geri kaydırma operatörü (*ing.* backward shift operator) iken fark alma işlemi Denklem 2.3'te verilmiştir.

$$\nabla x_t = x_t - x_{t-1} = (1 - B)x_t = y_t \quad (2.3.a)$$

$$Bx_t = x_{t-1} \quad (2.3.b)$$

Fark ve geri kaydırma operatörlerinin genelleştirilmiş ifadeleri Denklem 2.4'te verilmiştir.

$$\nabla^d = (1 - B)^d \quad (2.4.a)$$

$$B^d y_t = y_{t-d} \quad (2.4.b)$$

Gerekli durumlarda fark alma işlemi serinin trendi ortadan kalkana kadar art arda yapılabilir; $d = 2$ olduğu durum için hesaplama Denklem 2.5'te verilmiştir.

$$\begin{aligned} y_t &= \nabla^2 x_t = \nabla (\nabla x_t) = (1 - B)(1 - B)x_t = (1 - 2B + B^2)x_t \\ &= x_t - 2x_{t-1} + x_{t-2} \end{aligned} \quad (2.5)$$

Durağanlık varsayımı modellemede matematiksel kolaylık sağlıyor olması açısından yapılmaktadır; istatistiksel özellikleri zamanla değişmeyen hiçbir seri yoktur [71].

2.2 Öngörü Yöntemleri

Geçmiş gözlem değerleri kullanılarak gelecek değerlerinin öngörüsünün yapılmaya çalışılması, zaman serisi analizinin önemli bir uygulamasıdır. Bu çalışmada ele alınan problem doğrultusunda amaç sistem güvenliği ve maliyeti için kabul görülen en düşük hata ile rüzgar şiddetinin gelecek değerlerinin öngörüsünün yapılabilmesidir.

2.2.1 Doğrusal modeller: Box-Jenkins Modelleri

Bir zaman serisi 1920'lere kadar yaygın kullanılan haliyle gürültü eklenmiş periyodik fonksiyon olarak Denklem 2.6'daki gibi ifade ediliyordu [73].

$$y_t = \sum_{j=1}^p [A_j \cos(t\Omega_j) + B_j \sin(t\Omega_j)] + \varepsilon_t \quad (2.6)$$

Udun Yule'un 1927 yılındaki güneş lekeleri döngüsü analiziyle büyük bir adım atılmıştır. Yule güneş lekelerinin periodogramda gördüğü özelliklerini açıklamak için alternatif bir model kullanılabileceği düşüncesinden hareketle alınan ölçüm değerlerinden (güneş lekeleri) çıkarım yaparak bu verinin iç serbestlik dereceli bir modele (günümüzde doğrusal AR modeli olarak adlandırılan model) uydurulmasını sağlamıştır. Doğrusal zaman serisi teorisinin temelleri böylelikle atılmıştır. e_t beyaz gürültü iken doğrusal bir r_t zaman serisinin genel gösterimi ise Denklem 2.7'de verilmiştir.

$$r_t = \mu + \sum_{i=1}^{\infty} \psi_i e_{t-i} \quad (2.7)$$

Doğrusal ve durağan serilerinin öngörüsünde başvuru ARIMA modelleri olarak da kapsamlandırılan modeller AR (Autoregressive), MA (Moving Average), ARMA (Autoregressive Moving Average), ARIMA (Autoregressive Integrated Moving Average) modelleridir. Bunun yanı sıra AR ve ARMA modellerine deterministik bir eksojen girişin eklenmesiyle bu yapılardan ARX (Autoregressive Exogenous) ve ARMAX (Autoregressive Moving Average Exogenous) modelleri oluşturulur.

Beyaz gürültü terimi $e(t)$ 'nin direkt hata olarak girdiği bir model, giriş-çıkış ilişkisini ifade etmedeki kolaylığı sebebiyle tercih edilen doğrusal fark denklemi formunda Denklem 2.8'de verilmiştir [74]. Ayarlanacak parametreleri veren parametre vektörü θ ise Denklem 2.9'da verilmiştir.

$$\begin{aligned} y(t) + a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) \\ = b_1 u(t-1) + \dots + b_{n_b} u(t-n_b) + e(t) \end{aligned} \quad (2.8)$$

$$\theta = [a_1 \dots a_{n_a} \ b_1 \dots b_{n_b}]^T \quad (2.9)$$

A ve B polinomları Denklem 2.10'daki gibi tanımlanırsa,

$$A(B) = 1 + a_1 B + \dots + a_{n_a} B^{n_a} \quad (2.10a)$$

$$B(B) = b_1 B + \dots + b_{n_b} B^{n_b} \quad (2.10b)$$


Bunun sonucunda gürültüyle sürülen doğrusal modelin genelleştirilmiş ifadesi Denklem 2.11'de verilmiştir.

$$A(B)y(t) = B(B)u(t) + \frac{C(B)}{D(B)}e(t) \quad (2.11)$$

Denklem 2.11'i oluşturan A, B, C, D polinomlarından hangilerinin kullanıldığına bağlı olarak çok sayıda farklı model yapısı oluşturulabilir. Buna örnek olarak çalışmada kullanılan bazı model yapıları ve türetilmeleri için gereken kullanılan polinomlar Çizelge 2.1'de verilmiştir. Bahsedilen modeller için blok diyagram gösterimi Şekil 2.1'de yer almaktadır.

Çizelge 2.1 : Örnek model yapıları.

Kullanılan Polinom	Model Yapısı
A C	ARMA
A B	ARX
A B C	ARMAX



Şekil 2.1: Gürültüyle sürülen model yapısı blok diyagramı.

2.2.1.1 Otoregresif (AR) model

Bu model ile bağımlı değişken z 'nin anlık değeri zaman serisinin önceki değerlerinin sonlu toplamı ve rastlantısal hata terimi a_t cinsinden ifade edilir. $\tilde{z}_t = z_t - \mu$ olarak zaman serisinin ortalama değerden sapması olarak ifade edildiğinde p. mertebeden AR modeli Denklem 2.12'de verilmiştir.

$$\begin{aligned}\tilde{z}_t &= \phi_1 \tilde{z}_{t-1} + \phi_2 \tilde{z}_{t-2} + \dots + \phi_p \tilde{z}_{t-p} + a_t \\ \tilde{z}_t &= \sum_{i=1}^p \phi_i \tilde{z}_{t-i} + a_t\end{aligned}\tag{2.12}$$

Bağımlı değişken z ile bağımsız değişkenler kümesi $x_1, x_2, \dots, x_p$ 'yi ve rastlantısal hata terimi a 'yı ilişkilendiren modele lineer regresyon modeli adı verilmesinden hareketle Denklem 2.12'ye bakıldığında, z değişkeninin kendi geçmiş değerlerine regrese edilmiş olmasından ötürü bu denklemde verilen model otoregresif model olarak isimlendirilmiştir.

Geri kaydırma operatörü notasyonu kullanılarak p. mertebe için AR operatörü gösterimi ve AR modelinin kapalı formu sırasıyla Denklem 2.13 ve Denklem 2.14'te verilmiştir.

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p\tag{2.13}$$

$$\phi(B)\tilde{z}_t = a_t\tag{2.14}$$

2.2.1.2 Hareketli ortalama (MA) modeli

Wold Ayrışım Teoremi herhangi bir sıfır ortalama değere sahip kovaryans-durağan zaman serisi x_t 'nin biri deterministik biri stokastik olmak üzere iki ayrı zaman serisinin toplamı olarak yazılabileceğini ifade eder [72]. Wold Teoremi'nin zaman serisi analizindeki önemi x_t 'nin Denklem 2.15'te görüleceği üzere ARMA modeliyle modellenebileceğini belirtmesinden ileri gelmektedir.

$$\begin{aligned}x_t &= d_t + u_t \\ d_t &= \sum_{j=1}^{\infty} \alpha_j d_{t-j}, \quad u_t = \sum_{j=0}^{\infty} \psi_j e_{t-j}\end{aligned}\tag{2.15}$$

Denklemden, u_t beyaz gürültünün geçmiş değerlerinin doğrusal kombinasyonunu, e_t beyaz gürültüyü, d_t doğrusal deterministik zaman serisini (d_t 'nin geçmiş değerlerinin doğrusal kombinasyonunu), ψ_j ve α_j katsayıları göstermektedir.

MA modelinde zaman serisinin anlık değeri, rastlantısal hata terimi a_t 'nin q adet geçmiş değerine bağlı olarak ifade edilir. q . mertebeden MA modeli Denklem 2.16'da verilmiştir. Bu tanımdan hareketle Denklem 2.15'de verilen u_t 'nin aslında sonsuz moving average ($MA(\infty)$) model ifadesi olduğu da görülebilir.

$$\begin{aligned}\tilde{z}_t &= a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \\ \tilde{z}_t &= a_t - \sum_{i=1}^p \theta_i a_{t-i}\end{aligned}\tag{2.16}$$

q . mertebe için MA operatörü Denklem 2.17'deki gibi tanımlanırsa MA modelinin kapalı formda gösterimi Denklem 2.18'deki gibi ifade edilebilir.

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q\tag{2.17}$$

$$\tilde{z}_t = \theta(B)a_t\tag{2.18}$$

Ele alınan zaman serisi için hangi modelin uygun olduğuna karar verilirken modelin kullanım amacı, model karmaşıklığı, parametre sayısı, parametre tahmininin kolaylığı gibi faktörler değerlendirilir. AR modelinin doğrusal regresyon gibi yöntemler kullanılarak optimal olarak tahmin edilebilmesi avantajı olmasının yanısıra bazı durumlarda MA model kullanımı daha az parametreyle modelin oluşturulmasına olanak tanıyabileceğinden tercih edilebilir. Bunun yanısıra AR ve MA bileşenlerinin birlikte bulunduğu modellerde daha da az parametre kullanımı mümkün olabilir [75].

2.2.1.3 Otoregresif hareketli ortalama (ARMA) modeli

Çoğu durumda durağan zaman serileri için en iyi model sadece AR terimlerini veya MA terimlerini kullanan modeller çıkar; ancak bazen bunların birlikte bulunduğu bir model de veriye en iyi uygunluğu sağlayabilir. Seriyi modele uydurmada büyük bir esneklik sağladığı için ve yukarıda bahsedildiği gibi daha az sayıda parametre kullanımına olanak tanıdığı için tercih edilebilecek olan bu modellerde bazı koşullar

altında bir AR ve MA teriminin birbirlerinin etkisini götürmesi de mümkün olabileceği göz ardı edilmemelidir [76].

ARMA modeli kapalı formda gösterimiyle birlikte sırasıyla Denklem 2.19 ve 2.20’de verilmiştir.

$$\begin{aligned} \tilde{z}_t &= \phi_1 \tilde{z}_{t-1} + \dots + \phi_p \tilde{z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \\ \tilde{z}_t &= a_t + \sum_{i=1}^p \phi_i \tilde{z}_{t-i} + a_t - \sum_{i=1}^q \theta_i a_{t-i} \end{aligned} \quad (2.19)$$

$$\phi(B) \tilde{z}_t = \theta(B) a_t \quad (2.20)$$

2.2.1.4 Bütünleşik otoregresif hareketli ortalama (ARIMA) modeli

AR, MA ve ARMA modelleri durağan zaman serilerine uygulanır. Ancak pratikte, özellikle mühendislik sistemlerinde durağan olmayan zaman serileriyle uğraşılır. Bu serilerinin durağan hale getirilmesi için seride bir veya daha fazla sefer fark alma işleminin yapılması gerekir. Sonrasında farkı alınmış seri ARMA(p, q) olarak oluşturulur. Böylece (p, d, q). mertebeden ARIMA modeli oluşturulmuş olur.

