

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**EKSTREM RÜZGARLARIN YAPAY SİNİR AĞLARI VE ÇOKLU LİNEER
REGRESYON KULLANILARAK KISA SÜRELİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Melek AKIN

Meteoroloji Mühendisliği Anabilim Dalı

Atmosfer Bilimleri Programı

AĞUSTOS 2018

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**EKSTREM RÜZGARLARIN YAPAY SİNİR AĞLARI VE ÇOKLU LİNEER
REGRESYON KULLANILARAK KISA SÜRELİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Melek AKIN
(511151010)**

Meteoroloji Mühendisliği Anabilim Dalı

Atmosfer Bilimleri Programı

Tez Danışmanı: Doç. Dr. Ahmet ÖZTOPAL

AĞUSTOS 2018

İTÜ, Fen Bilimleri Enstitüsü'nün 511151010 numaralı Yüksek Lisans Öğrencisi Melek AKIN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “EKSTREM RÜZGARLARIN YAPAY SİNİR AĞLARI VE ÇOKLU LİNEER REGRESYON KULLANILARAK KISA SÜRELİ TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Ahmet ÖZTOPAL**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Zekai Şen**
İstanbul Medipol Üniversitesi

Prof. Dr. Ahmet Duran Şahin
İstanbul Teknik Üniversitesi

Teslim Tarihi : 3 Eylül 2018
Savunma Tarihi : 31 Ağustos 2018





Değerli Aileme,



ÖNSÖZ

Ülkemizin yenilenebilir enerji kaynaklarına olan ilgisi ve verdiği önem gün geçtikçe artmaktadır. Dolayısıyla bu alandaki potansiyel ve tahmin çalışmaları da gittikçe değer kazanmaktadır. Bu amaçla, yaşadığımız coğrafyanın kısa süreli rüzgar şiddeti tahminlerinin, Yapay Sinir Ağları ve Çoklu Lineer Regresyon gibi iki farklı yöntemle elde edilmesi üzerine olan bu tezi hazırlamış olmaktan mutluluk duyduğumu öncelikle ifade etmek isterim.

Aynı zamanda bu tez, araştırmacı bursiyer olarak yer aldığım bir TÜBİTAK araştırma projesi olan 215M387 numaralı ve “Yeni Avrupa Rüzgar Atlasında Ekstrem Rüzgarlar ve Türbülans Koşullarının Araştırılması ve Tahmin Sistemlerinin Geliştirilmesi” başlıklı projenin ekstrem rüzgar çalışmalarına katkı sağlamak amacıyla hazırlanmıştır. Tezde ülkemize ait 18 adet Rüzgar Tarlasına ait veriler kullanılmıştır. Bu kapsamda vermiş oldukları destekten dolayı TÜBİTAK ve RES firmalarına teşekkürü bir borç bilirim.

Yüksek lisans öğrenimim boyunca yardımlarını esirgemeyen, bilgisi ve desteğiyle her zaman yanımda olan başta danışmam hocam Doç. Dr. Ahmet ÖZTOPAL’a ve bu çalışmanın ortaya çıkmasında sağlamış olduğu değerli katkılarından dolayı yukarıda adı verilen projenin yürütücüsü Prof. Dr. Ahmet Duran ŞAHİN’e en derin saygı ve şükranlarımı sunarım.

Son olarak, bana olan inancını hiçbir zaman yitirmeyen, her konuda desteğini arkamda hissettiğim annem Emine AKIN ve aileme ise hayatım boyunca minnettar kalacağım.

Ağustos 2018

Melek AKIN
(Meteoroloji Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1 Tezin Amacı	3
2. RÜZGAR ŞİDDETİ VE ENERJİSİ TAHMİN SİSTEMLERİ	5
2.1 Sayısal Hava Tahmi Modelleri	5
2.1.1 Global modeller	6
2.1.2 SAM (Sınırlı alan modeli)	7
2.2 İstatistiksel Yaklaşımlar	7
3. VERİ	11
4. KULLANILAN YÖNTEM VE İSTATİSTİK	15
4.1 Yapay Sinir Ağları (YSA)	15
4.1.1 YSA'da öğrenme	17
4.2 Regresyon Analizi	18
4.2.1 Basit lineer regresyon	19
4.2.2 Çoklu lineer regresyon	19
5. YSA HASSASİYET ANALİZ YÖNTEMİ	21
6. BULGU VE DEĞERLENDİRMELER	25
6.1 Maksimum Rüzgarlar	25
6.3 Ekstrem Rüzgarlar	31
7. SONUÇLAR VE ÖNERİLER	37
KAYNAKLAR	39
EKLER	43
ÖZGEÇMİŞ	93



KISALTMALAR

ANFIS	: Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
AR	: Otoregresif Model
ARIMA	: Otoregresif Entegre Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
BM	: Bulanık Mantık
ÇLR	: Çoklu Lineer Regresyon
GA	: Genetik Algoritma
HIRLAM	: Yüksek Çözünürlüklü Sınırlı Bölge Modeli
KOH	: Karekök Ortalama Hata
m/s	: metre/saniye
MA	: Hareketli Ortalama
MGM	: Meteoroloji Genel Müdürlüğü
OKH	: Ortalama Karesel Hata
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
RT	: Rüzgar Tarlası
SAM	: Sınırlı Alan Modeli
SHT	: Sayısal Hava Tahmini
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
YSA	: Yapay Sinir Ağları
WRF	: Hava Tahmin ve Araştırma



SEMBOLLER

e	: Hata değeri
ε	: Hata terimi
P	: Hava basıncı
σ	: Standart sapma
t	: Zaman
T	: Hava sıcaklığı
v	: Rüzgar hızı





ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Çalışmada kullanılan RT'ler.	12
Çizelge 3.2 : RT'lerde ölçülen maksimum rüzgar şiddetlerinin esme aralıklarındaki sayıları.	13
Çizelge 5.1 : YSA mimari kodlaması.	22
Çizelge 6.1 : Maksimum rüzgarların YSA ve ÇLR eğitim aşaması hata ve korelasyon karşılaştırması.	25
Çizelge 6.2 : Maksimum rüzgarların YSA ve ÇLR test aşaması hata ve korelasyon karşılaştırması.	26
Çizelge 6.3: RT istasyonlarına ait ÇLR katsayıları.	27
Çizelge 6.4 : Ekstrem rüzgarların YSA ve ÇLR eğitim aşaması hata ve korelasyon karşılaştırması.	32
Çizelge 6.5 : Ekstrem Rüzgarların YSA ve ÇLR test aşaması hata ve korelasyon karşılaştırması.	32



ŞEKİL LİSTESİ

Sayfa

Şekil 4.1: YSA'ların genel yapısı.	16
Şekil 4.2: Genel bir YSA mimarisi.....	16
Şekil 5.1: rt_114 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.	23
Şekil 6.1: rt_114 nolu RT'nın eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	27
Şekil 6.2: rt_114 nolu RT'nın eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	28
Şekil 6.3: rt_114 nolu RT'nın test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	28
Şekil 6.4: rt_114 nolu RT'nın test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	29
Şekil 6.5: rt_118 nolu RT'nın eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	29
Şekil 6.6: rt_118 nolu RT'nın eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	30
Şekil 6.7: rt_118 nolu RT'nın test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	30
Şekil 6.8: rt_118 nolu RT'nın test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	31
Şekil 6.9: rt_114 nolu RT'nın eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	33
Şekil 6.10: rt_114 nolu RT'nın eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	33
Şekil 6.11: rt_114 nolu RT'nın test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	34
Şekil 6.12: rt_114 nolu RT'nın test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	34
Şekil 6.13: rt_118 nolu RT'nın eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	35
Şekil 6.14: rt_118 nolu RT'nın eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	35
Şekil 6.15: rt_118 nolu RT'nın test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.	36
Şekil 6.16: rt_118 nolu RT'nın test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.	36



EKSTREM RÜZGARLARIN YAPAY SİNİR AĞLARI VE ÇOKLU LİNEER REGRESYON KULLANILARAK KISA SÜRELİ TAHMİNİ

ÖZET

Son yıllarda, küresel ısınmayla birlikte meydana gelen iklim değişikliği, günümüzde hiç de az sayılamayacak araştırmalara konu olmuştur ve olmaktadır da. Bu olay; sıcaklık, yağış ve rüzgar gibi meteorolojik değişkenlerde ekstrem olayların meydana geliş sayısını da arttırmaktadır. Bu yüzden de, rüzgar enerjisi çalışmalarında, ekstrem rüzgar olaylarından zarar görmemek amacıyla yeni araştırmalar yapılmaktadır.

Bu tez, 215M387 nolu ve “Yeni Avrupa Rüzgar Atlasında Ekstrem Rüzgarlar ve Türbülans Koşullarının Araştırılması ve Tahmin Sistemlerinin Geliştirilmesi” isimli TÜBİTAK projesi kapsamında gerçekleştirilmiştir. Bu amaçla, ülkemizin Marmara, Ege, Güneydoğu ve Akdeniz Bölgelerinde bulunan 18 farklı Rüzgar Tarlası’na (RT) ait maksimum rüzgar şiddeti verileri temin edilmiştir. Verilerin zamansal çözünürlükleri birbirinden farklı olduğu için her bir RT verisi saatlik olarak işleme alınmıştır. Buna ek olarak, RT ölçüm yüksekliklerinin birbirinden oldukça farklı olması nedeniyle de, bu seviyeler mümkün olduğunca aynı yüksekliğe (80 m – 90 m) taşınmıştır.

Çalışmada yöntem olarak, Yapay Sinir Ağları (YSA) ve Çoklu Lineer Regresyon (ÇLR) metodları kullanılmıştır. Her iki yöntemde de girdi olarak; (t-2), (t-1) ve (t) zamanlarındaki maksimum rüzgar şiddetleri alınmış ve (t+1) zamanındaki maksimum rüzgar şiddeti modellenmeye çalışılmıştır. YSA yönteminin kendisini oluşturan mimariye duyarlı olması nedeniyle de, en uygun YSA mimarisinin belirlenmesi için çalışmada bir hassasiyet analizi gerçekleştirilmiştir. 3 farklı öğrenme algoritması, 2 farklı aktivasyon fonksiyonu, 4 farklı gizli katman ve her bir gizli katmanda 4 farklı sinir hücresi kullanılması nedeniyle, her RT için toplamda $3 \times 2 \times 4 \times 4 = 96$ farklı YSA mimarisi oluşturularak, her RT için en iyi YSA mimarileri belirlenmiştir. Daha sonra ise, hem maksimum rüzgar şiddetleri için hem de ekstrem rüzgar şiddeti olarak belirlenen 20 m/sn üzerindeki rüzgar şiddetleri için analiz ve değerlendirilmelerde bulunularak, elde edilen YSA sonuçları ÇLR sonuçlarıyla karşılaştırılmıştır.

Kullanım kolaylığı açısından ÇLR, YSA’dan daha pratiktir. Çünkü ÇLR bir denklemden oluşmaktadır. Buna karşın YSA yapısı açısından çok karmaşıktır. Farklı mimariler üzerinden YSA’nın geliştirilebilmesi imkanı olması da YSA’nın avantajıdır. Burada elde edilen YSA ve ÇLR sonuçları genel olarak birbirine yakın olarak elde edilmiştir.



SHORT TERM PREDICTION OF EXTREME WINDS USING ARTIFICIAL NEURAL NETWORK AND MULTIPLE LINEER REGRESSION

SUMMARY

In recent years, the climate change has emerged with global warming and which has become to subject lots of investigation like today. This situation also triggers the number of occurrence of extreme events in meteorological variables such as temperature, precipitation and wind. So new researchs have being conducted in the field of study wind power for pretend damages of extreme winds.