Y_t durağan olmayan zaman serisi iken, Denklem 2.20’de verilen modelde $\phi(B)$ ’nin durağan olmayan AR operatörü olduğu varsayıldığında bu operatörün d. dereceden farkı alınarak oluşturulan durağan operatör $\varphi(B)$, Denklem 2.21a’da verildiği gibi olup oluşan model Denklem 2.21b’de verilmiştir ($\nabla^d z_t = \nabla^d \tilde{z}_t$, $d \geq 1$).

$$\nabla^d \phi(B) = \varphi(B) \quad (2.21a)$$

$$\varphi(B) Y_t = \theta(B) a_t \quad (2.21b)$$

$y_t = \nabla^d Y_t$ eşitliği oluşturularak model, Denklem 2.22’deki gibi de ifade edilebilir. Kapalı formu ise Denklem 2.23’te verilmiştir

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.22)$$

$$\phi(B) y_t = \theta(B) a_t \quad (2.23)$$

Buradan durağan olmayan serinin d. Farkı alınarak ARMA modeli olarak ifade edilebileceği görülür. Pratikte d parametresi 1 veya 2 değerlerini alır.

2.2.1.5 Otoregresif eksojen (ARX) model

ARX modelini ifade etmekte yararlanılan fark denklemi gösterimi Denklem 2.24'tedir. Öngörü hatası minimum olacak şekilde ayarlanması istenen parametreleri ifade eden parametre vektörü θ ise Denklem 2.25'te verilmiştir.

$$y(t) + a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) = b_{n_k} u(t-n_k) + \dots + b_{n'_b} u(t-n'_b) + e(t) \quad (2.24)$$


$$n'_b = n_b + n_k - 1$$

$$\theta = [a_1 \dots a_{n_a} b_{n_k} \dots b_{n'_b}]^T \quad (2.25)$$

Bu doğrultuda Denklem 2.24'te verilen ARX model yapısının kullanılan eksojen giriş için n_k örnek gecikmesine sahip $ARX(n_a, n_b)$ modeli olduğu görülür.

İfade kolaylığı için $n_k = 1$ kabulüyle devam edilip Denklem 2.26'daki gösterimden faydalanılacaktır. ARX modelin parametrik ifadesi Denklem 2.14'te verilen genelleştirilmiş ifadede $C = D = 1$ olması durumudur [75]. Modelin isminde bulunan AR kısmına $A(B)y(t)$ ifadesi ve ekstra giriş ya da eksojen değişken anlamına gelen X kısmına da $B(B)u(t)$ ifadesi karşılık düşer. ARX modelinin blok diyagram gösterimi Şekil 2.2'de yer almaktadır.

$$A(B)y(t) = B(B)u(t-1) + e(t) \quad (2.26)$$



Şekil 2.2: ARX model yapısı blok diyagramı.

2.2.1.6 Otoregresif hareketli ortalama eksojen (ARMAX) modeli

ARMAX modelini ifade ederken kullanılan ayrık zamanlı fark denklemi gösterimi Denklem 2.27'deki gibi tanımlanır. Bu doğrultuda denklemde verilen ARMAX model yapısının n_k örnek gecikmesine sahip $ARMAX(n_a, n_b, n_c)$ modeli olduğu görülür. Öngörü hatası minimum olacak şekilde ayarlanması beklenen parametreleri barındıran parametre vektörü θ ise Denklem 2.28'tedir.

$$\begin{aligned} y(t) + a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) \\ = b_{n_k} u(t-n_k) + \dots + b_{n'_b} u(t-n'_b) + e(t) + c_1 e(t-1) \\ + \dots + c_{n_c} e(t-n_c) \end{aligned} \quad (2.27)$$


$$n'_b = n_b + n_k - 1$$

$$\theta = \left[a_1 \dots a_{n_a} \ b_{n_k} \dots b_{n'_b} \ c_1 \dots c_{n_c} \right]^T \quad (2.28)$$

ARX modelinin temel dezavantajı olan gürültünün özelliklerini tanımlamada yeterli serbestliği sağlayamamasından ötürü modele $C(B)e(t)$ terimi yani beyaz gürültünün hareketli ortalaması dahil edilir ve ARMAX modeli oluşturulmuş olur; Denklem 11'deki parametrik gösterime bakıldığında $D = 1$ iken $C \neq 1$ olması durumudur [82,83]. Bu model aynı zamanda ARMA modelinin eksojen girişlerin dahil edilerek genişletilmesi olarak ele alınabilir. $n_k = 1$ olduğu ve C polinomunun Denklem 2.29'daki gibi tanımlandığı durumda modelin parametrik gösterimi Denklem 2.30'da verilmiştir. ARMAX modelinin blok diyagram gösterimi Şekil 2.3'te yer almaktadır.

$$C(B) = 1 + c_1 B + \dots + c_{n_c} B^{n_c} \quad (2.29)$$

$$A(B)y(t) = B(B)u(t-1) + C(B)e(t) \quad (2.30)$$



Şekil 2.3: ARMAX model yapısı blok diyagramı.

2.2.1.7 Doğrusal modellerde mertebenin belirlenmesi

Model için uygun mertebenin belirlenmesinin çeşitli yolları bulunmakla birlikte bu amaç için çoğunlukla Akaike enformasyon kriteri (AIC), nihai öngörü hatası (FPE), Bayesian enformasyon kriteri (BIC) gibi kriterlerden faydalanılır. Pratikte her bir mertebe için hesaplanan bu kriterler net bir sonuç vermeyip birbirine yakın birden fazla mertebe için yakın değerler sağlayabileceğinden en azından mertebenin belirlenmesinde rastgele denemeler yapmak yerine başlangıç için fikir verici olması açısından da önemli bir yere sahiptir [75].

Akaike enformasyon kriteri (AIC)

Gözlem sayısı mertebeye göre büyük olduğu durumlarda ($N/n > 40$) iyi bir performans gösteren AIC'nin ifadesi Denklem 2.31'de verilmiştir.


$$AIC = \ln(\hat{\sigma}_x^2) + \frac{2n}{N} \quad (2.31)$$

Yukarıdaki denklemde; n model mertebesini, N gözlem sayısını, $\hat{\sigma}_x^2$ hataların kareleri toplamının gözlem sayısına oranını göstermektedir.

Genel olarak, model mertebesi arttıkça hatanın varyansındaki azalma daha baskın olacağından kriterin değeri azalır; ancak belli bir mertebeden sonra modelin uydurulmasındaki iyileştirme mertebenin artışının yanında önemsiz kalacaktır. Bu nedenle ideal model minimum AIC(n) değerini veren modeldir.

2.2.2 Doğrusal olmayan modeller: Yapay sinir ağları

Yapay sinir ağları daha az boyuttaki bilgiyle bir sistemin davranışını öğrenebilmesi ve sahip olduğu yüksek gürültü toleransı özelliği ile sistem modelleme uygulamalarında önemli bir yere sahiptir [77]. Yapay sinir ağları, biyolojik sinir ağlarının bilgiyi analiz etmesi ve işlemesinden esinlenilerek oluşturulan, deneme yolu ile öğrenme ve genelleştirme yapan matematiksel modeldir. Giriş ve çıkış değişkenleri arasındaki herhangi bir ön bilgiye ihtiyaç duymadan ve herhangi bir varsayımda bulunmadan, doğrusal olmayan modellemeyi sağlayabilmektedir [78]. Sinir ağını oluşturan *yapay nöron* adı verilen temel birim girişlerden, ilgili girişin ağırlıklarından ve bir aktivasyon fonksiyonundan oluşmaktadır [79]. Bir nöronunun gösterimi x_n girişler, w_{nj} ilgili girişin ağırlığı, $\phi(.)$ aktivasyon fonksiyonu, s_j ağırlıklandırılmış toplamın aldığı değer, y çıkış olmak üzere Şekil 2.4'te verilmiştir.



Şekil 2.4: Bir nöronun yapısı.

$$s_j = \sum w_{ij} \cdot x_i + w_b \cdot B = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + w_b \cdot B \quad (2.32)$$



Genellikle 1 olan bias değeri (B) de kendi ağırlığına sahiptir ve bütün girdiler sıfır olsa dahi nöronun hesaba katılmasına olanak tanır. Bunun yanında pratikte aktivasyon fonksiyonunu sağa ya da sola kaydırma imkanı sağlayabildiği için sinir ağının öğrenmesinde önemli bir yeri vardır. Denklem 2.32'ye göre s_j değeri hesaplandıktan sonra bu değer doğrusal olmayan bir fonksiyon olan Denklem 2.33'te verilen aktivasyon fonksiyonuna girer ve sıklıkla kullanılan şekliyle (0,1) veya (-1, 1) arasına normalize edilir [80].

$$y_j = \phi(s_j) \quad (2.33)$$


Çok sayıda aktivasyon fonksiyonu bulunsa da, doğrusal fonksiyonlara aksine çıktı değerlerini belirli değerler arasına sınırlayabilmesi sebebiyle sinir ağlarında çoğunlukla doğrusal olmayan aktivasyon fonksiyonları kullanılır [81]. Sinir ağının doğrusal olmayan davranış göstermesi ve daha karmaşık sistemleri modelleyebilmesi de bu yolla mümkün olmaktadır. Aktivasyon fonksiyonunun doğru seçilmesi ağın performansını direkt etkileyen bir kriterdir. Bölüm 2.2.2.1'de bahsedilmiş olan algoritmalarla öğrenmenin gerçekleşebilmesi için aktivasyon fonksiyonu türevi alınabilir bir fonksiyon olarak belirlenmelidir. x ağırlıklandırılmış toplam, w ağırlıklar, $f(x)$ aktivasyon fonksiyonu olmak üzere Çizelge 2.2'de çeşitli aktivasyon

fonksiyonları ve özellikleri verilmiştir. Tablodaki fonksiyonlara özel bir aktivasyon fonksiyonu sınıfına ait olan ve radyal tabanlı fonksiyon ağlarında ve genelleştirilmiş regresyon ağlarında kullanılabilen Gauss fonksiyonu da dahil edilebilir ancak buna detaylı olarak Bölüm 2.1.2.2.'de değinilmiştir.

Çizelge 2.2: Önemli aktivasyon fonksiyonları.


Fonksiyon Adı ve Grafiksel Gösterimi	Matematiksel İfadesi ve Özellikleri
Sigmoid (Logaritmik Sigmoid/Logsig) 	$f(x) = \frac{1}{1+e^{-x}}$ $f(x) \in (0,1)$ - Eksponansiyel terim barındırdığından hesaplama yükü fazladır. - Fonksiyonun uçlarında türev değeri sıfıra yakınsadığından (gradyanların kaybolması) öğrenme güçleşir.
Hiperbolik Tanjant (Tanh/tansig) 	$f(x) = \frac{1-e^{-2x}}{1+e^{-2x}}$ $f(x) \in (-1,1)$ $\tanh(x) = 2f(2x) - 1$ $f(x)$: sigmoid fonksiyon tanh, sigmoid fonksiyonun ölçeklenmiş - Avantajı, sigmoide göre türevi için daha geniş değer aralığı olmasıdır. - Fonksiyon sıfır merkezli olduğu için sigmoid'in aksine gradyanlarda bias görülmeyecek.