This thesis has been prepared at the extend of TUBITAK project with the title of Investigation of Extreme Winds and Turbulence Conditions in the New European Wind Atlas and Development of Prediction Systems'' numbered 215M387. For this purpose, maximum wind data have been obtained from Marmara, Aegean, Southeast and Mediterranean Regions by using eighteen wind farms (WF) of Turkey. The locations of these stations are not clearly stated for privacy reasons. Each of the WF data is processed hourly, because the temporal resolution of the data is different. In addition to mentioned thigs due to WF measurement scale height are differ from each other. Elevations have been transfared same level as it possible. The power law method was not used when carrying wind speeds for requested level. This level was determined as 80 m. Therefore, the wind speed of the stations without 80 m measurement data was transferred by establishing a curvilinear relationship between different measurement levels. However, since the measurement levels are different, 80 m data could not be obtained for each station. For example, in a station with measurements of 30 m and 50 m, the wind speeds were first raised to 70 m by means of the curvilinear relationship between these two levels. Then, considering therelationship between 50 m and 70 m wind speeds, 90 m wind speed data was obtained.

There are lots of ways to predict wind speed and power in literary. These consist of numerical weather prediction models and statistical approaches. Examples of statistical approaches are Multiple Linear Regression (MLR), Autoregressive Model (AR), Moving Average (MA), Autoregressive Moving Average (ARMA), Integrated Autoregressive Moving Average (ARIMA), Artificial Neural Networks (ANN), Fuzzy Logic (FL), Genetic Algorithms (GA) and Adaptive Network Based Fuzzy Inference System (ANFIS). In this thesis being used methods are Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR).

ANN is one of the techniques of artificial intelligences. It has been developed by imitating the stimulation and information received by the sense organs through the neurons in the computer environment. Today it is one of the technics of being used almost all computational science fields. ANN can also be thought as a black box which processes given inputs and generates outputs. This system process data in parallel and it also learn correlation coefficient among neurons with the principle of

minimalize and renew mistake. In other word ANN uses the method of trial and error.

In the real world, a dependent variable is expressed by several independent variables. The method used to explain the relationship between two or more independent variables affecting a variable with a linear model and to determine the effects of these independent variables is called multiple linear regression analysis.

The formula of Multiple Linear Regression:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_mX_m + \varepsilon$$

Where, Y is the dependent variable that is tried to be estimated, $X_1, X_2, \dots, X_m$ are independent variables, a is the regression constant, $b_1, b_2, b_3, \dots, b_m$ are the regression coefficients and finally ε is the error term, a is the regression constant and which indicates the value of the dependent variable when all the arguments are zero. b values are also can be call as partial regression or partial slope coefficients.

As an input in both methods; Maximum wind speeds at time (t-2), (t-1) and t have been taken and maximum wind speed at time (t+1) has been tried to be modeled. Because the ANN method is sensitive to the architecture that makes it, a sensitivity analysis has been carried out to determine the most appropriate ANN architecture. Therefore different learning algorithms like Levenberg-Marquardt backpropagation, Conjugate gradient backpropagation with Powell-Beale restarts and Conjugate gradient backpropagation with Fletcher-Reeves updates, 2 different activation functions named logsig and tansig, 4 different hidden layers and 4 different neurons in each hidden layer have been used. Finally, $3 \times 2 \times 4 \times 4 = 96$ different ANN architectures are created for each WF and the best ANN architectures are determined for each WF. Then, the results of the analyzes of the wind speeds over 20 m/s, which are determined as both the maximum wind speeds and the extreme wind speeds, were compared with the results of the MLRs.

The aim of this thesis is to develop a prediction model based on Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR) by using maximum wind data from eighteen different Wind Farms (WF) located in the Marmara, Aegean, Southeast and Mediterranean regions of Turkey. With the help of these models to be developed, the loss of energy and damage caused by extreme wind is expected to be reduced.

The results and suggestions obtained in the thesis can be listed as follows:

- 1) When ANN architectures of maximum wind speeds are examined; the architectures 1_2_3_4; (trainlm, tansig, 3, 9), 1_1_3_4; (trainlm, logsig, 3,9), 1_1_4_4; (trainlm, logsig, 4,9) and 1_2_2_4; (trainlm, tansig, 2, 9) were obtained as 6, 5, 6 and 1 respectively. As it can be understood from this, all architectures have the trainlm learning algorithm and 9 number of neurons in common.
- 2) As in the case with maximum winds, there is not a single best ANN architecture for all WF's in extreme winds. Tha architectures named 3_1_1_2; (traincgb, logsig, 1, 4), 1_1_1_2; (trainlm, logsig, 1, 4), 1_2_1_2; (trainlm, tansig, 1, 4) and 2_1_1_2; (traincgb, logsig, 1, 4) and 4, 3, 2, 2 of these architectures were obtained, respectively. Their common features are 1 hidden layer and 4 neurons.
- 3) In the prediction of both winds (maximum, extreme), when the analyzing the results of ANN and MLR, it was seen that the error of the train was smaller than the test as expected.

4) In terms of ease of use, MLR is more practical than ANN, because MLR has an equation. However, ANN is very complicated in terms of its structure. The advantage of ANN is that it has the possibility of developing ANN through different architectures. Generally, the ANN and MLR results obtained from here are close to each other.

5) In addition, suggesting for later studies is that testing different ANN architectures, using longer datasets, development of forecasts for longer periods and inclusion of meteorological variables produced by digital weather prediction models into the system.





1. GİRİŞ

Gerekli enerjisini güneşten alan bir ısı makinası olarak nitelenebilecek atmosferde; ısı potansiyel farklara sahip olan hava kütleleri, daha soğuk ve yüksek basınç alanı olan bir noktadan, daha sıcak ve alçak basınç alanına hareket ederler. Isı enerjisinin kinetik enerjiye dönüştüğü bu doğa olayındaki hava kütlesi hareketine, rüzgar adı verilir [1]. Başka bir ifadeyle, yeryüzüne ulaşan güneş ışınmı, yüzeyler tarafından farklı yansıtılarak sıcaklık farklılıklarına sebep olmaktadır. Dünyanın bir bölümünde güneş tarafından ısıtılan havanın yoğunluğu düşer ve hava yükselmeye başlar, bu bölgelerde alçak basınç alanı oluşur. Hava kütleleri yüksek basınçtan alçak basınca doğru hareket ederek rüzgar adı verilen meteorolojik hadiseyi meydana getirir.

Son zamanlarda, küresel ısınmadan dolayı anormal iklim ve deniz seviyesinin yükselmesi gibi konular öncelik kazanmıştır. Bunun sonucunda da, yenilenebilir enerjinin gelişimi üzerine, kayda değer sayıda çalışmalar küresel olarak yürütülmeye başlanmıştır [2]. Türkiye’de de yankı bulan bu konu üzerine, ekstrem rüzgar potansiyelinin araştırılması ve tahmin sistemlerinin geliştirilmesi amacıyla çalışmalar başlatılmıştır.

Dünyadaki hızlı sanayileşme ve kentleşme, enerjiye olan ihtiyacı giderek artırmaktadır. Ülkemizin de gelişmekte olan bir ülke olması sebebiyle, enerjiye olan ihtiyacımız ciddi boyutlara ulaşmaktadır. Ancak, fosil enerji rezervlerinin Sanayi Devrimi ile birlikte hızla tüketilmesi, bu kaynakları yok olmakla karşı karşıya getirmiştir. Bu sebeple, konvansiyonel enerji kaynakları açısından dışa bağlı olan ülkemizin, alternatif enerji kaynaklarına yönelmesi ciddi bir önem arz etmektedir. Bu kapsamda yapılan çalışmalarla aldığı girdiyi tüketmeyen sistemler tasarlanmıştır. Bunlara örnek olarak; güneş enerjisi, rüzgar enerjisi, hidroenerji, jeotermal enerji ve dalga enerjisi verilebilir. Ülkemizin rüzgar enerjisi potansiyeli birçok çalışmada değerlendirilmiş ve olumlu sonuçlar alınmıştır [3 - 7]. Böylelikle sadece ülkemizde değil, dünyanın her yerinde ulaşılabilir olan rüzgar gücüyle çevreye zarar vermeden enerji ihtiyacı karşılanabilir.

Rüzgar gücündeki artan pazar nüfusuna bağlı olarak, ekstrem rüzgarlar yöneticiler ve iletim sistemi operatörleri için endişe oluşturmaktadır. Enerji üretiminin planlanabilmesi amacıyla, meydana gelecek olayların ısrarlılığı önem arz etmektedir. Yakın gelecekte düşük ısrarlılıklı olaylar yakıt rezervi planlamasını etkileyecektir; uzun vadeli ısrarlılıklar da ise, bu olayların sıklığı ve şiddeti toplu enerji depolama gibi yenilikçi teknolojilerin potansiyelini değerlendirmek için gerekli olacaktır [8]. Buna ek olarak, ekstrem rüzgar hızı hesaplamaları, rüzgar türbinlerinin güvenliği nedeniyle de oldukça önem arz etmektedir. Ekstrem rüzgarlar, türbinlerin üzerinde ilave mekanik yük ortaya çıkarmaktadır ve zaman zaman türbinlerinin bozulmasına sebep olmaktadır [9].

Ekstrem rüzgar çalışmalarındaki diğer bir problem de veridir [10]. Ekstrem analizlerinde verinin güvenilir olması gerekir. Özellikle bu gerçek, Akdeniz’de ki gibi karmaşık yüzey şekillerine sahip yerlerde daha da önem arz etmektedir [11]. Bölgesel analizlerin daha doğru bir şekilde yapılabilmesi için uzun yıllara ait verilerin elde edilmesi gerekmektedir. Böylelikle, çalışılan sahada yıllara göre rüzgar trendinin nasıl bir değişim gösterdiği incelenebilir ve gelecek yıllara yönelik yüzeysel olarak bir tahmin yapma imkanına ulaşılabilir. Ekstrem rüzgar hızlarının mikrometeorolojik olarak da homojen olması gerekmektedir. Diğer bir deyişle, verilerin kayıt edildiği zaman aralığında arazi pürüzlülüğü sabit kalmalıdır, ölçümlerin sabit bir yükseklik seviyesinde yapılması gerekmektedir ve aynı zaman aralığında aritmetik ortalamalar alınmalıdır [12].

Ekstremlerin kıstas tanımı özgün olmaktan çok uzaktır. Ekstrem rüzgar hızlarının doğru bir şekilde elde edilmesi, rüzgar hızı verilerinden ekstrem değerlerin nasıl elde edildiğine bağlıdır. Bu değerleri elde etmenin bir yolu belirli bir eşik değerin üzerindeki rüzgar hızlarını kullanmaktır. Eşik değeri için oluşturulan kriterler de subjektiftir. Örneğin istasyonların tümü için sabit ve yüksek bir eşik değeri seçmek doğru değildir. Sabit bir eşik değeri hızı spesifik istasyonlarda ekstrem analizi yapılmasına yardımcı olur. Ancak bu değerin farklı coğrafik özelliklere sahip olmalarına rağmen, tüm istasyonlar için aynı değerde sabit kalması, o bölge için oldukça sıradan olan bir olayın ekstrem olarak değerlendirilmesine sebep olabilir. Eşik değerin belirlenmesi rüzgar çözümleyicilerine ve karar vericilere bağlıdır, bu konuyla ilgili sabit bir değeri yoktur [9, 11].

1.1 Tezin Amacı

Bu tezin amacı, ülkemizin Marmara, Ege, Güneydoğu ve Akdeniz Bölgelerinde bulunan 18 farklı Rüzgar Tarlası'na (RT) ait maksimum rüzgar verileri kullanılarak, Yapay Sinir Ağları (YSA) ve Çoklu lineer regresyon (ÇLR) temelli birer tahmin modeli geliştirmektir. Geliştirilecek bu modeller yardımıyla da ekstrem rüzgarların verebileceği zarar ve enerji kayıplarının azaltılması öngörülmektedir.





2. RÜZGAR ŞİDDETİ VE ENERJİSİ TAHMİN SİSTEMLERİ

Literatürde, rüzgar şiddeti ve enerjisi tahmini için bir çok yöntem kullanılmaktadır. Bunlar sayısal hava tahmin modelleri ve istatistiksel yaklaşımlardır. İstatistiksel yaklaşımlara örnek olarak Çoklu Lineer Regresyon (ÇLR), Otoregresif Model (AR), Hareketli Ortalama (MA), Otoregresif Hareketli Ortalama (ARMA), Bütünleşik Otoregresif Hareketli Ortalama (ARIMA), Yapay Sinir Ağları (YSA), Bulanık Mantık (BM), Genetik Algoritmalar (GA) ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) verilebilir.