Düzeltilmiş Doğrusal Birim (ReLU)




- $f(x) = \max(0, x)$
- $f(x) \in [0, +\infty)$
- Girişler için sıfırın eşik değeri olduğu bir fonksiyondur.
- Hesaplama yükü sigmoid ve tanh'a göre çok düşüktür; hızlı yakınsamaya olanak tanıdığından çok katmanlı ağlarda tercih edilir.
- Negatif girişlerde fonksiyonun sıfır değerini alması ağı daha hızlı çalışmasını sağlarken bu bölgede türevin de sıfır olması öğrenmenin gerçekleşmemesine sebep olur.

Sızıntı ReLU



- $f(x) = \max(0.01x, x)$
- $f(x) \in (-\infty, +\infty)$
- ReLU'daki negatif bölgedeki gradyanların olmamasına yönelik geliştiren fonksiyondur ancak bazı durumlarda bu girişler için tutarlı sonuçlar vermeyebilir.
- ReLU'ya benzer şekilde hesaplama yükü azdır.


Doğrusal (Purelin)



- $f(x) = x$
- $f(x) \in (-\infty, +\infty)$
- Nöron girişlerinin değişimine göre nöron çıkışı doğrusal olarak değişmektedir.
- Türevi sabit bir değer olduğundan geri yayılım algoritması kullanıldığında öğrenme gerçekleşmez
- Sinir ağları doğrusal yapıda olmadığından gizli katmanlardaki nöronlarda bu fonksiyon kullanılamaz.

2.2.2.1 İleri beslemeli yapay sinir ağı (FFN)

Nöronlar katmanlar olarak organize edilerek yapay sinir ağını oluşturur. İlk katman giriş katmanı, son katman çıkış katmanı ve arada bulunan katman gizli katman olarak isimlendirilir ve oluşturulan örnek bir ağ yapısı Şekil 2.5'te verilmiştir. Aynı zamanda bu ağ yapısı Çok Katmanlı Algılayıcı (*ing.* Multi Layer Perceptron (MLP)) olarak da adlandırılan en basit yapıdaki sinir ağı olan ileri beslemeli yapay sinir ağıdır. Her bir katmandaki nöronların kendi aralarında bağlantısı bulunmaz; bilgi ağda sadece ileri doğru hareket eder [79].



Şekil 2.5: FFN ağ yapısı.

Giriş katmanı ağda kullanılacak olan ham veriyi ifade eder. Bu katmanda değerler üzerinde herhangi bir işlem uygulanmadığından sinir ağı isimlendirilirken bu katman sayılmaz; gizli katman ve çıkış katmanı sayıları toplanır. Gizli katman barındırmayan sinir ağlarının tek katmanlı algılayıcı (*ing.* Single layer perceptron) olarak isimlendirilmesi bu sebeptendir. Bu katmandaki her bir değer bağlı olduğu nörona göre ağırlıklandırılarak gizli katmandaki her bir nörona giriş yapar; gizli katmandaki nöronlar da aynı prensiple hesaplamaların sonucunu çıkış katmanına iletir.

Çıkış katmanındaki nöron sayısının genellikle 1 olduğu gibi, birden fazla olabileceği durumlar da vardır. Bu katman ağın yaptığı hesaplamanın çıktısını verdiği için bu katmandaki nöronların doğrusal aktivasyon fonksiyonu barındırdığı düşünülebilir.

Katman sayısının, katmanların barındıracağı nöron sayısının ve kullanılacak aktivasyon fonksiyonunun netleştirilmesi sinir ağı mimarisinin belirlenmesindeki üç temel kriterdir [80]. Katman sayısı belirlenmesinde kabul görmüş herhangi bir kural

bulunmamaktadır. Gerekli gizli katman sayısından az gizli katmana sahip yapay sinir ağları karmaşık fonksiyonların çözümünde yetersiz kalırken, çok fazla gizli katmana sahip yapay sinir ağlarında ise istenmeyen kararsızlıklarla karşılaşmaktadır. Diğer bir problem ise gizli katmanlardaki nöron sayısının belirlenmesidir. Giriş katmanındaki sayı, sistemdeki girişlerin sayısına eşittir ve çıkış katmanı için nöron sayısı ise sinir ağının kullanılma amacı doğrultusunda istenilen çıktı sayısına göre belirlenebilmektedir. Gizli katman için ise en verimli hesaplama için kaç tane nöron bulundurması gerektiği konusunda herhangi bir matematiksel test bulunmadığından deneme ve yanılma yöntemi uygulanarak karar verilmektedir [81].

Yapay sinir ağında öğrenme

Sinir ağının giriş-çıkış ikililerini doğru bir şekilde sınıflandırmayı öğrenmesi, nöronlar arasındaki bağlantının gücünü ifade eden ağırlıkların ($\vec{w}$) ve biasın (b) uygun ayarlanmasına bağlıdır [79, 82]. Sinir ağının öğrenmesi olarak adlandırılan bu süreç bir optimizasyon problemi olarak yorumlanabilir. İlk başta rastgele atanan ağırlıklar, verilen girişe karşılık düşen çıkış değerinin bulunduğu giriş-çıkış ikililerinden oluşan eğitim veri setinin eğitilecek olan sinir ağına uygulanmasıyla güncellenir. Örnekler sırayla bu ağda kullanılır ve böylelikle ağırlıkların her defasında güncellenmesiyle en doğru değerlere erişilmeye çalışılır. Bu aşama tamamlandıktan sonra test setindeki örnekler kullanılarak ağın öğrenme performansı ölçülür yani ağ test edilmiş olur. Ağırlıkların ayarlanmasında amaç kısaca hatanın minimize edilmesidir.

Sinir ağlarında öğrenme stratejileri denetimli (*ing.* Supervised learning), takviyeli (*ing.* Reinforcement learning) ve denetimsiz (*ing.* Unsupervised learning) öğrenme olmak üzere üç gruba ayrılır; bu bölümde sadece denetimli öğrenme yöntemlerin olan hatanın geri yayılımı algoritması (*ing.* error backpropagation algorithm (EBP)) ve çalışmada kullanılan yöntem olan Levenberg-Marquardt algoritmasından bahsedilecektir.


Birinci dereceden türev kullanımı gerektiren, literatürde en dik iniş algoritması (*ing.* Steepest descent algorithm) olarak da isimlendirilen hatanın geri yayılımı algoritması, sinir ağlarını eğitmek için ortaya çıkan ilk yöntemlerden olup günümüzde hala sıklıkla kullanılsa da küçük adım boyutları seçilmesi gerekliliğinden ötürü yavaş yakınsaması nedeniyle verimsiz bir algoritmadır [83]. Bunun yanında

pratik uygulamalar için maliyetli olma ve yerel minimuma yakınsama gibi dezavantajlara sahiptir. Bu olumsuzlukların giderilmesi için pek çok farklı algoritma geliştirilmiştir [84]. Örneğin, Gauss-Newton algoritması hata fonksiyonlarının ikinci dereceden türevlerini kullandığından, özellikle hata fonksiyonu kuadratik bir yüzeye sahipse uygun adım boyutunu belirleyip yakınsamayı çok hızlı tamamlayabilir ancak diğer türlü de ıraksama ihtimali taşır [83].

Mevcut olanlardan daha yüksek başarılı bir öğrenmeye ihtiyaç duyulması nedeniyle EBP'nin sahip olduğu problemleri taşımayan, Gauss-Newton algoritmasının şiddeti ve en dik iniş algoritmasının kararlılığını birleştiren Levenberg-Marquardt algoritması ortaya çıkmış ve ağ eğitiminde başvurulan etkili metotlardandır [85]. Bu nedenle bu çalışmada FFN'in eğitilmesi için Levenberg-Marquardt algoritması kullanılmıştır.

Hatanın Geri Yayılımı Algoritması

Oluşturulan sinir ağına verilen bir girişin ilgili nöronlardan geçerek gerekli hesaplamaların yapılması sonucunda ağın bir çıkış değeri üretmesi işlemine ileri yayılım (*ing.* Forward propagation) adı verilir. İleri yayılım sonucunda elde edilen çıktı beklenen değer $\hat{y}$ 'dir. Hatayı hesaplamak için bu beklenen değer ile gerçek çıkış değeri y karşılaştırılır. Sinir ağının eğitilmesi, ağdaki ağırlıkların oluşturulan kayıp fonksiyonu aracılığıyla bu hatanın değerinin minimize edileceği şekilde seçilmesiyle mümkün olmaktadır. EBP algoritmasının şematik ifadesi Şekil 2.6'da verilmiştir.



Şekil 2.6: EBP algoritmasının şematik ifadesi

Hata deęerini minimize etme amacıyla sıklıkla kullanılan kayıp fonksiyonu ortalama karesel hata (MSE)'dir ve w aędaki bütün aęlırlıklar, N eęitim veri setinin eleman sayısı, e_p hata ifadesi ve p ise verinin indisi olmak üzere Denklem 2.34'te verilmiřtir. Hata hesaplandıktan sonra bu bilgi geriye iletilir; bu nedenle yöntem geri yayılım algoritması ismini alır.

$$L(w) = \frac{1}{N} \sum_{p=1}^N (e_p)^2 ; e_p = y_p - \hat{y}_p \quad (2.34)$$

Bu yöntemde aęlırlıkların ayarlanması için, kayıp fonksiyonunun aędaki her bir aęlırlığa ve biasa göre kısmi türevi alınarak sırasıyla Denklem 2.35 ve 2.36'da verildięi gibi işleme sokulur ve kayıp fonksiyonunun minimum deęerine yaklařması amaçlanır. Bu amaca ulařılana kadar bütün süreç her biri eęitim veri seti örneęi için yapılan iterasyonla (epoch) tekrar edilir.

$$w_{ij}(t) = w_{ij}(t-1) - \alpha \frac{\partial L(t)}{\partial w_{ij}(t-1)} \quad (2.35)$$

$$b_i(t) = b_i(t-1) - \alpha \frac{\partial L(t)}{\partial b_i(t-1)} \quad (2.36)$$

Denklemlerde w_k sonraki katmanda baęlı olduęu j nöronu için i nöronunun aęlırlığı, b_k j nöronunun bias deęeri, w_{k+1} ve b_{k+1} sonraki iterasyon için hesaplanan aęlırlık ve bias deęerleri olmak üzere α , 0 ile 1 arasında deęer alabilen *öęrenme oranı*dır. Aęın öęrenme řiddetine direkt etkisi olan bu parametre, en dik iniř metodunun her iterasyonda alacaęı adım boyutunu kontrol eder ve genellikle küçük deęerlerde seęilir.

Levenberg-Marquardt algoritması

Kayıp fonksiyonu Denklem 2.34'teki gibi verilen, en dik iniř algoritması ile Gauss-Newton algoritmalarının kombinasyonu olan Levenberg-Marquardt (LM) algoritması Denklem 2.37'de ifade edilmiřtir [86]. Λ negatif olmayan kombinasyon katsayısı ve I birim matristir. Denklemden bulunan J Jakobiyen matrisi ise Denklem 2.38'de verilmiřtir. Aęlırlık vektörü w , w_1 'den w_m 'ye kadar olan aęlırlıkları, hata vektörü e ise e_1 'den e_p 'ye kadar olan hataları içerir.

$$w_{k+1} = w_k - (J_k^T J_k + \lambda I)^{-1} J_k e_k \quad (2.37)$$

$$J = \begin{pmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \cdots & \frac{\partial e_1}{\partial w_M} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \cdots & \frac{\partial e_2}{\partial w_M} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_p}{\partial w_1} & \frac{\partial e_p}{\partial w_2} & \cdots & \frac{\partial e_p}{\partial w_M} \end{pmatrix} \quad (2.38)$$

Bu yöntem kombinasyon katsayısı λ çok büyükse veya parametreler istenen değerlerden uzaksa en dik iniş algoritması gibi; kombinasyon katsayı çok küçükse Gauss-Newton algoritması gibi davranır. Ayarlanabilir bir parametre olan kombinasyon katsayısı başlangıç için $\mu = 0.01$ seçilir. c sabit bir sayı E uygunluk değeri olmak üzere kombinasyon katsayısının belirlenmesi Denklem 2.39'a göre gerçekleşmektedir [87].

$$\lambda_{k+1} = \begin{cases} \lambda_k c & E_{k+1} > E_k \\ \lambda_k / c & E_{k+1} \leq E_k \end{cases} \quad (2.39)$$


Öğrenme algoritmaları arasında en başarılı olanlardan birisi olan ve bu çalışmada da faydalanılan bu algoritmanın bahsedilen avantajları yanında en büyük dezavantajı parametresi fazla olan bir ağ mimarisi karşısında Jakobiyeen matrisleri de büyüyeceğinden ve çok büyük matrislerin tersini almak gerekeceğinden hesaplama yükünün de bu doğrultuda artıyor olmasıdır [88].

Yapay Sinir Ağı'nın Test edilmesi

Kullanılan veri eğitim seti ve test seti olarak ikiye ayrılır. Test setinin boyutu eğitim setine göre çok küçüktür. Öngörücünün yüksek/düşük tahmin etmesine sebep olabileceğinden bu iki veri setinin farklı karakteristiklerde olacak şekilde ayrılmadığından emin olunmalıdır. Eğitim seti kullanılarak eğitim tamamlandıktan (ağıdaki bütün ağırlıklar belirlendikten) sonra ağı test edilmesi amacıyla ağı ilk kez göreceği örnekleri barındıran test seti kullanılır. Eğitimin tamamlanması sonucunda oluşturulan ağ verilen örnekler için çıkışlar üretir. Bu çıkışların doğruluk değerlerinin belirli kriterler kullanılarak incelenmesine göre eğitimin performansı yorumlanır.


2.2.2.2 Radyal tabanlı fonksiyon ağı (RBFN)

Radyal Tabanlı Fonksiyon Ağları (*ing.* Radial Basis Function Network (RBFN)) temelde gizli nöronlarının aktivasyon fonksiyonu olarak radyal tabanlı fonksiyonları kullandığı iki katmanlı ileri beslemeli sinir ağıdır. Ağı öğrenmesi ilk olarak girişten gizli katmana olan ve sonrasında gizli katmandan çıkışa olan ağırlıkların belirlenmesi şeklinde iki aşamada gerçekleşmektedir. Şekil 2.7’de n boyutlu bir giriş vektörü, k adet karşılaştırılacak prototip μ barındıran RBF nöronları katmanı, her kategori (veri sınıfı) için bir nöron barındıran ve FFN gibi doğrusal aktivasyon fonksiyonları kullanan çıkış katmanından oluşan RBF ağ mimarisi verilmiştir [80].



Şekil 2.7: RBF ağ yapısı

Radyal tabanlı sinir ağı, girişin veri setindeki örneklerle benzerliğini ölçerek bir sınıflandırma gerçekleştirir [89]. Her RBF nöronu eğitim veri setindeki örneklerden birisi olan bir prototip vektörünü tutar; giriş vektörüyle prototipini aradaki Öklidyen mesafeyi hesaplamak suretiyle karşılaştırır ve giriş değeri prototipe eşitse nöronun çıktısı 1 olmak üzere, aradaki benzerliğe göre 0 ile 1 arasında değer alır. Girişle prototip arasındaki mesafe büyüdükçe Şekil 2.8’te aktivasyon fonksiyonu olarak Gauss fonksiyonu kullanan bir RBF nöronunun yanıtının (aktivasyon değerinin) çan eğrisi şeklinde olmasından da görülebileceği üzere yanıt artan değerler için eksponansiyel olarak 0’a yaklaşır. Bu sebeple prototip vektörü, çan eğrisinin merkezindeki değer olduğundan *nöronun merkezi* olarak da isimlendirilir.



Şekil 2.8: RBF nöronu aktivasyon değerleri

Her bir sınıflandırma kategorisini ifade etmek için bir nöron bulunan çıkış katmanında her nöron ilgili kategori için bir skor üretir. Skorlar her bir çıkış nöronu için o nörona giden ağırlıklı toplamaların alınmasıyla hesaplanır. Her çıkış nöronu farklı bir kategori için skoru hesapladığından, her çıkış nöronu kendi ağırlık kümesine sahiptir. En yüksek skora sahip kategoriyle ilgili giriş eşleştirilince sınıflandırma işlemi yapılmış olur.

Girişle prototip arasındaki yakınlığı belirlemek için kullanılan çeşitli fonksiyonlar vardır ancak bu çalışmada radyal bazlı fonksiyon olarak bu amaçla sıklıkla kullanılan Gauss fonksiyonu seçilmiştir. Bir boyutlu giriş için Gauss fonksiyonu x giriş, μ ortalama değer (üretilen çan eğrisinin merkezinin konumu), σ standart sapma olmak üzere Denklem 2.40'ta verilmiştir.

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.40)$$


Kullanılacak aktivasyon fonksiyonu (ϕ) için Denklem x'i basitleştirecek iki düzenleme yapmak mümkündür. $\frac{1}{\sigma \sqrt{2\pi}}$ terimi Gauss eğrisinin yüksekliğini kontrol eden terimdir ve RBFN için ağırlıklara bir etkisi olmadığından RBF nöron aktivasyon fonksiyonu oluşturulurken denklemden kaldırılabilir. $\frac{1}{2\sigma^2}$ terimi ise çan eğrisinin genişliğini kontrol eden, genişlik parametresi olarak adlandırılan β olarak ifade edilir. Böylece tek değişkenli bir fonksiyon haline gelen RBF nöron aktivasyon fonksiyonu denklem 2.41'de verilmiştir. Gauss dağılımı için eğrinin ortalama değeri

olan μ , $[0,1]$ aralığında deęer alabilen RBF nörön aktivasyon fonksiyonu için 1 deęerinin alındığı nokta yani prototip vektörüdür.

$$\phi(x) = e^{-\beta \|x-\mu\|^2} \quad (2.41)$$

n-boyutlu bir vektörü uygularken x ile μ arasındaki Öklidyen mesafeyi belirten $\|x - \mu\|$ ifadesi bir boyutlu Gauss fonksiyonunda $(x - \mu)$ olarak sadeleştirilebilir.

RBF nörönları merkezine yakın konumda olan veri noktaları için daha hassastır. Gauss aktivasyon fonksiyonu için bu hassaslık genişlik parametresi (açıklık) ile oynanarak deęiştirilebilir ve β 'nın 1, 2 ve 3 deęerlerini almasıyla oluşturulan fonksiyonlar Şekil 2.9'da verilmiştir. Parametre büyüdükçe hassasiyet azalır. Bu sebeple genelde RBF nörönları için küçük genişlik parametresi kullanıldığında sinir ağının başarımı daha iyi olur.




Şekil 2.9: Deęişen genişlik parametresine göre Gauss fonksiyonu.

2.2.2.3 Genelleştirilmiş regresyon sinir ağları (GRNN)

Giriş katmanını dışında örnek, toplama ve çıkış katmanları olmak üzere üç katmana sahip ileri beslemeli bir sinir ağı modeli olan genelleştirilmiş regresyon sinir ağlarında öğrenme FFN'den farklı olarak iteratif olarak gerçekleşmez. Giriş katmanındaki nörön sayısı verinin boyutuna eşit iken örnek katmanındaki nörön sayısı eğitim setindeki veri sayısına eşittir. Her bir nörön için ağırlık deęerlerinin belirlenmesi için yapılan işlem örnek katmanındaki nörönların eğitim ve test verisi arasındaki mesafeyi radyal tabanlı fonksiyondan bir geçirmesidir. Bu katmandan elde

edilen ağırlıklar ise, toplama katmanındaki pay ve payda nöronları adı verilen iki nörona iletilir.



Şekil 2.10: GRNN ağı yapısı.

Gerçek sistemlerin ölçümlerinden elde edilen veriler ileri beslemeli sinir ağı için genellikle yeterli olmaz. Bu nedenle veriyle ilgili oluşturulacak fonksiyona birkaç eğitim verisi örneğiyle yakınsamadaki başarımı GRNN’i avantajlı kılmaktadır [90]. Yani sinir ağının eğitim için ihtiyaç duyduğu veri setinin çok küçük kısmıyla eğitilebilen bir sinir ağıdır. Bu durum GRNN’i öngörü problemlerinde kullanmaya oldukça elverişli kılmaktadır.

Payda nöronunda sadece her bir nörona ait ağırlık değerleri toplanır. Pay nöronunda bu ağırlık değerleri ile ait olduğu nörona bulunan eğitim verisinin çıkış değeri çarpılır ve son olarak bu çarpımlar toplanır. Çıkış katmanında ise pay nöronundan gelen değer payda nöronundan gelen değere bölünür ve çıkış üretilir [91].

2.3 Model Performanslarının Değerlendirmesi

Önerilen modellerin performanslarının öngörü doğruluğu açısından değerlendirilip karşılaştırılması gereklidir. Bu amaç doğrultusunda kabul görmüş tek bir metrik bulunmamaktadır [92]. Bu nedenle modellerin performans değerlendirmesinin yapılabilmesi için için determinasyon katsayısı (R^2), ortalama karesel hatanın karekökü (ing. *Root-mean-square error (RMSE)*) ve ortalama sapma (ing. *Mean-bias error (MBE)*) gibi pek çok farklı ölçüt kullanılmaktadır [93].

Aşağıdaki denklemlerde x_m gözlem (ölçüm) değeri, x_c hesaplanan değer, x_N normalizasyon değeri, $\langle \rangle$ ortalama değer operatörü olmak üzere bu çalışmada kullanılan uyum iyiliği ölçütlerinin matematiksel ifadeleri aşağıda verilmiştir.