2.1 Sayısal Hava Tahmi Modelleri

Sayısal hava tahminleri (SHT), sayısal prosedürler kullanılarak atmosferdeki hemen hemen tüm dinamik ve fiziksel süreçleri tanımlayan kapsamlı bir matematiksel denklemler dizisinin zaman-entegrasyonu yoluyla bir tahmin üretimi olarak tanımlanır [13]. SHT modelleri, meteoroloji uzmanları tarafından onlarca yıl süren araştırmalar sonucunda geliştirilmiştir. Bu modeller, bir dizi iklimsel ve fiziksel giriş parametresi aracılığıyla rüzgardaki değişiklikleri tahmin edebilen matematiksel akışkanlar mekaniği modellerine dayanmaktadır [14].

Atmosferdeki hareketle ilgili temel denklemler momentumun, enerjinin, kütleinin ve suyun korunumu denklemidir. Bu denklemler, atmosferin gerçek fiziksel süreçlerinin basitleştirilmiş modelleridir. Doğrusal olmamaları nedeniyle, analitik çözümlerin bulunması hesaplama açısından zordur ve bu nedenle sayısal bir yaklaşım uygulanır. SHT modelleri, belirli bir alanda sayısal olarak koruma denklemlerini çözerek çalışır. Aynı zamanda, daha doğru sonuçlara ulaşabilmek için topoğrafyayı temsil etmek amacıyla SHT modelinde dijital yükseklik modelleri kullanılmaktadır. Ayrıca modeller yüksek mekânsal çözünürlükle çalıştığında daha doğru sonuçlar üretir, fakat hesaplama işlemleri son derece fazladır [15 - 17].

Meteoroloji istasyonlarından gelen ölçümler, rüzgar değerlendirmesi için veri sağlamış olsa da, bu veri türleri kullanımlarını olumsuz yönde etkileyen bazı kısıtlamalara sahiptir. Bu ana kısıtlamalardan biri rüzgar ölçümlerinin pahalılığıdır.

Rüzgar direklerinde sıcaklık, basınç, nem, rüzgar hızı ve yönü gibi değişkenler kayıt altına alınır ve bu yüzden bir çok sensör aynı anda satın alınmalıdır. Yanı sıra bunların kurulumu, elektrik ve iletişim hatları gibi altyapı hazırlıkları gerekmektedir. Bu da rüzgar ölçümünü oldukça ücretli bir hale getirmektedir. Bir diğeri ise ölçümlerin belirli bir yükseklikte yapılmasıdır. Rüzgar direklerinde ölçümler 10 metre ve üzeri için yapılmaktadır. Daha yüksek seviyelerdeki rüzgar değerlerini elde etmek amacıyla değişik ekstrapolasyonlar yapılmaktadır. Bu durum aynı zamanda gerçek ölçüm değerleri olmadığı için rüzgar enerjisi hesaplamalarında ciddi hatalara sebep olmaktadır [15]. Bu nedenle, SHT verilerine dayanan rüzgar değerlendirme çalışmalarının sayısının artması ve yaygınlaşması şaşırtıcı olmamaktadır. Jimenez ve diğeri Almanya’da ki deniz aşırı rüzgar kaynaklarının incelenmesi amacıyla orta ölçekli MM5 tahmin modelini kullanmışlardır [18]. Lazic ve diğeri İsveç’te bulunan Gotland adasında yaptıkları çalışmada ETA SHT modelini kullanmışlar ve rüzgar tahminleri için oldukça kullanışlı olduğu sonucuna ulaşmışlardır [19]. Zhao ve diğeri kısa süreli rüzgar tahmini yapmak amacıyla WRF modelini kullanmışlardır [20]. Carvalho ve diğeri potansiyeli yüksek ve karmaşık bir arazide WRF modelinin performansını farklı sayısal ve fiziksel süreçler altında değerlendirmiştir [21]. Landberg elektrik şebekesine bağlı rüzgar çiftliklerinden üretilen gücün tahmini için bir çalışma yapmıştır. Bu çalışmada HIRLAM modelinden elde edilen tahminler kullanılmıştır [22]. Ramirez-Rosado ve diğeri kısa vadeli rüzgar tahmini yapmak amacıyla iki farklı araştırma grubu tarafından geliştirilen istatistiksel sistemleri karşılaştırmışlardır. Bu amaçla sistemlere MM5 modelinden elde edilen tahminler girdi değişkenleri olarak sunulmuştur [23].

Günümüzde kullanılan SHT modelleri Sınırlı Alan Modeli (SAM) ve global model olarak iki grupta toplanmaktadır ve bu gruplara ait farklı ürünler geliştirilmiştir [24].

2.1.1 Global modeller

Yatay çözünürlük, spektral ya da grid olarak çözümlenir, ayrıca basit hidrostatik eşitlik kullanılmaktadır. Diğer bir deyişle havanın ağırlığıyla düşey basınç gradyan kuvveti arasında denge olduğu varsayılır. Düşey ivme hesaplama esnasında göz ardı edilir. Dünyada kullanılan global modeller ve bu modelleri geliştiren ülkelere örnek olarak IFS (ECMWF), UM (İngiltere), GME (Almanya), ARPEGE (Fransa), AVN/MRF (ABD), GEM (Kanada), JMA (Japonya) verilebilir [25].

2.1.2 SAM (Sınırlı alan modeli)

SAM hava tahmini gibi bir çok araştırma konusunda operasyonel olarak koşturulmaktadır. Teknolojide meydana gelen gelişmeler bu gruptaki modelleri amatör kullanıcılar için daha ulaşılabilir bir hale getirmiştir. SAM bölgesel hava kalitesi, tehlikeli yol koşullarının tahmini, rüzgar tahminleri, askeri operasyonlar için hava tahmini, radyoaktif maddelerin yayılım takibi, küçük yüzölçümlü ülkelerin kullanım ihtiyaçlarının karşılanması amacıyla kullanılmaktadır. Sınırlı alan modellerinde yatay çözünürlük dalga sayısı ile değil grid noktaları arasındaki mesafe ile orantılıdır. Yani sınırlı alan modellerinde grid sayısı artınca çözünürlük artmaktadır. Sınırlı alan modellerinin bir kısmında hidrostatik denge kabul edilirken bir kısmında ise kabul edilmemektedir. Dünyada kullanılan belli başlı sınırlı alan modelleri ve bu modelleri geliştiren ülkelere örnek olarak ALADIN (Fransa, Macaristan, Avusturya, Belçika, Çek Cumhuriyeti, Slovenya, Romanya, Fas, Tunus, Slovakya, Cezayir, Portekiz, Bulgaristan, Hırvatistan, Polonya, Türkiye), Eta (ABD), LM (Almanya ve Cosmo Konsorsiyumu; HIRLAM (İrlanda, Danimarka, İspanya, Hollanda, İzlanda, İspanya, İsveç, Letonya, Litvanya, Finlandiya, Estonya), MM5 ve WRF (ABD) verilebilir [25].

2.2 İstatistiksel Yaklaşımlar

Mohandes, Rehman ve Rahman Suudi Arabistan'da ANFIS yöntemiyle rüzgar şiddeti analizi yapmışlardır. 10, 20, 30 ve 40 metredeki rüzgar şiddeti bilgileri kullanılarak 100 metredeki değerler elde edilmiştir. Bunun için öncelikle 10, 20 ve 30 metrede ki değerler kullanılarak 40 metre değerleri elde edilmiş ve ortalama mutlak yüzde hatası (OMYH) hesaplanarak hata payının %3 olduğu tespit edilmiştir. Böylelikle uygulanan yöntemin güvenilirliği test edilmiş ve bölgeye ait düşey rüzgar hızları elde edilmiştir [26].

Xingpei, Yibing ve Weidong 2009 yılında Çin'de yapay sinir ağı kullanarak kısa süreli rüzgar tahmini yapmışlardır. Rüzgar tahminlerinde çok sık kullanılan geri yayımlı sinir ağına ek olarak momentum geri yayılım ve genetik algoritmali geri yayılım ile tahminlerin doğruluğu test edilmiştir. Standart geri yayılım algoritması kullanıldığında tahmin hatasının arttığı ve eğitim süreci 2000 iterasyonda belirlenen hedefe yakınsamamıştır. Buna karşılık, momentum geri yayılım 578. adımda, genetik algoritmali geri yayılım ise 467. adımda hedefe ulaşmıştır [27].

2010 yılında Zhao, Xia ve Dai destek vektör regresyonu ve YSA kullanarak rüzgar şiddeti tahmininde bulunmuştur. Böylelikle her iki yöntemin de tahminler için elverişli olduğuna ulaşmışlardır. Ancak destek vektör regresyonunun geri beslemeli yapay sinir ağına göre daha kullanışlı olduğu tespit edilmiştir [28].

Tarade ve Katti 2011 yılında Hindistan'da kısa süreli rüzgar şiddeti tahmin yöntemleri üzerine bir çalışma yapmışlardır. Bu çalışmada bütünleşik otoregresif hareketli ortalama (ARIMA), yapay sinir ağı, polinom eğri uydurma modeli karşılaştırma yapmak amacıyla kullanılmıştır. Hata oranları ortalama karesel hata (OKH) ile hesaplanmış ve ARIMA yönteminin en az hatayla tahmin yaptığı görülmüştür [29].

Bir başka çalışmada ise, 2014 yılında rüzgar gücü tahmini yapmak için gauss sürecini ve sayısal hava tahmin yöntemini bir arada kullanılarak 1 gün sonrası için tahmin yapılmıştır. Oluşturulan bu yöntem ile çok katmanlı YSA modelinin sonuçları karşılaştırılmış ve elde edilen yeni yöntemin daha iyi sonuç verdiği görülmüştür [30].

Kusiak ve Zhang, 2010 yılında kısa süreli rüzgar tahminin için çalışmalar yapmışlardır. Bu kapsamda 10 saniye sonrasından başlayarak 60 saniye zaman aralıklarında tahminler yapıp doğruluklarını analiz etmişlerdir. Üstel düzeltme, yapay sinir ağları, destek vektör makinaları gibi yöntemler kullanılmıştır. Yapılan hesaplamaların sonucunda ele alınan zaman aralığı arttıkça tahmin edilen rüzgar şiddetlerindeki hata miktarının da arttığı gözlemlenmiştir. Ayrıca tahmin yöntemlerinden yapay sinir ağlarının diğer yöntemlere göre daha iyi sonuç verdiği görülmüştür. Bu yöntem ile 1 dakika sonraki rüzgar şiddetinin tutarlılığı %90 olarak hesaplanmıştır [31].

1998 yılında Mohandes, Rehman ve Halawani Suudi Arabistan'da Kızıldeniz'in yakınlarında bulunan Cidde kentinde rüzgar şiddeti tahmini yapmak amacıyla çalışmalar yapmışlardır. Çalışma kapsamında 3 katmanlı ileri beslemeli YSA modeli kullanılmıştır. Sinir ağını eğitmek için geri yayılım algoritması kullanılmaktadır. Sonuçta aylık ve günlük yapılan rüzgar şiddeti tahminlerinde YSA metodunun otoregresif modellerden daha iyi sonuç verdiği görülmüştür [32].

Bilgili, Şahin ve Yaşar 2007 yılında Türkiye'de yapay sinir ağlarını kullanarak rüzgar şiddeti tahmini üzerine çalışmalarda bulunmuşlardır. Akdeniz bölgesinde bulunan 8 farklı ölçüm istasyonu referans seçilerek, belirlenen bir istasyon için

rüzgar şiddeti tahmini buraya en yakın istasyon aracılığıyla tahmin edilmeye çalışılmıştır. Eğitim algoritması olarak esnek yayılım kullanılmıştır. YSA metoduyla elde edilen değerler gerçek verilerle karşılaştırılmış ve her bir istasyon için OMYH hesaplamaları yapılmıştır. Sonuçta en çok hata %14,13 ile Antakya'da en az hata ise %4,49 ile Mersin'de elde edilmiştir. Bu sonuçlar YSA modellerinin rüzgar şiddeti tahmininde başarılı sonuçlar ürettiğini göstermiştir [33].

Monfared, Rastegar ve Kojabadi 2009 yılında İran'ın kuzeyinde bulunan Rüstemabad şehrinde 2002 ve 2005 yılları arasında elde edilen verilerle rüzgar üzerine çalışmalar yapmışlardır. Bu çalışmalarda YSA ve bulanık mantık yöntemleri kullanılmıştır. Sonuçlar her iki yönteminde daha basit bir yapıya sahip olmakla kalmayıp, aynı zamanda doğru rüzgar tahmini yapmayı sağladığını göstermiştir [34].

Mohandes, Halawani, Rehman ve Hussain 2004 yılında Suudi Arabistan'da rüzgarı tahmin edebilmek için çalışmalar yapmıştır. Çalışma kapsamında destek vektör makinalarından ve çok katmanlı YSA'dan faydalanmışlardır. Bölgeden elde edilen günlük ortalama rüzgar şiddeti verileri her iki modelinde eğitim ve test aşamasında kullanılmıştır. Yöntemlerin performansı karekök ortalama hata (KOH) hesaplamalarından elde edilen sonuçlara göre değerlendirilmiş ve destek vektör makinalarının çok katmanlı sinir ağlarına göre daha başarılı olduğu görülmüştür [35].

Mabel ve Fernandez rüzgar hızı ve enerjisini tahmin etmek amacıyla araştırmalar yapmış bu amaçla YSA kullanmışlardır. Araştırmalar için Hindistan'ın Tamil Nadu kentinden 2002 ve 2005 yıllarına ait verilerle çalışılmıştır. Çalışmada ileri beslemeli geri yayımlı YSA algoritması kullanılmıştır. Araştırmacılar hangi YSA mimarisinin daha iyi sonuç üretebileceği üzerine testler yapmıştır. Bu amaçla gizli katman sayısı ve katmanlarda bulunacak nöron sayıları deneme yanılma yöntemiyle belirlenmeye çalışılmıştır. Testler sonucunda 1 gizli katmanlı ve 4 nöronlu YSA mimarisi uygun bulunmuştur. Böylelikle giriş katmanında 3, gizli katmanda 4, çıkış katmanında 1 nöronlu mimari yapı oluşturulmuştur. Gizli katmanda logaritmik sigmoid çıkış katmanında ise lineer aktivasyon fonksiyonu kullanılmıştır. Bu yöntemle yapılan rüzgar enerjisi tahminlerinin gerçek değerlerle yakından benzerlik gösterdiği görülmüştür [36].

Şenol ve Musayev çeşitli rüzgar türbinleri ile YSA modeli oluşturarak rüzgar enerjisinden elektrik üretimi tahmini yapmışlardır. Çalışma için en uygun YSA

modelinin belirlenmesi amacıyla model parametreleri bir çok kez deęiştirilerek en az hata ile tahmin yapan model belirlenmiştir. Modelde ileri beslemeli geri yayılım algoritması kullanılmıştır. Günlük rüzgar hızları giriş verisi, 6 türbine ait çıkış güçleri çıktı verisi olarak seçilmiş ve deneme yanılma yöntemiyle gizli katmandaki nöron sayısı 8 olarak belirlenmiştir. Yapılan çalışmalar sonucunda rüzgar enerjisi sektöründeki uygulamacılar ve karar vericilerin geleceęe yönelik planlamalarında YSA'yı güvenli bir şekilde kullanabileceęi görülmüştür [37].



3. VERİ

Çalışmada, Türkiye'nin farklı illerinde bulunan rüzgar tarlalarından (RT) elde edilen rüzgâr verileri kullanılmıştır (Çizelge 3.1). Verilerin kayıt aralığı istasyondan istasyona çeşitlilik göstermektedir. Genel bir değerlendirme yapacak olursak, veriler 2005 ile 2016 aralığını kapsamaktadır. Ölçümlerin alındığı yükseklikler de birbirinden oldukça farklıdır. 2000 ve öncesinde 10, 20 ve 30 metre yükseklikte kayıtlar alınmışken, daha sonraki yıllarda 60 metreye kadar ölçüm yüksekliği çıkmış ve son yıllardaysa 80 metrelere ulaşmıştır. Bunlara ek olarak verilerin sabit bir zamansal çözünürlüğü de bulunmamaktadır. Verilerin bir kısmı 10 dakikalık ölçüm aralığına sahipken diğer bir kısmı ise 1 saatlik ölçüm aralığına sahiptir.

Veri setlerinin bir kısmının içinde tarih, zaman, farklı yükseklikte rüzgâr şiddeti ve rüzgâr yön bilgisi bulunurken, diğer veri setlerinde tarih, saat, farklı yüksekliklerde rüzgâr şiddeti ve yön bilgisi, basınç, sıcaklık, yağış, nem gibi değişkenler bulunmaktadır. Verilerin ölçüm yükseklikleri farklı seviyelerde olduğu için bu ölçüm yükseklikleri olabildiğince aynı seviyelere taşınmaya çalışılmıştır. Bu amaçla 80 metre ölçümleri göz önünde tutularak çalışılmıştır. Bu seviyede ölçümü olmayan istasyonlarda ise rüzgâr şiddetleri bu seviyeye taşınmıştır. Her istasyonda bunu yapmak mümkün olmadığı için bazı istasyonlar 90 m ve 82 m gibi ölçüm seviyelerine sahiptir.

80 m ölçüm verisi bulunmayan istasyonların rüzgar şiddetleri farklı ölçüm seviyeleri arasında eğrisel bir ilişki kurularak taşınmıştır. Veri setlerinde bulunan farklı seviyelerdeki ölçümler arasından en yüksek iki seviyedeki değerler ile rüzgar şiddetleri bir sonraki seviyeye taşınmıştır. Örneğin 30 m ve 50 m ölçümü bulunan bir istasyonda bu iki seviye arasında elde edilen eğrisel ilişki aracılığıyla rüzgar şiddetleri öncelikle 70 m' ye yükseltilmiştir. Ardından 50 m ve 70 m rüzgar şiddetleri göz önünde bulundurularak buradan elde edilen ilişki ile 90 m seviyesine rüzgar şiddetleri taşınmıştır.

Çizelge 3.1 : Çalışmada kullanılan RT'ler.

RT kodu	Bölge	Yükseklik (m)	Veri aralığı
rt_101	Adıyaman	82	24.03.2014-15.03.2015
rt_102	Aydın	80	26.06.2012-14.09.2015
rt_103	Aydın	80	21.11.2013-20.11.2014
rt_104	Balıkesir	90	19.03.2014-06.03.2015
rt_105	Balıkesir	90	30.03.2006-19.10.2006
rt_106	Balıkesir	90	17.03.2014-05.04.2015
rt_107	Çanakkale	90	14.11.2005-18.10.2006
rt_108	Çanakkale	90	17.03.2014-04.04.2015
rt_109	Çanakkale	80	12.02.2013-12.01.2014
rt_110	Çanakkale	90	21.03.2014-10.04.2016
rt_111	Çanakkale	90	21.03.2014-24.08.2015
rt_112	Çanakkale	90	27.03.2014-04.04.2015
rt_113	Gaziantep	82	27.03.2014-12.03.2015
rt_114	İzmir	90	05.02.2014-24.03.2015
rt_115	İzmir	80	20.07.2014-20.12.2015
rt_116	Muğla	82	20.11.2013-19.11.2014
rt_117	Tekirdağ	90	11.04.2014-05.04.2015
rt_118	Tekirdağ	90	19.03.2014-16.04.2015

Çizelge 3.2’de tezde kullanılan RT’lerde ölçülen maksimum rüzgar şiddeti verilerinin 1 saatlik zaman çözünürlüğünde 4 m/sn aralıklarla olan esme sayıları görülmektedir. Bu çizelgeye göre ekstrem olarak değerlendirilen 20 m/sn ve üzeri rüzgar şiddetleri tüm verilerin yaklaşık %15’ini oluşturmaktadır.

Çizelge 3.2 : RT’lerde ölçülen maksimum rüzgar şiddetlerinin esme aralıklarındaki sayıları.

RT kodu	Rüzgâr Şiddeti Aralıkları											Toplam
	V<4	4<V<8	8<V<12	12<V<16	16<V<20	20<V<24	24<V<28	28<V<32	32<V<36	36<V<40	V>40	
rt_101	1639	2657	2189	1173	475	142	44	8	3	2	0	8332
rt_102	2353	8143	6979	2363	655	216	101	22	5	4	76	20917
rt_103	1063	3500	3058	864	208	36	7	0	0	0	0	8736
rt_104	338	2222	2749	1560	459	114	30	11	0	0	0	7483
rt_105	50	1291	1152	857	687	458	259	98	14	0	0	4866
rt_106	843	3194	3117	1447	418	106	47	22	6	4	0	9204
rt_107	503	2687	2241	1336	802	378	98	45	22	0	1	8113
rt_108	551	2221	2390	2052	1227	516	156	48	29	12	3	9205
rt_109	991	3154	2479	1323	524	151	34	8	0	0	0	8664
rt_110	1765	6426	5067	2965	932	319	162	60	26	7	1	17730
rt_111	546	3751	4964	2240	712	200	63	8	0	0	0	12484
rt_112	964	1909	2483	2036	916	448	135	32	22	11	0	8956
rt_113	2147	2282	1217	1050	866	405	43	3	0	0	0	8013
rt_114	813	3500	2137	963	426	120	53	18	1	0	0	8031
rt_115	703	1445	1511	1004	572	260	74	7	0	0	0	5576
rt_116	1968	3090	2031	1004	296	56	9	1	0	0	0	8455
rt_117	499	3043	3252	1375	333	84	23	21	6	4	1	8641
rt_118	526	2662	2590	1274	454	146	73	28	12	0	0	7765
Toplam	18262	57177	51606	26886	10962	4155	1411	440	146	44	82	171171




4. KULLANILAN YÖNTEM VE İSTATİSTİK

Bu tez çalışmasında, yöntem olarak Yapay Sinir Ağları (YSA) ve Çoklu Lineer Regresyon (ÇLR) seçilmiştir. Ayrıca, hata istatistikleri için Ortalama Kare Hata (OKH), Ortalama Mutlak Hata (OMH) ve Karekök Ortalama Hata (KOH) kullanılırken, gözlem değerleri ile model tahmin değerleri arasındaki ilişki için de korelasyon göz önünde tutulmuştur.


4.1 Yapay Sinir Ağları (YSA)

YSA, yapay zeka tekniklerinden biridir. Duyu organları yardımıyla çevreden alınan uyarım ve bilgilerin, sinir hücreleri vasıtasıyla beyne aktarılması olayının bilgisayar ortamında taklit edilmesiyle geliştirilmiştir. Bugün neredeyse tüm hesaplamalı bilim alanlarında kullanılan yöntemler arasında yer almaktadır. YSA'lar, verilen girdileri işleyen ve girdiler karşılığında çıktılar üretebilen bir kara kutu olarak da düşünülebilir. Bu sistem, bilgileri paralel olarak işler ve sinirler arasında yer alan bağlantı katsayılarının hatanın en küçüklenmesiyle yenilenmesi prensibiyle öğrenir. Bir başka ifadeyle, YSA'da öğrenme, deneme yanılma şeklindedir.

Şekil 4.1'den görüleceği üzere bir YSA modeli; giriş tabakası, gizli tabaka ve çıkış tabakası katmanlarından oluşmaktadır. Her bir katman sinir hücrelerine sahiptir ve çıktı katmanı hariç diğer katmanlardaki sinir hücreleri birbirleriyle ağırlık katsayıları vasıtasıyla bağlı bulunmaktadır. Girdi tabakasında girdi ve çıktı tabakasında da çıktı sayısı kadar sinir hücresi bulunur. Ancak gizli tabakadaki sinir hücresi sayısı tamamen girdiye bağlı bulunmaktadır. n girdi sayısı olmak üzere, gizli tabakada genelde $(n+1)/2$ veya $2n+1$ adet sinir hücresi kullanılabilir. Gerektiği takdirde problemin özelliğine göre daha farklı sayılarda sinir hücreleri de kullanılabilir. Yalnız burada dikkat edilmesi gereken bir nokta bulunmaktadır. Gereğinden az sinir hücresinin kullanılması sistemin öğrenme yeteneğini azaltacağı gibi fazla olması halinde de sistemde ezberlemeye neden olacaktır [38].