- Mutlak hata (ing. *Absolute error (AE)*)

$$AE = |x_c - x_m| \quad (2.42)$$

- Ortalama sapma

$$MBE = \langle \sum AE \rangle \quad (2.43)$$

- Ortalama mutlak hata (ing. *Mean-absolute error (MAE)*)

$$MAE = \langle |x_c - x_m| \rangle \quad (2.44)$$

- RMS hatası

$$RMSE = \sqrt{\langle AE^2 \rangle} \quad (2.45)$$

Bu hataların hesaplanan değerlerinin küçük çıkması ölçüm ve hesaplama değerleri arasındaki yakınlığı ifade eder. Farklı ölçekteki modeller arasında karşılaştırma yapmaya olanak sağlaması nedeniyle bu hata kriterlerinin normalize edilmesine sıklıkla başvurulur. Normalizasyon, genel olarak ölçütün ölçüm değerinin aralığına bölünmesiyle gerçekleştirilir. Aralığın hesaplaması Denklem 2.46'da verilmiştir.

$$x_N = aralık(x_m) = max(x_m) - min(x_m) \quad (2.46)$$

- Bağlı ortalama mutlak hata (relative Mean-Absolute Error, rMAE)

$$rMAE = \frac{MAE}{x_N} \quad (2.47)$$

- Bağlı RMS hata (relative Root-Mean-Squared Error, rRMSE)

$$rMSE = \frac{RMSE}{x_N} \quad (2.48)$$

- Bağlı ortalama sapma (relative Mean-Bias Error, rMBE)

$$rMBE = \frac{MBE}{x_N} \quad (2.49)$$

– Determinasyon katsayısı (R^2)

$$R^2 = 1 - \frac{ESS}{TSS} \quad (2.50)$$

Denklem 2.50'ta TSS ifadesi kareler toplamı (ing. *Total Sum of Squares*) ve ESS ifadesi hatanın kareleri toplamı (ing. *Error Sum of Squares*) anlamına gelmektedir.

TSS'nin Denklem 2.51'de verilen şekliyle iki farklı tanımlaması yapılarak 2 farklı R^2 hesaplaması yapılması mümkündür. ESS de Denklem 2.52'de verilmiştir.

$$TSS_1 = \sum_i^n [x_m]^2 \quad (2.51a)$$

$$TSS_2 = \sum_i^n [x_m - \bar{x}_m]^2 \quad (2.51b)$$

$$ESS = \sum_i^n [x_c - x_m]^2 \quad (2.52)$$

3. BENZETİM ÇALIŞMASI

Bölüm 2’de detaylı tanımlamalarına yer verilen 5 doğrusal, 3 doğrusal olmayan toplam 8 adet model yapısı eldeki rüzgar şiddeti verisi kullanılarak MATLAB programı yardımıyla oluşturulmuştur. Kullanılan veri 2005 yılında Atatürk Havalimanı’nda bulunan otomatik meteorolojik gözlem sisteminden (AWOS) elde edilen bir dakikalık aralıklarla örneklenmiş 10 m’deki rüzgar şiddeti verisidir. Veri aracılığıyla ilgili modelin parametre kestirimi (sinir ağı terminolojisinde ağı eğitimi) yapıldıktan sonra her bir model yapısı için veriye uygun öngörü modelleri oluşturulmuştur. Giriş olarak rüzgar şiddeti verisinin kullanılması sonucunda bir adım ileri öngörü yapılması amacıyla model, çıkış değerlerini hesaplamıştır. Öngörü değerleri belirlenen hata kriterleri doğrultusunda gerçek değerlerle (ölçüm) karşılaştırılmış ve modelin öngörü performansı değerlendirilmiştir.

Burada amaç aynı model yapısının farklı model mertebelerindeki modellerinin, kullanılan performans kriterleri aracılığıyla başarımının kıyaslanması; ilgili model yapısının mevcut veri için hangi parametrelerle en iyi öngörü yapabileceğinin belirlenmesidir. Sonrasında ise farklı model yapılarının önde gelen modelleri karşılaştırılarak kullanılan rüzgar şiddeti verisinin bir adım ileri öngörüsünde en başarılı modelin hangisi olduğu tespit edilmiştir.


Bölüm 2.3’te verilen hata kriterleri hesaplanmış ve her model yapısının en iyi modeli için ilgili hata değerleri verilerek Bölüm 4’ün sonundaki Çizelge 4.1 oluşturulmuştur. Çizelgede verilen bütün modeller için bütün kriterlere birlikte bakılarak modellerin yanıtı incelenmiştir. Sonuçların yorumlanmasında üzerinde durulan kriterlerden olan R_1^2 değeri hesaplanırken kareler toplamı (TSS) ifadesi olarak Denklem 2.51a’dan faydalanılmıştır. Ortalama mutlak hata (MBE) ve ortalama sapma (MAE) ifadeleri ise sırasıyla Denklem 2.43 ve 2.44’te verilmiştir.

3.1 Doğrusal Modeller


Otoregresif model ve Otoregresif Eksojen model için AR model mertebesi 1'den 50'ye götürülerek; MA terimi içeren Otoregresif Hareketli Ortalama (ARMA), Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) ve Otoregresif Hareketli Ortalama Eksojen (ARMAX) modelleri için ise AR mertebesi 1'den 49'a götürülürken AR ve MA mertebelerinin toplamı 50'den küçük olacak şekilde gerekli hesaplamalar yapılmıştır [74]. Eksojen giriş içeren modeller için n_b eksojen giriş mertebesi, örnek gecikmesi $n_k=1$ tutularak, sırasıyla 1, 3, 5 ve 10 olarak alınmış ve her bir AR ve MA mertebesi için yukarıda bahsedilen işlemler gerçekleştirilmiştir.

AR Modeli

Otoregresif modeller içerisinde en iyi model çıkan AR(19) modelinin yanıtı ve ölçüm değerleri Şekil 3.1'de verilmiştir. Model yanıtı ve ölçüm değerleri kullanılarak oluşturulan korelasyon grafiği ise Şekil 3.2'dedir. Bu model için $R_1^2 = 0,998965$, $MAE=0,149189$ 'dir. Bu modelin işareti iyi öngörebilmekte olduğu görülmektedir. $MBE=0,044378$ değerinin de ifade ettiği gibi model, yüksek ya da düşük tahminde bulunmamaktadır. Model geneline bakıldığında çok az miktarda yüksek tahmin ettiği görülmektedir.




Şekil 3.1: AR(19) modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.2: En iyi AR modeli için korelasyon grafiği

ARMA Modeli

En iyi model çıkan ARMA(19,1) modelinin yanıtı ve ölçüm değerleri Şekil 3.3’de verilmiştir. Model yanıtı ve ölçüm değerleri kullanılarak oluşturulan korelasyon grafiği ise Şekil 3.4’tedir. AR modeline benzer şekilde işareti iyi öngörebilmektedir. $MBE=0,044378$ değerinden anlaşıldığı üzere model yüksek ya da düşük tahmin etmemektedir. Model geneline bakıldığında çok az miktarda yüksek tahmin ettiği görülmektedir.



Şekil 3.3: ARMA(19,1) modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.4: En iyi ARMA modeli için korelasyon grafiği


ARIMA Modeli

Bütünleşik Otoregresif Hareketli Ortalama modelinde Wold Ayrışım Teoremi'nde ifade edildiği şekilde işaretin sıfır ortalama değerli olması şartını sağlamak için öncelikle fark alma işlemi gerçekleştirilir. Fark alma mertebesinin yüksek değerlere götürülmesi işaretin doğasını bozacağı için sıfır ortalama değere erişildikten sonra fark alma işleminin sürdürülmemesi gerekmektedir. Bu nedenle bu modelde zaman serisine fark alma işlemi uygulanması için I mertebesi olan d'nin 1 olarak hesaba katılmasıyla gerekli işlemler yapıldığında çıkan en iyi model çıkan ARIMA(16,1,1) modelinin yanıtı ve ölçüm değerleri Şekil 3.5'te; d=2 olarak belirlendiğinde ise en iyi model çıkan ARIMA(19,2,9) modelinin yanıtı ve ölçüm değerleri Şekil 3.6'da verilmiştir. d=1 ve d=2 için sırasıyla model yanıtı ve ölçüm değerleri için korelasyon grafikleri ise Şekil 3.7 ve 3.8'dedir.


Bu iki model için sırasıyla R_1^2 değerleri 0,996166 ve 0,99053; MAE değerleri de 0,444613 ve 0,706887'dir. Yüksek bir MBE değeri olan 0,373356'dan da görülebileceği üzere genel olarak model yüksek tahmin etmektedir. d=2 için ise MBE=0,059982 olmasına rağmen model gerçek işarete bulunmayan daha yüksek frekanslı bileşenler üretmekte ve öngöründe başarısız olmaktadır.




Şekil 3.5: $d=1$ iken en iyi ARIMA modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.



Şekil 3.6: $d=2$ iken en iyi ARIMA modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.



Şekil 3.7: $d=1$ iken en iyi ARIMA modeli için korelasyon grafiği




Şekil 3.8: $d=2$ iken en iyi ARIMA modeli için korelasyon grafiği


ARX Modeli

Eksojen giriş mertebesi olan n_b değerlerinin 1, 3, 5 ve 10 alındığı durumlarda AR mertebesi 1'den 150'ye götürülürken çıkan en iyi ARX modellerinin mertebeleri sırasıyla (149,1), (150,3), (150,5), (150,10) olarak hesaplanmıştır. Bu modelde eksojen giriş olarak rüzgar şiddeti verisi örnek gecikmesi $n_k=1$ olarak belirlenerek kullanılmıştır.

En iyi modellerin model yanıtları ve ölçüm değerleri Şekil 3.9'da; $n_b=1$ olan modelin yanıtı ve ölçüm değerleri için korelasyon grafiği ise Şekil 3.10'dadır. Gözle görülecek bir farklılık bulunmadığından değişen n_b mertebeleri için korelasyon grafikleri tek tek verilmemiştir. Benzer şekilde, bütün modeller için R_1^2 değerleri 0,999883 olarak bulunmuştur. Modelin, model mertebesinden yeterince küçük kalması şartıyla eksojen girişin boyutundan fazla etkilenmediği ve çok başarılı bir şekilde işareti modellediği görülmüştür. MBE -0,001512 ile -0,001533 arasında değişen değerler almaktadır. Model çok az miktarda düşük tahmin etmektedir. Bütün modeller içinde en yüksek R_1^2 değerine sahip model, ARX modeli olarak bulunmuştur. Buradan hareketle kullanılan rüzgar şiddeti verisi için bu çalışmanın öngörü performansı en yüksek olan öngörücüsü olduğu ifade edilebilir.



Şekil 3.9: En iyi ARX modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.10: En iyi ARX modeli için korelasyon grafiği


ARMAX Modeli

Eksojen giriş mertebesi olan n_b değerlerinin 1, 3, 5 ve 10 alındığı durumlarda AR mertebesi 1'den 49'a kadar ilerlerken AR ve MA model mertebelerinin toplamı 50'ye ulaşana dek yapılan hesaplamalar sonucunda çıkan en iyi ARMAX modellerinin mertebeleri sırasıyla (19,1,30), (20,3,30), (20,5,29), (20,10,30) olarak hesaplanmıştır. Bu modelde eksojen giriş olarak rüzgar şiddeti verisi örnek gecikmesi $n_k=1$ olarak belirlenerek kullanılmıştır.

En iyi modellerin model yanıtları ve ölçüm değerleri Şekil 3.11'de; $n_b=1$ olan modelin yanıtı ve ölçüm değerleri için korelasyon grafiği ise Şekil 3.12'dedir. Gözle görülecek bir farklılık bulunmadığından değişen n_b mertebeleri için korelasyon grafikleri tek tek verilmemiştir. Benzer şekilde, bütün modeller için R_1^2 değerleri 0,999869 olarak bulunmuştur. ARMAX modellerinin başarımı da ARX modelleri gibi eksojen girişin mertebesinden çok etkilenmemektedir. MBE'nin -0,00096 ile -0,001452 değerleri arasında değiştiği görülmüştür. Model, işareti çok başarılı bir şekilde tahmin edebilmektedir.