Şekil 4.1: YSA'ların genel yapısı [39].



Şekil 4.2: Genel bir YSA mimarisi [39].

4.1.1 YSA'da öğrenme

Şekil 4.2, birer adet girdi, gizli ve çıkış tabakalarından meydana gelen genel bir YSA mimarisini göstermektedir. Buradaki düz oklar bilginin ileriye doğru olan akışını ifade ederken, kesikli oklar ise sistemin sahip olduğu hatanın geriye doğru yayılımını anlatmaktadır. Şekilde F_X girdi, F_Y gizli ve F_Z de çıktı tabakasıdır. V girdi ile gizli ve W ise gizli ile çıktı tabakaları arasındaki bağlantı katsayılarını göstermektedir. Gizli tabakada yer alan Y ve çıkış tabakasında bulunan Z değerleri aşağıda verilen denklemler ile hesaplanmaktadır.

$$Y_i = f\left(\sum_{h=1}^n X_h V_{ih}\right) \quad (4.1)$$

$$Z_j = f\left(\sum_{i=1}^p Y_i W_{ji}\right) \quad (4.2)$$

Buradaki öğrenme, ileri beslemeli ve hatanın geriye yayılımı şeklindedir. İleriye olan harekette, varolan ağırlık katsayıları vasıtasıyla sinir hücrelerindeki ve nihayetinde de sistemin çıktıları elde edilir. Elde edilen bu sistem çıktıları ile gerçek değerler arasındaki toplam hata hesap edilir ve bu hata değeri geriye doğru yayılarak bağlantılardaki ağırlık katsayıları yenilenir. Bu işlem ya belirli bir sayıda ya da verilen bir hata eşiğine ulaşıncaya kadar tekrarlanır ve sonunda da öğrenme tamamlanır [38]. Bu noktada hatanın geriye yayılımı sırasında ağırlık katsayılarının nasıl yenileneceğine dair aşağıdaki adımları takip etmek gerekmektedir [40].

- 1) İlk olarak YSA mimarisindeki tabaka ve her bir tabakadaki sinir hücre sayıları tespit edilmelidir.
- 2) Oluşturulan YSA mimarisinin ihtiyaç duyduğu öğrenme oranı, hata adımı, itersayon sayısı, hata kıstası, vd. sabit parametre değerleri belirlenmelidir.
3. YSA katmanları arasındaki bağlantıyı sağlayan V ve W ağırlık katsayıları atanmalı. Bu atama işlemi rastgele olabileceği gibi belirli bir şekilde de tanımlanabilir.
4. Z_{kj} çıkış değerleri hesaplanır. Burada belirtilen L ölçüm sayısını ve q da girdi sayısını ifade etmektedir ($j = 1,..q, k = 1,..L$).

5. Bu adımda ise, aşağıdaki denklem yardımıyla, gözlem değerleri ($\mathbf{b}_{kj}$) ile YSA'ya ait tahmini değerleri ($\mathbf{Z}_{kj}$) arasındaki toplam hata belirlenir.

$$H = \sum_{k=1}^L \sum_{j=1}^q (b_{kj} - z_{kj})^2 \quad (4.3)$$

5. Son olarak da, aşağıda verilen denklemler yardımıyla $\mathbf{V}$ ve $\mathbf{W}$ ağırlık katsayıları yenilenir

$$w_{ji}^{yeni} = w_{ji}^{eski} - \eta \frac{\partial H}{\partial w_{ji}} \quad (4.4)$$

$$\frac{\partial H}{\partial w_{ji}} = 2 \sum_{k=1}^L (b_{kj} - z_{kj}) (-1) f'(z_j) y_i \quad (4.5)$$

$$v_{ih}^{yeni} = v_{ih}^{eski} - \eta \frac{\partial H}{\partial v_{ih}} \quad (4.6)$$

$$\frac{\partial H}{\partial v_{ih}} = 2 \sum_{k=1}^L \sum_{j=1}^q (b_{kj} - z_{kj}) (-1) f'(z_j) w_{ji} f'(y_i) a_{kh} \quad (4.7)$$

Konu hakkındaki ayrıntılar için [38, 40-42] incelenebilir.

4.2 Regresyon Analizi

Gerçek hayatta iki değişken arasındaki ilişki birbirinin fonksiyonu şeklinde açıklamak mümkün değildir. Yani değişkenlerden biri bir değer aldığı anda diğer değişkenin de aynı değeri alacağı söylenemez. Fakat yine de değişkenler arasındaki fonksiyonel olmayan ilişkinin bulunması uygulamada önem kazanmaktadır. Elde edilen bu ilişkiye regresyon denklemi denilmektedir. Regresyon analizi istatistikte yaygın olarak kullanılan yöntemlerdendir. Bu yöntem kısaca iki değişken arasındaki ilişkiyi analiz eder. Bu ilişki zıt yönlü olduğu gibi aynı yönlü de olabilir.

4.2.1 Basit lineer regresyon

Basit regresyon modeli tek bağımsız değişken (x) ile tek bir bağımlı değişken (y) arasındaki lineer ilişkiyi inceler. Denklem:

$$y_i = \alpha + \beta x_i + \varepsilon_i \quad (4.8)$$

şeklindedir. Denkleminde bulunan α ve β regresyon katsayılarıdır. Bağımsız değişken (x), 0 olduğunda α değeri y eksenini kesmektedir. β ise bağımsız değişkenin meydana gelecek olan bir birimlik değişmeye karşılık bağımlı değişkenindeki ortalama değişiklik miktarını verir. Son olarak ε_i ise hata terimidir ve beklenen değeri 0'dır.

4.2.2 Çoklu lineer regresyon

Gerçek dünyada bir bağımlı değişken birçok bağımsız değişkenle ifade edilir. Bir değişkeni etkileyen iki ve daha fazla bağımsız değişken arasındaki ilişkiyi lineer bir modelle açıklamak ve bu bağımsız değişkenlerin etkilerini belirlemek için yararlanılan yöntem çoklu lineer regresyon analizi denilmektedir. Çoklu lineer regresyon denklemi:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_mX_m + \varepsilon \quad (4.9)$$

şeklinde tanımlanır. Burada Y tahmin edilmeye çalışılan bağımlı değişken, $X_1, X_2, \dots, X_m$ bağımsız değişkenler, a regresyon sabitini, $b_1, b_2, b_3, \dots, b_m$ regresyon katsayılarını ve son olarak ε ise hata terimini göstermektedir. a regresyon sabiti tüm bağımsız değişkenler sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir. b değerleri aynı zamanda kısmi regresyon veya kısmi eğim katsayıları olarak da adlandırılmaktadır.

Çoklu lineer regresyonda bağımsız değişken sayısı ile tahmin doğruluğu arasında bir orantı bulunmamaktadır. Bundan dolayı analizlerde bağımsız değişken sayısına doğru karar vermek tahminlerin güvenilirliği açısından önemlidir.



5. YSA HASSASİYET ANALİZ YÖNTEMİ

Uygulama öncesi en uygun YSA mimarisinin tespit edilebilmesi için bir hassasiyet analizi gerçekleştirilmiştir. Bu analizde etkili olan değişkenler, sırasıyla öğrenme algoritması, gizli tabaka sayısı, tabakalardaki sinir sayısı ve aktivasyon fonksiyonudur.

Analizde öğrenme algoritması olarak trainlm (Levenberg-Marquardt backpropagation), traincgf (Conjugate gradient backpropagation with Fletcher-Reeves updates) ve traincgb (Conjugate gradient backpropagation with Powell-Beale restarts) algoritmaları seçilmiştir. Gizli tabaka sayısı olarak ise, sırasıyla 1, 2, 3 ve 4 farklı katman uygulanmıştır. Tabakalardaki sinir sayıları, n giriş katmanındaki sinir sayısı olmak üzere, literatürde genelde kullanılan $(n+1)/2$ ve $(2n+1)/2$ sayılarını da içeren 2, 4, 7 ve 9 sinir sayıları seçilmiştir. Son olarak ise, tansig (tanjant sigmoid) ve logsig (logaritma sigmoid) aktivasyon fonksiyonları tercih edilmiştir. Buradan hareketle de toplamda 96 farklı YSA mimarisi oluşturularak, bu mimariler rt_101_a_b_c_d şeklinde kodlanmıştır. Burada rt rüzgar tarlasını ifade ederken, 101 RT kodunu göstermektedir. a öğrenme algoritmasını, b aktivasyon fonksiyonunu, c gizli tabaka sayısını ve d de her bir tabakadaki sinir sayısını anlatmaktadır.

Örneğin rt_101_a_b_c_d kodlamasının çözümlemesi şu şekildedir:

rt: Rüzgar tarlası

101: Rüzgar tarlasının numarası

a: Öğrenme algoritması

b: Aktivasyon fonksiyonu

c: Gizli tabaka sayısı

d: Her bir tabakadaki sinir sayısı


Çizelge 5.1 göz önüne alınırsa, rt_118_2_1_3_4 mimarisinin çözümlemesi;

- rt_118: 118 nolu rüzgar tarlası
- 2: traincgf öğrenme algoritması
- 1: logsig aktivasyon fonksiyonu
- 3: 3 adet gizli tabaka
- 4: 9 adet sinir sayısı olmaktadır.

Çizelge 5.1 : YSA mimari kodlaması.

YSA değişkeni	Kodu	Açıklama
Öğrenme Algoritması	1	trainlm
	2	traincgf
	3	traincgb
Aktivasyon Fonksiyonu	1	logsig
	2	tansig
Gizli Tabaka Sayısı	1	1
	2	2
	3	3
	4	4
Katmandaki Sinir Sayısı	1	2
	2	4
	3	7
	4	9

Şekil 5.1 rt_114 nolu RT'nın 96 farklı YSA mimarisinin OMH, OKH, KOH ve r değerlerini göstermektedir. Çalışmanın bu bölümünde her bir RT'nın bu hata ve korelasyon grafikleri elde edilmiş ve bunlardan elde edilen en iyi mimariler Bölüm 6'da çizelgeler halinde özetlenmiştir.



Şekil 5.1: rt_114 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.



6. BULGU VE DEĞERLENDİRMELER

6.1 Maksimum Rüzgarlar

Çizelge 6.1 çalışmada kullanılan maksimum rüzgarların belirlenen en iyi mimariye sahip YSA ile ÇLR sonuçlarının eğitim aşaması için olan hata ve korelasyon karşılaştırmalarını göstermektedir. Buradan görüldüğü üzere tüm RT'ler için tek bir en iyi YSA mimarisi yerine farklı mimariler söz konusudur. Görüldüğü üzere; 1_2_3_4; (trainlm, tansig, 3, 9), 1_1_3_4; (trainlm, logsig, 3, 9), 1_1_4_4; (trainlm, logsig, 4, 9) ve 1_2_2_4; (trainlm, tansig, 2, 9) mimarileri sırasıyla 6, 5, 6 ve 1 adet olarak elde edilmiştir. Buradan da anlaşılabileceği gibi tüm mimarilerde trainlm algoritması ve 9 adet sinir hücre sayısı ortaktır. Ayrıca tüm RT'ler için YSA ve ÇLR karşılaştırma sonuçları birbirlerine çok yakın olup, YSA sonuçları az bir miktar daha iyidir. Örneğin 101 nolu RT için bakacak olursak; YSA'ya ait OHM, OKH, KOH ve r değerleri sırasıyla 1,369; 3,558; 0,448 ve 0,917 iken, ÇLR değerleri sırasıyla 1,403; 3,863; 0,456 ve 0,909 olarak hesaplanmıştır.

Çizelge 6.1 : Maksimum rüzgarların YSA ve ÇLR eğitim aşaması hata ve korelasyon karşılaştırması.