Şekil 3.11: En iyi ARMAX modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.12: En iyi ARMAX modeli için korelasyon grafiği.

3.2 Doğrusal Olmayan Modeller


FFN Modeli

Rüzgar şiddeti serisi her dört elemanın ilk üç elemanı eğitim veri setine, sonra gelen elemanı test setine ayrılacak şekilde işlem görmüş olup ağı öğrenmesi için kullanılan örnek veri seti böylelikle oluşturulmuştur. Eğitim/test verilerinin ayrılması işlemi bütün sinir ağı modellerinde (FFN, RBFN, GRNN) aynı şekilde gerçekleştirilmiştir. Gizli nöronlarda aktivasyon fonksiyonu olarak kullanılmak üzere tanjant sigmoid fonksiyonu seçilmiştir. Giriş nöronları 1'den 50'ye kadar götürülürken gizli katman sayısı 1 olarak belirlendikten sonra gizli nöron sayısı 2'den 15' kadar artırılarak denemeler yapılmıştır.

Bu ağ yapısı için modeli isimlendirmenin sırasıyla giriş nöronu sayısı, gizli nöron sayısı, çıkış nöronu sayısı olarak yapıldığı durumda Şekil 3.13'te ölçüm değerleriyle birlikte yanıtı verilen en iyi model (2-14-1) olarak hesaplanmıştır. En iyi çıkan modelin model yanıtı ve ölçüm değerleri için korelasyon grafiği ise Şekil 3.14'tedir Bu model için $R_1^2=0,996836$, $MAE=0,444946$ 'tür. $MBE=0,033439$ değerinin gösterdiği gibi az miktarda yüksek tahmin etmekle birlikte işaretin öngörüsünde başarılı modellerin arasında yer almaktadır.



Şekil 3.13: En iyi FFN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.14: En iyi FFN modeli için korelasyon grafiği


RBFN Modeli

Rüzgar şiddeti serisi her dört elemanının ilk üç elemanı eğitim veri setine, sonra gelen elemanı test setine ayrılacak şekilde işlem görmüştür. Bir adet RBF katmanı barındıran bu ağ yapısında, sabit bir ağ mimarisi olduğu için katman sayılarına dair herhangi bir belirleme yapılmasına ihtiyaç bulunmamaktadır. RBF nöronlarında aktivasyon fonksiyonu olarak kullanmak üzere Gauss fonksiyonu seçilmiştir. Genişlik parametresi 1’den 300’e götürülürken gömme boyutunun 1’den 5’e değişen değerleri için incelemeler yapılmıştır.

Bu ağ yapısı için isimlendirmenin sırasıyla giriş nöronu sayısı, çıkış nöronu sayısı, genişlik parametresi (β) olarak yapıldığı durumda Şekil 3.15’de ölçüm değerleriyle birlikte yanıtı verilen en iyi model (2-1-53) olarak hesaplanmıştır. Genellikle genişlik parametresinin 1 olduğu modeller en iyi öngörüyü yapabildiği bilindiğinden en iyi modelin genişlik parametresinin 53 olarak hesaplanması beklenenden farklı bir sonuçtur. En iyi çıkan modelin model yanıtı ve ölçüm değerleri için korelasyon grafiği ise Şekil 3.16’dadır. Bu model için $R_1^2=0,996752$, $MAE=0,444904$ ’tür. MBE 0,034587 değerinin gösterdiği gibi az miktarda yüksek tahmin etmekle birlikte işareti iyi öngören modeller arasındadır.



Şekil 3.15: En iyi RBFN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.




Şekil 3.16: En iyi RBFN modeli için korelasyon grafiği


GRNN Modeli

Rüzgar şiddeti serisi her dört elemanının ilk üç elemanı eğitim veri setine, sonra gelen elemanı test setine ayrılacak şekilde işlem görmüştür. Aktivasyon fonksiyonu olarak örnek nöronlarında RBFN'e benzer şekilde Gauss fonksiyon kullanılmıştır. Bu ağın mimarisi de RBFN gibi sabit olduğundan katman sayılarına dair herhangi bir belirleme yapılmasına ihtiyaç bulunmamaktadır.

Bu ağ yapısı için isimlendirmenin sırasıyla giriş nöronu sayısı, çıkış nöronu sayısı, genişlik parametresi (β) olarak yapıldığı durum için Şekil 3.17'de ölçüm değerleriyle birlikte yanıtı verilen en iyi model (1-1-1) olarak hesaplanmıştır. Artan genişlik parametresiyle modelin öngörü performansının kötüleştiği gözlemlendiğinden $\beta=1$ değeri için (genişlik parametresi sabit tutularak) ve gömme boyutu 1'den 200'e artırılarak modeller incelenmiştir. RBFN'in aksine bu ağ yapısında, beklenildiği üzere en iyi modelin genişlik parametresi 1 olarak bulunmuştur. En iyi çıkan modelin model yanıtı ve ölçüm değerleri için korelasyon grafiği ise Şekil 3.18'dedir Bu model için $R_1^2=0,996312$, MAE=0,48404 olarak bulunmuştur. En iyi model için MBE değeri 0,006797 olarak hesaplanmış olmakla birlikte yer yer yüksek, yer yer düşük öngöründe bulunduğu için yeterince başarılı bir öngörücü değildir.



Şekil 3.17: En iyi GRNN modeli için ölçüm değerleri ve modelin çıkışının zamana bağlı grafiği.



Şekil 3.18: En iyi GRNN modeli için korelasyon grafiği

4. SONUÇ VE ÖNERİLER

Bu çalışmada bir adım ileri rüzgar şiddeti öngörüsü yapmak amacıyla 5 adet doğrusal ve 3 adet doğrusal olmayan toplam 8 model için gerekli hesaplamalar yapılmıştır. Her modelin matematiksel altyapısına dair gerekli bilgiler Bölüm 2’de verilmiştir. Çalışmada incelenen bütün modeller MATLAB programı yardımıyla oluşturulmuştur. Bölüm 3’te, kullanılan modellerin başarımları ve modellerin öngörü sırasında gösterdikleri karakteristik davranışlar değerlendirilmiştir.

AR model mertebesi AR modeli için 1’den 50’ye kadar, ARX modeli için 1’den 150’ye kadar; AR ve MA terimlerinin birlikte bulunduğu modeller için ise mertebelerin toplamı 50’ye ulaşana dek ilgili modeller hesaplamaya dahil edilmiştir. FFN modeli için giriş nöron sayısı 1’den 50’ye artırılırken 1 adet gizli katman için bu gizli katmanda bulunan nöron sayısı da artan giriş nöronu sayılarının her biri için 1’den 15’e kadar artırılarak gerekli hesaplamalar yapılmıştır. RBFN modeli için gömme boyutunun 1’den 5’e kadar artan değerleri için genişlik parametresi 1’den 300’e kadar değiştirilerek neticesinde oluşturulan modeller öngörü amacıyla kullanılmıştır. GRNN modeli için ise artan genişlik parametreleri için model öngörüsünün kötüleştiği gözlemlendiğinden genişlik parametresi 1 olarak belirlenerek gömme boyutu 1’den 200’e artırılmıştır. Bahsedilen model yapılarının her biri için en iyisi olarak bulunan modelin öngörü başarımını değerlendiren hata kriterleri Çizelge 4.1’de verilmiştir.

0 ile 1 aralığında değerler alan R_1^2 ’nin büyük değerler alması veriyle modelin uyumunun iyi olduğunu gösterdiğinden Çizelge 4.1’e bakıldığında oluşturulan bütün modeller içerisinde en başarılı modelin ARX modeli olduğu görülür. RMSE’nin iyi bir model için küçük değerler alması gerektiği bilinmektedir. ARX modelinden sonra en küçük RMS hatası değerine ARMAX modelinin sahip olduğu çizelgeden görülebilir. Ek olarak ARMAX modelleri ARMA modelinden daha iyi sonuçlar vermiştir. Bu gözlemler sonucunda eksojen giriş kullanımının model performansını iyileştirmeye direkt etkisi olduğu ifade edilebilir. Eksojen modellerin eksojen

Çizelge 4.1: En iyi başarımları gösteren modeller ve hata kriterleri.

Model ve Sabit Parametre	Parametre Değeri	R_1^2	R_2^2	MAE	$nMAE$	MBE	$nMBE$	$RMSE$	$nRMSE$	En İyi Model
ARX (n_b)	1	0,999883	0,999139	0,087623	0,008793	-0,001512	-0,000152	0,116047	0,011645	149,1
	3	0,999883	0,999140	0,087548	0,008785	-0,001533	-0,000154	0,115984	0,011639	150,3
	5	0,999883	0,999140	0,087548	0,008785	-0,001533	-0,000154	0,115984	0,011639	150,5
	10	0,999883	0,999140	0,087548	0,008785	-0,001533	-0,000154	0,115984	0,011639	150,10
ARMAX (n_b)	1	0,999869	0,999036	0,095785	0,009612	-0,001452	-0,000146	0,122777	0,012320	19,1,30
	3	0,999869	0,999035	0,095646	0,009598	-0,00122	-0,000122	0,122809	0,012324	20,3,29
	5	0,999869	0,999036	0,095733	0,009606	-0,001067	-0,000107	0,122732	0,012316	20,5,30
	10	0,999869	0,999037	0,095136	0,009547	-0,00096	-0,000096	0,12269	0,012312	20,10,30
ARIMA (d)	1	0,996166	0,971794	0,444613	0,044608	0,373356	0,037459	0,663975	0,066617	16,1,1
	2	0,99053	0,930338	0,706887	0,070922	0,059982	0,006018	1,043475	0,104692	19,2,9
ARMA	-	0,998965	0,992387	0,149189	0,014968	0,044378	0,004452	0,344960	0,034610	19,1
AR	-	0,998965	0,992387	0,149189	0,014968	0,044378	0,004452	0,344960	0,034610	19
FFN	-	0,996836	0,976813	0,444946	0,025869	0,033439	0,001944	0,602998	0,003506	2-14-1
RBFN	-	0,996752	0,976201	0,444904	0,025867	0,034587	0,002011	0,610912	0,035518	2-1-53
GRNN (β)	1	0,996312	0,972909	0,484047	0,028142	0,006797	0,000395	0,650984	0,037848	1-1-1

olmayan geleneksel modellerden daha iyi sonuç verdiđi ve hareketli ortalama (MA) ifadesinin incelenen rüzgar verisi için anlamlı bir katkı sağlamadıđı görölmüştür.

Çalışmanın bir diğ er sonucu ise eksojen modellerin kullanılan veri seti için, karmaş ık ve doğ rusal olmayan sistemleri modellemedeki başarısıyla bilinen yapay sinir ağı ları modellerinden de daha başarılı olmasıdır. Zaman serisi analizinde kullanımı giderek artan ve bazen geleneksel ö ngörü yöntemlerine göre daha iyi sonuçlar sağlayabilen yapay sinir ağı ları bu çalışma için en iyi ö ngörü yü yapabilen modellerden olamamıştır. Bu çalışma, sunduğ u avantajlar sebebiyle çalış malarda sıklıkla faydalanılan yapay sinir ağı larına alternatif olarak eksojen modellerin de değ erlendirilmesi gereken bir yaklaş ım olduğ u göstermektedir.

Bir adım ileri ö ngörü yapılan bu çalış manın ış ığında ileriki çalış malarda bir rüzgar verisi için ö ngörü ufkunun bir adımdan daha ileri olması durumu irdelenebilir. Ek olarak, bu çalış manın çıktı larının pekiştirilebilmesi amacıyla farklı topografik özelliklere sahip bölgelerden alınan, farklı karakteristiklere sahip rüzgar ş iddeti verileri için de benzer bir çalışma yürütülebilir. Dakikalık rüzgar ş iddeti verisi kullanılan bu çalış manın yanısıra farklı ö rnekleme periyotlarındaki veriler için modellerin ö ngörü performansının incelenmesi de ileriki çalış malar için düşünö lebilir.

KAYNAKLAR

- [1] **Nersesian, R.** (2010). *Energy for the 21st century: a comprehensive guide to conventional and alternative sources*. Armonk (NY): M.E. Sharpe.
- [2] **Url-2** <<https://www.enerji.gov.tr/tr-tr/sayfalar/ruzgar>>, Eriřim tarihi 06.05.2019.
- [3] **Çömert, R., Bilget, Ö., ve Çabuk, A.** (2015). Kyoto Protokolüne İmza Atan G20 Ülkelerinin Yıllara Göre Karbon Salınımlarının (1990-2012) Coğrafi Bilgi Sistemleri Yardımı İle Analizi. *Anadolu Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü*, 883-891.
- [4] **Url-4** <<http://www.mfa.gov.tr/kyoto-protokolu.tr.mfa>>, Eriřim tarihi 06.05.2019.
- [5] **Küresel Rüzgar Enerjisi Konseyi (GWEC).** (2017). *Global Wind Report*. Eriřim tarihi 06.05.2019. Eriřim adresi <https://www.slideshare.net/wyakab/gwec-global-wind-report-april-2018>.
- [6] **Url-6** <<https://www.euractiv.com/section/climate-environment/news/denmark-breaks-its-own-world-record-in-wind-energy>>, erişim tarihi 06.05.2019.
- [7] **Url-7** <<https://cleantechnica.com/2018/01/06/44-wind-denmark-smashed-already-huge-wind-energy-records-2017/>>, erişim tarihi 06.05.2019.
- [8] **Uluslararası Yenilenebilir Enerji Ajansı (IRENA).** (2013). *30 Years of Policies for Wind Energy: Lessons from 12 Wind Energy Markets*. Birleşik Arap Emirlikleri. Eriřim adresi https://www.irena.org/DocumentDownloads/Publications/IRENA_GWEC_WindReport_Full.pdf
- [9] **Url-9** <<https://www.edie.net/news/10/Scottish-renewables-break-100--threshold-for-electricity-demand/>>, erişim tarihi 06.05.2019.
- [10] **Url-10** <<http://wwindea.org/blog/2018/02/12/2017-statistics>>, erişim tarihi 06.05.2019.
- [11] **Url-11** <https://en.wikipedia.org/wiki/Coal_in_China#cite_note-fall-1>, erişim tarihi 06.05.2019.
- [12] **Url-12** <<https://www.iea.org/policiesandmeasures/pams/china/name-161254-en.php>>, erişim tarihi 06.05.2019.
- [13] **U.S. Energy Information Administration.** (2017). *International Energy Outlook*. Eriřim adresi [https://www.eia.gov/outlooks/ieo/pdf/0484\(2017\).pdf](https://www.eia.gov/outlooks/ieo/pdf/0484(2017).pdf)

- [14] **Strateji Geliştirme Başkanlığı.** (2017). *Dünya ve Türkiye Enerji ve Tabii Kaynaklar Görünümü.* Ankara: T.C. Enerji ve Tabii Kaynaklar Bakanlığı. Erişim adresi https://www.enerji.gov.tr/Resources/Sites/1/Pages/Sayi_15/mobile/index.html#p=1
- [15] **T.C. Enerji ve Tabii Kaynaklar Bakanlığı.** (2019). *Türkiye Elektrik Enerjisi Talep Projeksiyonu Raporu.* Ankara.
- [16] **Yenilenebilir Enerji Genel Müdürlüğü.** (2014). *Türkiye Ulusal Yenilenebilir Enerji Eylem Planı.* Ankara: T.C. Enerji ve Tabii Kaynaklar Bakanlığı. Erişim adresi http://www.yegm.gov.tr/duyurular_haberler/document/Turkiye_Ulusal_Yenilenebilir_Enerji_Eylem_Planı.pdf
- [17] **Kısar, A.** (2016). Türkiye’de Rüzgar Enerjisinin Gelişimi ve Geleceği. *Elektrik Mühendisleri Odası İzmir Şubesi Haziran 2016 Bülteni*, 27.
- [18] **Doğal Hayatı Koruma Vakfı (WWF).** (2014). *Türkiye’nin Yenilenebilir Gücü: Türkiye için Alternatif Elektrik Enerjisi Arz Senaryoları.* İstanbul. Erişim adresi http://www.wwf.org.tr/basin_bultenleri/raporlar/?3640/turkiyeninyenilenebilirgucu#
- [19] **Türkiye Rüzgar Enerjisi Birliği (TÜREB).** (2018). *Türkiye Rüzgar Enerjisi İstatistik Raporu.* Ankara. Erişim adresi https://www.tureb.com.tr/files/tureb_sayfa/duyurular/2018/03/turkiye_ruzgar_enerjisi_istatistik_raporu_ocak_2018.pdf
- [20] **Çalışkan, M.** (2010). Türkiye Rüzgar Enerjisi Potansiyeli. [Powerpoint slaytı]. Ankara: T.C. Enerji ve Tabii Kaynaklar Bakanlığı. Erişim adresi https://www.mgm.gov.tr/FILES/haberler/2010/rets-seminer/2_Mustafa_CALISKAN_RITM.pdf
- [21] **Milligan, M., Miller, A. ve Chapman, F.** (1995). Estimating the Economic Value of Wind Forecasting to Utilities. 25. *Annual Conference and Exhibition on Wind Power.* Washington, ABD.
- [22] **Hutting, H., & Cleijne, J.** (1999). The Price of Large Scale Offshore Wind Energy in a Free Electricity Market. *Proceedings of the European Wind Energy Conference.* Nice, Fransa. 399-401.
- [23] **Nielsen, L., Morthorst, P., ve Skytte, K.** (1999). *Wind power and a liberalised North European electricity exchange.* Danimarka.
- [24] **Sørensen, B. ve Meibom, P.** (1998). A global renewable energy scenario. IMFUFA Texts 354, 112. Roskilde University.
- [25] **Kariniotakis G., Matos M. ve Miranda V.** (1999). Assessment of the benefits from advanced load & wind power forecasting in autonomous power systems. *Proceedings of the European Wind Energy Conference,* Nice, Fransa. 391-394.
- [26] **Nogaret, E., Stavrakakis, G., Kariniotakis, G., Papadopoulos, M., Hatziargyriou, N., Androutsos, A., ... Karagounis, V.** (1997). An

- advanced control system for the optimal operation and management of medium size power systems with a large penetration from renewable power sources. *Renewable Energy*, 12(2), 137–149. doi: 10.1016/s0960-1481(97)00028-1
- [27] **Gilman, B., Cheng, M., Isaac, J., Zack, J., Bailey, B. ve Brower, M.** (2001). The Value of Wind Forecasting to Southern California Edison. *Proceedings Windpower2001*. Washington, ABD.
- [28] **Efthimiou, G., Kumar, P., Giannissi, S., Feiz, A. ve Andronopoulos, S.** (2019). Prediction of the wind speed probabilities in the atmospheric surface layer. *Renewable Energy*, 132, 921-930. doi: 10.1016/j.renene.2018.08.060
- [29] **Kovács, A., Erdős, G., Viharos, Z. J. ve Monostori, L.** (2011). A system for the detailed scheduling of wind farm maintenance. *CIRP Annals*, 60(1), 497-501. doi:10.1016/j.cirp.2011.03.049
- [30] **Parks, K., Wan, Y., Wiener, G. ve Liu, Y.** (2011). Wind Energy Forecasting: A Collaboration of the National Center for Atmospheric Research (NCAR) and Xcel Energy. doi: 10.2172/1027161
- [31] **Jia, X., Zhao, M., Di, Y., Li, P. ve Lee, J.** (2018). Sparse filtering with the generalized lp/lq norm and its applications to the condition monitoring of rotating machinery. *Mechanical Systems and Signal Processing*, 102, 198-213. doi: 10.1016/j.ymssp.2017.09.018
- [32] **Karık, F., Sözen, A. ve İzgeç, M.** (2017). Rüzgâr Gücü Tahminlerinin Önemi: Türkiye Elektrik Piyasasında Bir Uygulama. *Journal of Polytechnic*, 851-861. doi:10.2339/politeknik.369038
- [33] **Bhaskar, M., Jain, A. ve Srinath, N.** (2010). Wind speed forecasting: Present status. *International Conference on Power System Technology*. doi: 10.1109/powercon.2010.5666623
- [34] **Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J. ve G. Conzelmann** (2009). *Wind Power Forecasting: State-of-the-Art*. Argonne Laboratuvarı, Chicago Üniversitesi, ABD. Erişim adresi <https://publications.anl.gov/anlpubs/2009/11/65613.pdf>
- [35] **Sideratos, G. ve Hatziargyriou, N.** (2007). An Advanced Statistical Method for Wind Power Forecasting. *IEEE Transactions on Power Systems*, 22(1), 258–265. doi: 10.1109/tpwrs.2006.889078
- [36] **Wang, S., Zhang, N., Wu, L. ve Wang, Y.** (2016). Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method. *Renewable Energy*, 94, 629–636. doi: 10.1016/j.renene.2016.03.103
- [37] **Haque, A., Mandal, P., Meng, J. ve Negnevitsky, M.** (2013). Wind speed forecast model for wind farm based on a hybrid machine learning algorithm. *International Journal of Sustainable Energy*, 34(1), 38–51. doi: 10.1080/14786451.2013.826224