RT	YSA EĞİTİM AŞAMASI					ÇLR EĞİTİM AŞAMASI			
	En İyi Mimari	OHM	OKH	KOH	r	OHM	OKH	KOH	r
101	rt_101_1_2_3_4	1,369	3,558	0,448	0,917	1,403	3,863	0,456	0,909
102	rt_102_1_1_3_4	1,785	22,217	0,492	0,659	2,232	27,781	0,565	0,541
103	rt_103_1_1_3_4	1,136	2,52	0,423	0,9	1,173	2,735	0,429	0,891
104	rt_104_1_1_3_4	0,985	1,957	0,334	0,938	1,009	2,149	0,338	0,932
105	rt_105_1_1_3_4	1,348	3,353	0,355	0,957	1,39	3,594	0,36	0,953
106	rt_106_1_1_4_4	1,026	2,1	0,377	0,925	1,056	2,285	0,381	0,918
107	rt_107_1_2_3_4	1,324	3,555	0,404	0,941	1,332	3,801	0,41	0,935
108	rt_108_1_1_4_4	1,169	2,589	0,363	0,948	1,196	2,838	0,368	0,943
109	rt_109_1_2_3_4	1,138	2,454	0,394	0,94	1,162	2,643	0,397	0,935
110	rt_110_1_2_3_4	1,031	2,281	0,381	0,944	1,046	2,418	0,381	0,941
111	rt_111_1_2_3_4	1,127	2,372	0,366	0,927	1,145	2,503	0,368	0,923
112	rt_112_1_1_4_4	1,344	3,405	0,422	0,931	1,368	3,617	0,425	0,927
113	rt_113_1_2_3_4	1,485	4,306	0,456	0,941	1,541	4,652	0,467	0,936
114	rt_114_1_1_4_4	1,139	2,582	0,415	0,924	1,171	2,756	0,421	0,919
115	rt_115_1_1_4_4	1,257	3,059	0,41	0,942	1,286	3,236	0,416	0,938
116	rt_116_1_1_3_4	1,111	2,359	0,455	0,932	1,144	2,575	0,455	0,926
117	rt_117_1_1_4_4	1,037	2,177	0,367	0,905	1,072	2,477	0,373	0,891
118	rt_118_1_2_2_4	1,081	2,306	0,387	0,924	1,109	2,502	0,39	0,917

Çizelge 6.2’den ise, çalışmada kullanılan maksimum rüzgarların belirlenen en iyi mimariye sahip YSA ile ÇLR sonuçlarının test aşaması için olan hata ve korelasyon karşılaştırmaları görülebilir. Eğitim aşamasında olduğu gibi tüm RT’ler için YSA ve ÇLR karşılaştırma sonuçları birbirlerine çok yakın olup, test aşamasında ise ÇLR sonuçları az bir miktar daha iyidir. Örneğin 101 nolu RT için bakacak olursak; YSA’ya ait OHM, OKH, KOH ve r değerleri sırasıyla 1,350; 3,924; 0,565 ve 0,920 iken, ÇLR değerleri sırasıyla 1,291; 3,607; 0,543 ve 0,926 olarak hesaplanmıştır.

Çizelge 6.2 : Maksimum rüzgarların YSA ve ÇLR test aşaması hata ve korelasyon karşılaştırması.

RT	YSA TEST AŞAMASI					ÇLR TEST AŞAMASI			
	En İyi Mimari	OMH	OKH	KOH	r	OMH	OKH	KOH	r
101	rt_101_1_2_3_4	1,35	3,924	0,565	0,92	1,291	3,607	0,543	0,926
102	rt_102_1_1_3_4	1,12	2,585	0,454	0,879	1,056	2,55	0,421	0,873
103	rt_103_1_1_3_4	1,163	2,641	0,435	0,874	1,159	2,624	0,433	0,874
104	rt_104_1_1_3_4	1,05	2,353	0,369	0,94	1,019	2,089	0,351	0,947
105	rt_105_1_1_3_4	1,438	4,355	0,367	0,954	1,382	3,665	0,363	0,961
106	rt_106_1_1_4_4	1,278	4,501	0,375	0,925	1,104	2,362	0,366	0,958
107	rt_107_1_2_3_4	1,24	3,217	0,379	0,938	1,2	3,154	0,38	0,937
108	rt_108_1_1_4_4	1,402	3,719	0,367	0,96	1,322	3,267	0,363	0,964
109	rt_109_1_2_3_4	1,145	3,632	0,4	0,902	1,103	2,259	0,396	0,94
110	rt_110_1_2_3_4	1,051	2,503	0,367	0,957	1,028	2,418	0,362	0,958
111	rt_111_1_2_3_4	1,202	2,794	0,379	0,909	1,185	2,649	0,377	0,914
112	rt_112_1_1_4_4	1,54	5,023	0,417	0,944	1,453	4,071	0,407	0,954
113	rt_113_1_2_3_4	1,164	2,905	0,567	0,851	1,103	2,629	0,536	0,859
114	rt_114_1_1_4_4	1,272	4,006	0,396	0,929	1,182	3,018	0,395	0,947
115	rt_115_1_1_4_4	1,321	3,305	0,39	0,956	1,287	3,137	0,389	0,958
116	rt_116_1_1_3_4	1,166	2,637	0,452	0,926	1,156	2,53	0,451	0,929
117	rt_117_1_1_4_4	1,271	4,684	0,367	0,906	1,138	2,601	0,361	0,947
118	rt_118_1_2_2_4	1,311	3,564	0,364	0,945	1,213	2,795	0,36	0,956

Çizelge 6.3’te de her bir istasyondaki (t-2), (t-1) ve (t) zamanındaki maksimum rüzgar hızlarından (t+1) zamanına ait rüzgar hızları hesaplanırken kullanılan ÇLR denkleminde ait katsayılar verilmiştir. ÇLR denklemi;


$$V_{(t+1)} = a V_{(t-2)} + b V_{(t-1)} + c V_{(t)} + d \quad (6.1)$$

Şeklinde ifade edilmiştir.


Çizelge 6.3: RT istasyonlarına ait ÇLR katsayıları.

RT Kodu	ÇLR Katsayıları			
	a	b	c	d
rt_101	0,921	0,008	-0,022	0,849
rt_102	0,359	0,160	0,138	3,111
rt_103	0,951	-0,079	0,013	0,949
rt_104	0,901	0,004	0,030	0,659
rt_105	1,001	-0,089	0,041	0,615
rt_106	0,892	0,018	0,011	0,693
rt_107	0,933	-0,062	0,067	0,617
rt_108	0,927	0,007	0,011	0,613
rt_109	0,893	-0,003	0,051	0,544
rt_110	0,947	-0,014	0,008	0,538
rt_111	0,885	-0,020	0,064	0,693
rt_112	0,920	-0,031	0,040	0,730
rt_113	0,942	-0,022	0,016	0,681
rt_114	0,946	-0,069	0,044	0,644
rt_115	0,957	-0,071	0,054	0,595
rt_116	0,918	-0,004	0,013	0,545
rt_117	0,905	-0,051	0,039	0,944
rt_118	0,870	0,041	0,011	0,704

Şekil 6.1 ve 6.2 rt_114 nolu RT'nin eğitim aşamasındaki YSA ve ÇLR sonuçlarının gözlem değerleriyle olan saçılımını göstermektedir. Çizelge 6.1'e göre, buradaki YSA'ya ait OHM, OKH, KOH ve r değerleri sırasıyla 1,139; 2,582; 0,415 ve 0,924 iken, ÇLR için olan değerler ise 1,171; 2,756; 0,421 ve 0,919 olarak elde edilmiştir.




Şekil 6.1: rt_114 nolu RT'nin eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.2: rt_114 nolu RT'nin eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Şekil 6.3 ve 6.4 ise rt_114 nolu RT'nin test aşamasındaki YSA ve ÇLR karşılaştırmasını içermektedir. Yine Çizelge 6.2'den görüleceği üzere, buradaki YSA için hesaplanan OHM, OKH, KOH ve r değerleri sırasıyla 1,272; 4,006; 0,396 ve 0,929 iken, ÇLR için olan değerler ise 1,182; 3,018; 0,395 ve 0,947 olarak hesaplanmıştır.




Şekil 6.3: rt_114 nolu RT'nin test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.4: rt_114 nolu RT'nin test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Aşağıdaki 2 şekilden rt_118 nolu RT'nin eğitim aşamasındaki YSA ve ÇLR sonuçlarının gözlem değerleriyle olan saçılımını görülmektedir (Şekil 6.5 ve 6.6). Buradaki YSA'ya ait OHM, OKH, KOH ve r değerleri sırasıyla 1,081; 2,306; 0,387 ve 0,924 iken, ÇLR için olan değerler ise 1,109; 2,502; 0,390 ve 0,917 olarak elde edilmiştir.




Şekil 6.5: rt_118 nolu RT'nin eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.6: rt_118 nolu RT'nin eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Şekil 6.7 ve 6.8 ise rt_118 nolu RT'nin test aşamasındaki YSA ve ÇLR karşılaştırmasını içermektedir. YSA için hesaplanan OHM, OKH, KOH ve r değerleri sırasıyla 1,311; 3,564; 0,364 ve 0,945 iken, ÇLR için olan değerler ise 1,213; 2,795; 0,360 ve 0,956 olarak hesaplanmıştır.



Şekil 6.7: rt_118 nolu RT'nin test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil 6.8: rt_118 nolu RT'nin test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Maksimum rüzgarların değerlendirilmesiyle ilgili diğer RT'lere ait saçılma grafiklerine EK B'de ki RT'lere ait maksimum rüzgarların eğitim ve test aşamasındaki YSA ile ÇLR tahmin ve gözlem değerlerinin saçılma grafikleri kısmından ulaşılabilir.

6.3 Ekstrem Rüzgarlar

Ekstrem rüzgarların belirlenen en iyi mimariye sahip YSA ile ÇLR sonuçlarının eğitim aşaması için olan hata ve korelasyon karşılaştırmaları Çizelge 6.3'te görülmektedir. Aynen maksimum rüzgarlarda olduğu gibi burada da, tüm RT'ler için tek bir en iyi YSA mimarisi yerine farklı mimariler söz konusudur. Bunlardan 3_1_1_2 (traincgb, logsig, 1, 4) 4, 1_1_1_2 (trainlm, logsig, 1, 4) 3, 1_2_1_2 (trainlm, tansig, 1, 4) 2 ve 2_1_1_2 (traincgb, logsig, 1, 4) 2 adet bulunmaktadır. Bunların ortak özellikleri 1 gizli tabaka ve 4 sinir hücre sayısına sahip olmalarıdır.

Yapılan hassasiyet analizinde, birkaç istisna hariç neredeyse her RT için farklı mimariler elde edilmiştir. Genel olarak, 103 ve 113 RT sonuçları dışında diğer RT'ler için YSA ve ÇLR karşılaştırma sonuçları birbirlerine yakındır. Buradaki hata ve korelasyon sonuçlarının maksimum rüzgarlardaki sonuçlarla olan karşılaştırmasındaysa, hata değerlerinin yükseldiği ve korelasyon değerinin ise düştüğü açık olarak görülebilmektedir. Ekstrem rüzgarda sadece 20 m/sn rüzgar hızının göz önüne alındığı düşünülecek olursa bu beklenen bir sonuçtur.

Çizelge 6.4 : Ekstrem rüzgarların YSA ve ÇLR eğitim aşaması hata ve korelasyon karşılaştırması.