- [38] **Chang, W.-Y.** (2014). A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, 02(04), 161–168. doi: 10.4236/jpee.2014.24023
- [39] **Wang, J. ve Li, Y.** (2019). An innovative hybrid approach for multi-step ahead wind speed prediction. *Applied Soft Computing*, 78, 296–309. doi: 10.1016/j.asoc.2019.02.034
- [40] **Cassola, F. ve Burlando, M.** (2012). Wind speed and wind energy forecast through Kalman filtering of Numerical Weather Prediction model output. *Applied Energy*, 99, 154–166. doi: 10.1016/j.apenergy.2012.03.054
- [41] **Durán, M., Cros, D. ve Riquelme, J.** (2007). Short-Term Wind Power Forecast Based on ARX Models. *Journal of Energy Engineering*, 133(3), 172–180. doi: 10.1061/(asce)0733-9402(2007)133:3(172)
- [42] **Bossanyi, E.** (1985). Short-Term Wind Prediction Using Kalman Filters. *Wind Engineering*, 9(1), 1-8.
- [43] **Contaxis, G. ve Kabouris, J.** (1991). Short term scheduling in a wind/diesel autonomous energy system. *IEEE Transactions on Power Systems*, 6(3), 1161–1167. doi: 10.1109/59.119261
- [44] **Torres, J., García, A., Blas, M. ve Francisco, A.** (2005). Forecast of hourly average wind speed with ARMA models in Navarre (Spain). *Solar Energy*, 79(1), 65–77. doi: 10.1016/j.solener.2004.09.013
- [45] **Erdem, E. ve Shi, J.** (2011). ARMA based approaches for forecasting the tuple of wind speed and direction. *Applied Energy*, 88(4), 1405–1414. doi: 10.1016/j.apenergy.2010.10.031
- [46] **Hodge, B.-M., Zeiler, A., Brooks, D., Blau, G., Pekny, J. ve Reklatis, G.** (2011). Improved Wind Power Forecasting with ARIMA Models. *Computer Aided Chemical Engineering 21st European Symposium on Computer Aided Process Engineering*, 1789–1793. doi: 10.1016/b978-0-444-54298-4.50136-7
- [47] **Miranda, M. ve Dunn, R.** (2006). One-hour-ahead wind speed prediction using a Bayesian methodology. *IEEE Power Engineering Society General Meeting*. doi: 10.1109/pes.2006.1709479
- [48] **Milligan, M., Schwartz, M. ve Y.-H. Wan.** (2004). Statistical Wind Power Forecasting for U.S. Wind Farms. *The 17th Conference on Probability and Statistics in the Atmospheric Sciences*. Elektronik ön baskı.
- [49] **Gomes, P. ve Castro, R.** (2012). Wind Speed and Wind Power Forecasting using Statistical Models: AutoRegressive Moving Average (ARMA) and Artificial Neural Networks (ANN). *International Journal of Sustainable Energy Development*, 1(2), 41–50. doi: 10.20533/ijsted.2046.3707.2012.0007

- [50] **Abdel-Aal, R., Elhadidy, M. & Shaahid, S.** (2009). Modeling and forecasting the mean hourly wind speed time series using GMDH-based abductive networks. *Renewable Energy*, 34(7), 1686–1699. doi: 10.1016/j.renene.2009.01.001
- [51] **Sideratos, G. ve Hatziargyriou, N.** (2006). Application of Radial Basis Function Networks for Wind Power Forecasting. *Artificial Neural Networks – ICANN Lecture Notes in Computer Science*, 726–735. doi: 10.1007/11840930_76
- [52] **Wang, X., Sideratos, G., Hatziargyriou, N. ve Tsoukalas, L.** (2004) Wind speed forecasting for power system operational planning. *International Conference on Probabilistic Methods Applied to Power Systems*, 470-474.
- [53] **Kariniotakis, G., Stavrakakis, G. ve Nogaret, E.** (1996). Wind power forecasting using advanced neural networks models. *IEEE Transactions on Energy Conversion*, 11(4), 762–767. doi: 10.1109/60.556376
- [54] **Katsigiannis, Y., Tsikalakis, A., Georgilakis, P., ve Hatziargyriou, N.** (2006). Improved wind power forecasting using a combined neuro-fuzzy and artificial neural network model. *Hellenic Conference on Artificial Intelligence*, 105-115. doi: 10.1007/11752912_13
- [55] **Barbounis, T. ve Theocharis, J.** (2007). Locally recurrent neural networks for wind speed prediction using spatial correlation. *Information Sciences*, 177(24), 5775-5797. doi: 10.1016/j.ins.2007.05.024
- [56] **More, A. ve Deo, M.** (2003). Forecasting wind with neural networks. *Marine Structures*, 16(1), 35-49. doi: 10.1016/s0951-8339(02)00053-9
- [57] **Fonte, P. ve Quadrado, J.** (2005). ANN approach to WECS power forecast. *IEEE Conference on Emerging Technologies and Factory Automation*, 1, 1069-1072. doi: 10.1109/etfa.2005.1612645
- [58] **Wu, L., Park, J., Choi, J., Cha, J. ve Lee, K. Y.** (2009). A study on wind speed prediction using artificial neural network at Jeju Island in Korea. *Transmission & Distribution Conference & Exposition: Asia and Pacific*. doi: 10.1109/td-asia.2009.5356873
- [59] **López, P., Velo, R. ve Maseda, F.** (2008). Effect of direction on wind speed estimation in complex terrain using neural networks. *Renewable Energy*, 33(10), 2266–2272. doi: 10.1016/j.renene.2007.12.020
- [60] **Alexiadis, M., Dokopoulos, P., Sahsamanoglou, H. ve Manousaridis, I.** (1998) Short-term forecasting of wind speed and related electric power. *Solar Energy*, 63(1), 61-68. doi: 10.1016/s0038-092x(98)00032-2
- [61] **Alexiadis, M., Dokopoulos, P. ve Sahsamanoglou, H.** (1999) Wind speed and power forecasting based on spatial correlation models. *IEEE Transactions on Energy Conversion*, 14(3), 836–837.

- [62] **Sfetsos, A.** (2000). A comparison of various forecasting techniques applied to mean hourly wind speed time series. *Renewable Energy*, 21(1), 23-35. doi: 10.1016/s0960-1481(99)00125-1
- [63] **Sfetsos, A.** (2002). A novel approach for the forecasting of mean hourly wind speed time series. *Renewable Energy*, 27(2), 163–174. doi: 10.1016/s0960-1481(01)00193-8.
- [64] **Potter, C. ve Negnevitsky, M.** (2006). Very short-term wind forecasting for Tasmanian power generation. *IEEE Transactions on Power Systems*, 21(2), 965-972. doi: 10.1109/tpwrs.2006.873421
- [65] **Maqsood, I., Khan, M. R., Huang, G. H. ve Abdalla, R.** (2005). Application of soft computing models to hourly weather analysis in southern Saskatchewan, Canada. *Engineering Applications of Artificial Intelligence*, 18(1), 115–125. doi: 10.1016/j.engappai.2004.08.019
- [66] **Atakulreka, A. ve Sutivong, D.** (2007). Avoiding Local Minima in Feedforward Neural Networks by Simultaneous Learning. *Advances in Artificial Intelligence Lecture Notes in Computer Science*, 100-109. doi: 10.1007/978-3-540-76928-6_12
- [67] **Zhang, Y., Chen, B., Pan, G. ve Zhao, Y.** (2019). A novel hybrid model based on VMD-WT and PCA-BP-RBF neural network for short-term wind speed forecasting. *Energy Conversion and Management*, 195, 180-197. doi: 10.1016/j.enconman.2019.05.005
- [68] **Feng, C., Cui, M., Hodge, B.-M. ve Zhang, J.** (2017). A data-driven multi-model methodology with deep feature selection for short-term wind forecasting. *Applied Energy*, 190, 1245–1257. doi: 10.1016/j.apenergy.2017.01.043
- [69] **Sideratos, G. ve Hatziargyriou, N.** (2007). An Advanced Statistical Method for Wind Power Forecasting. *IEEE Transactions on Power Systems*, 22(1), 258–265. doi: 10.1109/tpwrs.2006.889078
- [70] **Wu, Y.-K. ve Hong, J.-S.** (2007). A literature review of wind forecasting technology in the world. *IEEE Lausanne Power Tech.* doi: 10.1109/pct.2007.4538368
- [71] **Brockwell, P. ve Davis, R..** (2016). *Introduction to time series and forecasting*. Switzerland: Springer.
- [72] **Montgomery, D., Kulahci, M. ve Jennings, C.** (2016). *Introduction to time series analysis and forecasting*. Hoboken, NJ: Wiley.
- [73] **Subba Rao, S.** (2018) *A Course in Time Series Analysis*. Ders notları, Texas A&M Üniversitesi, ABD.
- [74] **Ljung, L.** (2012). *System identification: theory for the user*. Upper Saddle River, NJ: Prentice Hall PTR.
- [75] **Tangirala, A. K.** (2015). *Principles of system identification: theory and practice*. Boca Raton: CRC Press, Taylor & Francis Group.
- [76] **Url-76** <<http://people.duke.edu/~rnau/411arim3.htm>>, erişim tarihi 03.05.2019.

- [77] **Kalınlı, A.** (2002) Elman Ağının Simulated Annealing Algoritması Kullanılarak Sistem Kimliklendirme İçin Eğitilmesi. *Osmangazi Üniversitesi Müh.Mim.Fak.Dergisi*, XVI(2).
- [78] **Kaastra, I. ve Boyd, M.** (1996) Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*. 10, 215- 236.
- [79] **Öztemel, E.** (2006). *Yapay Sinir Ağları (2. Baskı)*. İstanbul: Papatya Yayıncılık.
- [80] **Haykin, S.** (1999). *Neural Networks: A Comprehensive Foundation*. Macmillan College Publishing Company.
- [81] **Fausett, L.** (2004). *Fundamentals of neural networks: architectures, algorithms, and applications*. Delhi, India: Pearson Education.
- [82] **Reed, R. ve Marks, R. J.** (1999). *Neural smithing: supervised learning in feedforward artificial neural networks*. Cambridge (Massachusetts): MIT.
- [83] **Wilamowski, B. ve Irwin, J.** (2011). *Intelligent systems*. Boca Raton, FL: CRC Press.
- [84] **Osborne M.** (1992). Fisher's method of scoring. *International Statistical Review*, 86, 271–286.
- [85] **Khosravi, M., Barghinia, S. ve Ansarimehr, P.** (2006). New momentum adjustment technique for Levenberg-Marquardt neural network training used in short term load forecasting. *21st International Power System Conference*. Tehran, Iran. 1782-1788.
- [86] **Ahmadian, A.** (2016). *Numerical models for submerged breakwaters: coastal hydrodynamics and morphodynamics*. Amsterdam: Butterworth-Heinemann is an imprint of Elsevier.
- [87] **Çavuşlu, M., Becerikli, Y. ve Karakuzu, C.** (2012). Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleştirilmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(1).
- [88] **Wilamowski, B., Iplikci, S., Kaynak, O. ve Efe, M.** (2001). An algorithm for fast convergence in training neural networks. *International Joint Conference on Neural Networks. Proceedings (Cat. No.01CH37222)*. doi: 10.1109/ijcnn.2001.938431
- [89] **Moody, J. ve Darken, C.** (1989). Fast Learning in Networks of Locally-Tuned Processing Units. *Neural Computation*, 1(2), 281–294. doi: 10.1162/neco.1989.1.2.281
- [90] **Specht, D.** (1993). The general regression neural network - Rediscovered. *Neural Networks*, 6(7), 1033–1034. doi: 10.1016/s0893-6080(09)80013-0
- [91] **Specht, D. ve Shapiro, P.** (1991). Generalization accuracy of probabilistic neural networks compared with backpropagation networks. *Seattle International Joint Conference on Neural Networks*. doi: 10.1109/ijcnn.1991.155296
- [92] **Li, G. ve Shi, J.** (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7), 2313–2320. doi: 10.1016/j.apenergy.2009.12.013

- [93] **Korkmaz, E., Izgi, E. ve Tutun, S.** (2018). Forecasting of short-term wind speed at different heights using a comparative forecasting approach. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(5), 2553–2569. doi: 10.3906/elk-1601-213

ÖZGEÇMİŞ

Ad-Soyad : İrem Damla Nacar

E-posta : damlanacar@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2015, İTÜ, Elektrik-Elektronik Fakültesi, Kontrol ve Otomasyon Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- ENKA İnşaat ve Sanayi A.Ş.'de Kontrol ve Enstrümantasyon Mühendisi olarak çalışmaktayım.