RT	YSA EĞİTİM AŞAMASI					ÇLR EĞİTİM AŞAMASI			
	En İyi Mimari	OMH	OKH	KOH	r	OMH	OKH	KOH	r
101	rt_101_1_1_1_3_11	3,22428	16,9538	0,37443	0,36674	3,0512	15,57408	0,36466	0,35125
102	rt_102_3_1_3_2_11	23,10482	894,4184	0,81358	0,22146	16,21157	687,9919	0,62825	-0,15979
103	rt_103_3_2_4_4_11	10,8328	123,4839	0,69569	-0,30948	3,89992	26,44764	0,41715	0,26268
104	rt_104_1_2_1_2_11	2,29998	9,09035	0,31906	0,50359	2,21046	8,66582	0,31327	0,52959
105	rt_105_3_1_1_2_11	1,97548	6,59593	0,28836	0,80275	1,56718	4,15912	0,25716	0,81799
106	rt_106_1_1_1_2_11	3,5428	21,84876	0,40339	0,38585	3,22871	19,98658	0,38533	0,38196
107	rt_107_2_1_1_2_11	7,5631	73,85833	0,56119	0,72197	2,07807	8,7465	0,29389	0,79863
108	rt_108_2_1_1_2_11	2,05218	7,6957	0,29839	0,7473	1,95995	7,17888	0,29387	0,75189
109	rt_109_3_2_1_2_11	2,54896	12,65149	0,33929	0,49848	2,50584	12,18287	0,33501	0,46538
110	rt_110_1_1_1_2_11	2,61366	14,69402	0,3248	0,8212	2,65179	14,83034	0,32562	0,80866
111	rt_111_2_1_3_4_11	2,0155	7,42287	0,298	0,62025	2,11367	7,93571	0,30487	0,63203
112	rt_112_1_1_1_2_11	2,09206	9,6837	0,30369	0,65086	2,13166	9,78311	0,30638	0,6438
113	rt_113_2_1_1_1_11	11,28874	129,7076	0,71657	0,20052	1,74364	6,11425	0,28154	0,51348
114	rt_114_3_1_1_2_11	2,15223	8,08599	0,31342	0,66078	2,30144	8,7471	0,32371	0,63628
115	rt_115_3_2_1_3_11	2,44707	11,10128	0,33187	0,5113	2,33304	10,45062	0,32439	0,50741
116	rt_116_1_2_1_2_11	3,99482	21,31663	0,42547	0,49554	3,49234	19,04842	0,39784	0,44442
117	rt_117_3_1_1_2_11	6,32567	52,59721	0,52637	-0,0599	4,83238	39,2666	0,45873	-0,00174
118	rt_118_3_1_1_2_11	4,12962	22,69014	0,4218	0,61794	3,21278	16,3351	0,37236	0,61317

Çizelge 6.4 ise, çalışmada kullanılan ekstrem rüzgarların belirlenen en iyi mimariye sahip YSA ile ÇLR sonuçlarının test aşaması için olan hata ve korelasyon karşılaştırmalarını özetlemektedir. Eğitim aşamasında olduğu gibi genel olarak, 103 ve 113 RT sonuçları dışında diğer RT'ler için YSA ve ÇLR karşılaştırma sonuçları birbirlerine yakın olarak görülmektedir.


Çizelge 6.5 : Ekstrem Rüzgarların YSA ve ÇLR test aşaması hata ve korelasyon karşılaştırması.

RT	YSA TEST AŞAMASI					ÇLR TEST AŞAMASI			
	En İyi Mimari	OMH	OKH	KOH	r	OMH	OKH	KOH	r
101	rt_101_1_1_1_3_11	3,22428	16,9538	0,37443	0,36674	3,50775	17,80898	0,38205	0,72339
102	rt_102_3_1_3_2_11	15,501	285,8659	0,787	0,71084	10,1522	218,6115	0,60154	-0,68171
103	rt_103_3_2_4_4_11	10,60133	116,4978	0,69929	-0,72042	5,93114	50,2781	0,52069	-0,37867
104	rt_104_1_2_1_2_11	2,17648	7,55368	0,29699	0,76407	1,86309	5,89596	0,27504	0,78999
105	rt_105_3_1_1_2_11	1,92115	6,16122	0,27999	0,85039	1,48721	4,23133	0,24637	0,84623
106	rt_106_1_1_1_2_11	2,57643	10,27615	0,3213	0,87051	2,01663	6,75244	0,28339	0,86248
107	rt_107_2_1_1_2_11	5,37327	46,58544	0,48303	0,64162	1,46382	8,12646	0,25143	0,50848
108	rt_108_2_1_1_2_11	1,89409	6,12996	0,27671	0,89912	1,5966	4,59209	0,25763	0,89898
109	rt_109_3_2_1_2_11	2,51746	10,29418	0,3278	0,70103	2,16793	9,51557	0,30346	0,70758
110	rt_110_1_1_1_2_11	2,07876	8,45429	0,29345	0,7035	1,93375	7,50102	0,2838	0,69344
111	rt_111_2_1_3_4_11	2,40507	10,13559	0,32824	0,40354	2,62662	11,44681	0,34261	0,33805
112	rt_112_1_1_1_2_11	1,96354	7,29926	0,28495	0,86783	1,7864	6,32705	0,27211	0,86479
113	rt_113_2_1_1_1_11	11,17789	127,3462	0,71472	0,91908	4,73757	28,51748	0,46627	0,42275
114	rt_114_3_1_1_2_11	2,25896	9,51025	0,30821	0,7634	2,09388	8,39707	0,29597	0,75973
115	rt_115_3_2_1_3_11	1,84395	5,78199	0,28104	0,67366	1,67753	4,92598	0,2684	0,66994
116	rt_116_1_2_1_2_11	3,92358	22,51665	0,42214	0,54054	3,28379	19,26217	0,3873	0,52789
117	rt_117_3_1_1_2_11	4,76845	31,26311	0,43743	0,7862	2,26424	10,3731	0,30039	0,84206
118	rt_118_3_1_1_2_11	2,84943	11,92816	0,34491	0,83151	1,95013	6,51641	0,28302	0,8172

Şekil 6.9 ve 6.10 rt_114 nolu RT'nin eğitim aşamasındaki YSA ve ÇLR sonuçlarının gözlem değerleriyle olan saçılımını göstermektedir. Çizelge 6.3'e göre, buradaki YSA'ya ait OHM, OKH, KOH ve r değerleri sırasıyla 2,152; 8,086; 0,313 ve 0,661 iken, ÇLR için olan değerler ise 2,301; 8,747; 0,324 ve 0,636 olarak elde edilmiştir.




Şekil 6.9: rt_114 nolu RT'nin eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.10: rt_114 nolu RT'nin eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Şekil 6.11 ve 6.12 ise rt_114 nolu RT'nin test aşamasındaki YSA ve ÇLR karşılaştırmasını içermektedir. Yine Çizelge 6.4'ten görüleceği üzere, buradaki YSA için hesaplanan OHM, OKH, KOH ve r değerleri sırasıyla 2,259; 9,510; 0,308 ve 0,763 iken, ÇLR için olan değerler ise 2,094; 8,397; 0,296 ve 0,760 olarak hesaplanmıştır.




Şekil 6.11: rt_114 nolu RT'nin test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.12: rt_114 nolu RT'nin test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Aşağıdaki 2 şekilden rt_118 nolu RT'nin eğitim aşamasındaki YSA ve ÇLR sonuçlarının gözlem değerleriyle olan saçılımı görülmektedir (Şekil 6.13 ve 6.14). Buradaki YSA'ya ait OHM, OKH, KOH ve r değerleri sırasıyla 4,130; 22,690; 0,422 ve 0,618 iken, ÇLR için olan değerler ise 3,213; 16,335; 0,372 ve 0,913 olarak elde edilmiştir.




Şekil 6.13: rt_118 nolu RT'nin eğitim aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil 6.14: rt_118 nolu RT'nin eğitim aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Şekil 6.15 ve 6.16 ise rt_118 nolu RT'nin test aşamasındaki YSA ve ÇLR karşılaştırmasını içermektedir. YSA için hesaplanan OHM, OKH, KOH ve r değerleri sırasıyla 2,849; 11,928; 0,345 ve 0,832 iken, ÇLR için olan değerler ise 1,950; 6,516; 0,283 ve 0,817 olarak hesaplanmıştır.



Şekil 6.15: rt_118 nolu RT'nın test aşamasındaki YSA tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil 6.16: rt_118 nolu RT'nın test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

Ekstrem rüzgarların değerlendirilmesiyle ilgili diğer RT'lere ait saçılma grafiklerine EK C'de ki RT'lere ait ekstrem rüzgarların eğitim ve test aşamasındaki YSA ile ÇLR tahmin ve gözlem değerlerinin saçılma grafikleri kısmından ulaşılabilir.

7. SONUÇLAR VE ÖNERİLER

Ekstrem rüzgarların verebileceği zarar ve enerji kayıplarının azaltılması noktasında ekstrem rüzgarların tahmini önem arz eden bir konudur. Bu amaçla bu çalışmada, ülkemizin Marmara, Ege, Güneydoğu ve Akdeniz Bölgelerinde bulunan 18 farklı Rüzgar Tarlası'na (RT) ait maksimum rüzgar verileri kullanılarak, Yapay Sinir Ağları (YSA) ve Çoklu Lineer Regresyon (ÇLR) temelli birer tahmin modeli geliştirmeye çalışılmıştır. (t-2), (t-1) ve (t) zamanlarından (t+1) zamanındaki maksimum rüzgar tahminleri elde edilerek değerlendirilmiştir.

Maksimum rüzgar hızlarının YSA mimarileri incelendiğinde; 1_2_3_4; (trainlm, tansig, 3, 9), 1_1_3_4; (trainlm, logsig, 3, 9), 1_1_4_4; (trainlm, logsig, 4, 9) ve 1_2_2_4; (trainlm, tansig, 2, 9) mimarileri sırasıyla 6, 5, 6 ve 1 adet olarak elde edilmiştir. Buradan da anlaşılabileceği gibi tüm mimarilerde trainlm öğrenme algoritması ve 9 adet sinir hücre sayısı ortaktır.

Maksimum rüzgarlarda olduğu gibi ekstrem rüzgarlarda da, tüm RT'ler için tek bir en iyi YSA mimari bulunmamaktadır. Yüksek performansa sahip mimarilerden 3_1_1_2; (traincgb, logsig, 1, 4) 4, 1_1_1_2; (trainlm, logsig, 1, 4) 3, 1_2_1_2; (trainlm, tansig, 1, 4) 2 ve 2_1_1_2; (traincgb, logsig, 1, 4) 2 adet bulunmaktadır. Bunların ortak özellikleri ise 1 gizli tabaka ve 4 sinir hücre sayısına sahip olmalarıdır.

Her iki rüzgar (maksimum, ekstrem) tahmininde de YSA ve ÇLR sonuçlarına bakıldığında beklendiği gibi eğitim aşamasındaki hataların test aşamasına göre daha küçük değerler aldığı görülmüştür.

Kullanım kolaylığı açısından ÇLR, YSA'dan daha pratiktir. Çünkü nihayetinde ÇLR bir denklemden oluşmaktadır. Buna karşın YSA yapısı açısından çok karmaşıktır. Farklı mimariler üzerinden YSA'nın geliştirilebilmesi imkanı olması da YSA'nın avantajıdır. Burada elde edilen YSA ve ÇLR sonuçları genel olarak birbirine yakındır.

Ayrıca, daha sonraki çalışmalar için daha farklı YSA mimarilerinin denenmesi, daha uzun veri setlerinin kullanılması, tahminlerin daha uzun zamanlar için geliştirilmesi ve sayısal hava tahmin modelleri tarafından üretilen meteorolojik değişkenlerin de sisteme dahil edilmesi önerilmektedir.



KAYNAKLAR

- [1] **Özdamar, A.** (2000). Dünya ve Türkiye'de rüzgar enerjisinden yararlanılması üzerine bir araştırma. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 6(2), 133-145.
- [2] **Lee, B., Ahn, D., Kim, H. & Ha, Y.** (2012). An estimation of the extreme wind speed using the Korea wind map. *Renewable Energy*, 42, 4-10. doi:10.1016/j.renene.2011.09.033.
- [3] **Satir, M., Murphy, F. & McDonnell, K.** (2018). Feasibility study of an offshore wind farm in the Aegean Sea, Turkey. *Renewable and Sustainable Energy Reviews*, 81(2), 2552-2562. doi:10.1016/j.rser.2017.06.063.
- [4] **Korukçu, M. Ö.** (2017). Investigation of long term wind characteristics and wind energy potential in Bandırma, Turkey. *Pamukkale University Journal of Engineering Sciences*, 23(4), 337-342. doi:10.5505/pajes.2016.99267.
- [5] **Kaplan, Y. A.** (2015). Overview of wind energy in the world and assessment of current wind energy policies in Turkey. *Renewable and Sustainable Energy Reviews*, 43, 562-568. doi:10.1016/j.rser.2014.11.027.
- [6] **Ucar, A. & Balo, F.** (2009). Evaluation of wind energy potential and electricity generation at six locations in Turkey. *Applied Energy*, 86(10), 1864-1872. doi:10.1016/j.apenergy.2008.12.016.
- [7] **Gökçek, M., Bayülken, A., & Bekdemir, Ş.** (2007). Investigation of wind characteristics and wind energy potential in Kırklareli, Turkey. *Renewable Energy*, 32(10), 1739-1752. doi:10.1016/j.renene.2006.11.017.
- [8] **Cannon, D., Brayshaw, D., Methven, J., Coker, P., & Lenaghan, D.** (2015). Using reanalysis data to quantify extreme wind power generation statistics: A 33 year case study in Great Britain. *Renewable Energy*, 75, 767-778. doi:10.1016/j.renene.2014.10.024.
- [9] **Kang, D., Ko, K., & Huh, J.** (2015). Determination of extreme wind values using the Gumbel distribution. *Energy*, 86, 51-58. doi:10.1016/j.energy.2015.03.126.
- [10] **Wang, J., Qin, S., Jin, S., & Wu, J.** (2015). Estimation methods review and analysis of offshore extreme wind speeds and wind energy resources. *Renewable and Sustainable Energy Reviews*, 42, 26-42. doi:10.1016/j.rser.2014.09.042.
- [11] **Sotillo, M., Aznar, R., & Valero, F.** (2008). The 44-year Mediterranean HIPOCAS wind database: A useful tool to analyse offshore extreme wind events from a long-term regional perspective. *Coastal Engineering*, 55(11), 930-943. doi:10.1016/j.coastaleng.2008.02.008.

- [12] **Escalante-Sandoval, C.** (2008). Bivariate estimation of extreme wind speeds. *Structural Safety*, 30(6), 481-492. doi:10.1016/j.strusafe.2007.09.005.
- [13] **G.C. Schulze, G.C.** (2007). Atmospheric observations and numerical weather prediction. *South African Journal of Science*, 103(7-8), 318-323.
- [14] **Negnevitsky, M., & Potter, C.** (2006). Innovative short-term wind generation prediction techniques. *2006 IEEE PES Power Systems Conference and Exposition*. doi:10.1109/psce.2006.296250.
- [15] **Al-Yahyai, S., Charabi, Y., & Gastli, A.** (2010). Review of the use of numerical weather prediction (NWP) Models for wind energy assessment. *Renewable and Sustainable Energy Reviews*, 14(9), 3192-3198. doi:10.1016/j.rser.2010.07.001.
- [16] **Zhang, J., Draxl, C., Hopson, T., Monache, L. D., Vanvyve, E., & Hodge, B.** (2015). Comparison of numerical weather prediction based deterministic and probabilistic wind resource assessment methods. *Applied Energy*, 156, 528-541. doi:10.1016/j.apenergy.2015.07.059.
- [17] **Lei, M., Shiyan, L., Chuanwen, J., Hongling, L. & Yan, Z.** (2009). A review on the forecasting of wind speed and generated power. *Renewable and Sustainable Energy Reviews*, 13(4), 915-920. doi: 10.1016/j.rser.2008.02.002.
- [18] **Jimenez, B., Durante, F., Lange, B., Kreutzer, T., & Tambke, J.** (2007). Offshore wind resource assessment with WAsP and MM5: comparative study for the German Bight. *Wind Energy*, 10(2), 121-134. doi:10.1002/we.212.
- [19] **Lazić, L., Pejanović, G., & Živković, M.** (2010). Wind forecasts for wind power generation using the Eta model. *Renewable Energy*, 35(6), 1236-1243. doi:10.1016/j.renene.2009.10.028.
- [20] **Zhao, P., Wang, J., Xia, J., Dai, Y., Sheng, Y., & Yue, J.** (2012). Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. *Renewable Energy*, 43, 234-241. doi:10.1016/j.renene.2011.11.051.
- [21] **Carvalho, D., Rocha, A., Gómez-Gesteira, M., & Santos, C.** (2012). A sensitivity study of the WRF model in wind simulation for an area of high wind energy. *Environmental Modelling & Software*, 33, 23-34. doi:10.1016/j.envsoft.2012.01.019.
- [22] **Landberg, L.** (1999). Short-term prediction of the power production from wind farms. *Journal of Wind Engineering and Industrial Aerodynamics*, 80(1-2), 207-220. doi:10.1016/s0167-6105(98)00192-5.
- [23] **Ramirez-Rosado, I. J., Fernandez-Jimenez, L. A., Monteiro, C., Sousa, J., & Bessa, R.** (2009). Comparison of two new short-term wind-power forecasting systems. *Renewable Energy*, 34(7), 1848-1854. doi:10.1016/j.renene.2008.11.014.
- [24] **Chen, N., Qian, Z., Nabney, I. T., & Meng, X.** (2014). Wind power forecasts using gaussian processes and numerical weather prediction. *IEEE Transactions on Power Systems*, 29(2), 656-665. doi:10.1109/tpwrs.2013.2282366.

- [25] **Url-1** <<http://www.mgm.gov.tr/FILES/genel/sss/sayisalnedir.pdf>>, erişim tarihi: 10.02.2018.
- [26] **Mohandes, M., Rehman, S., & Rahman, S.** (2011). Estimation of wind speed profile using adaptive neuro-fuzzy inference system (ANFIS). *Applied Energy*, 88(11), 4024-4032. doi:10.1016/j.apenergy.2011.04.015.
- [27] **Li, X., Liu, Y., & Xin, W.** (2009). Wind speed prediction based on genetic neural network. *2009 4th IEEE Conference on Industrial Electronics and Applications*. doi:10.1109/iciea.2009.5138642.
- [28] **Pan Zhao; Junrong Xia; Yiping Dai; Jiaying He.** (2010). Wind speed prediction using support vector regression, 5th IEEE Conference on Industrial Electronics and Applications (ICIEA), vol., no., pp.882,886.
- [29] **Tarade, R. S., & Katti, P. K.** (2011). A comparative analysis for wind speed prediction. *2011 International Conference on Energy, Automation and Signal*. doi:10.1109/iceas.2011.6147167.
- [30] **Chen, N., Qian, Z., Nabney, I. T., & Meng, X.** (2014). Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction. *IEEE Transactions on Power Systems*, 29(2), 656-665. doi:10.1109/tpwrs.2013.2282366.
- [31] **Kusiak, A., & Zhang, Z.** (2010). Short-Horizon Prediction of Wind Power: A Data-Driven Approach. *IEEE Transactions on Energy Conversion*, 25(4), 1112-1122. doi:10.1109/tec.2010.2043436.
- [32] **Mohandes, M. A., Rehman, S., & Halawani, T. O.** (1998). A neural networks approach for wind speed prediction. *Renewable Energy*, 13(3), 345-354. doi:10.1016/s0960-1481(98)00001-9.
- [33] **Bilgili, M., Sahin, B., & Yasar, A.** (2007). Application of artificial neural networks for the wind speed prediction of target station using reference stations data. *Renewable Energy*, 32(14), 2350-2360. doi:10.1016/j.renene.2006.12.001.
- [34] **Monfared, M., Rastegar, H., & Kojabadi, H. M.** (2009). A new strategy for wind speed forecasting using artificial intelligent methods. *Renewable Energy*, 34(3), 845-848. doi:10.1016/j.renene.2008.04.017.
- [35] **Mohandes, M., Halawani, T., Rehman, S., & Hussain, A. A.** (2004). Support vector machines for wind speed prediction. *Renewable Energy*, 29(6), 939-947. doi:10.1016/j.renene.2003.11.009.
- [36] **Mabel, M. C., & Fernandez, E.** (2008). Analysis of wind power generation and prediction using ANN: A case study. *Renewable Energy*, 33(5), 986-992. doi:10.1016/j.renene.2007.06.013.
- [37] **Şenol, Ü., & Musayev, Z.** (2017). Rüzgar Enerjisinden Elektrik Üretiminin Yapay Sinir Ağları ile Tahmini. *Bilge Uluslararası Fen ve Teknoloji Araştırma Dergisi*, 1(1), 23-31.
- [38] **Öztopal, A.** (2007). Uydu Ve Yer Kaynaklı Meteorolojik Değişkenlerle Kısa Vadeli Yağış Modellemesi İçin Yapay Sinir Ağı Yaklaşımı, Doktora Tezi, İTÜ Fen Bilimleri Enstitüsü.

- [39] **Yurtoğlu, H.** (2005). Yapay sinir ağları metodolojisi ile öngörü modellemesi: Bazı makroekonomik değişkenler için Türkiye örneği, Uzmanlık Tezi, DPT.
- [40] **Şen, Z.** (2004). Yapay sinir ağları ilkeleri, Su Vakfı Yayınları, İstanbul.
- [41] **Haykin, S.** (1999). Neural networks: a comprehensive foundation, 2nd edition, Pentice-Hall, New Jersey.
- [42] **Haykin, S.** (2001). Kalman filtering and neural networks, Wiley , New York.



EKLER


EK A: Rüzgar tarlalarına ait YSA mimarilerinin hata ve korelasyonları

EK B: RT'lere ait maksimum rüzgarların eğitim ve test aşamasındaki YSA ile ÇLR tahmin ve gözlem değerlerinin saçılma grafikleri


EK C: RT'lere ait ekstrem rüzgarların eğitim ve test aşamasındaki YSA ile ÇLR tahmin ve gözlem değerlerinin saçılma grafikleri




EK A




Şekil A.1: rt_101 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.2: rt_102 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.3: rt_103 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.4: rt_104 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




(a)



(b)




(c)




(d)


Şekil A.5: rt_105 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.6: rt_106 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




(a)



(b)




(c)







(d)





Şekil A.7: rt_107 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.8: rt_108 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.9: rt_109 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.10: rt_110 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.11: rt_111 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




(a)



(b)




(c)




(d)


Şekil A.12: rt_112 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.







Şekil A.13: rt_113 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.14: rt_115 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.15: rt_116 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




Şekil A.16: rt_117 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.




(a)



(b)




(c)




(d)

Şekil A.17: rt_118 nolu RT'na ait YSA mimarilerinin (a) Ortalama Mutlak Hata, (b) Ortalama Karesel Hata, (c) Karekök Ortalama Hata ve (d) korelasyon grafikleri.


EK B




Şekil B.1: rt_101 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




(a)



(b)




(c)




(d)


Şekil B.2: rt_102 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.3: rt_103 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.4: rt_104 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.5: rt_105 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.6: rt_106 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerin saçılma grafiği.




Şekil B.7: rt_107 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.8: rt_108 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.9: rt_109 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.10: rt_110 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.11: rt_111 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.12: rt_112 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.13: rt_113 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil B.14: rt_115 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.15: rt_116 nolu RT'nin (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil B.16: rt_117 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.


EK C




Şekil C.1: rt_101 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.2: rt_102 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.







Şekil C.4: rt_104 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.5: rt_105 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.6: rt_106 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.7: rt_107 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.8: rt_108 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.9: rt_109 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




(a)



(b)




(c)




(d)


Şekil C.10: rt_110 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




(a)



(b)




(c)




(d)


Şekil C.11: rt_111 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.12: rt_112 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.




Şekil C.13: rt_113 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil C.14: rt_115 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil C.15: rt_116 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.



Şekil C.16: rt_117 nolu RT'nın (a) Eğitim aşamasındaki YSA, (b) Eğitim aşamasındaki ÇLR, (c) Test aşamasındaki YSA, (d) Test aşamasındaki ÇLR tahmin ve gözlem değerlerinin saçılma grafiği.

ÖZGEÇMİŞ

VESİKALIK
FOTO

Ad-Soyad : Melek AKIN
Doğum Tarihi ve Yeri : 17.08.1992 Safranbolu
E-posta : akinm@itu.edu.tr

ÖĞRENİM DURUMU:

- **Lisans** : 2015, İTÜ, UUBF, Meteoroloji Mühendisliği

