

**HAVA KİRLETİCİ, COĞRAFİ VE
METEOROLOJİK FAKTÖRLERİN GÜNEŞ IŞINIM
ŞİDDETİ TAHMİN PERFORMANSINA
ETKİLERİNİN İNCELENMESİ**

**2018
DOKTORA TEZİ
MAKİNE MÜHENDİSLİĞİ**

Yusuf KURTGÖZ

**HAVA KİRLETİCİ, COĞRAFI VE METEOROLOJİK FAKTÖRLERİN
GÜNEŞ IŞINIM ŞİDDETİ TAHMİN PERFORMANSINA ETKİLERİNİN
İNCELENMESİ**

Yusuf KURTGÖZ

Karabük Üniversitesi

Fen Bilimleri Enstitüsü

Makine Mühendisliği Anabilim Dalında

Doktora Tezi

Olarak Hazırlanmıştır

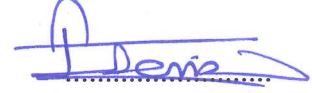
KARABÜK

OCAK 2018

Yusuf KURTGÖZ tarafından hazırlanan “HAVA KİRLLETİCİ, COĞRAFİ VE METEOROLOJİK FAKTÖRLERİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİN PERFORMANSINA ETKİLERİNİN İNCELENMESİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Emrah DENİZ

Tez Danışmanı, Makine Mühendisliği Anabilim Dalı



Bu çalışma, jürimiz tarafından oy birliği ile Makine Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 19/01/2018

Ünvanı, Adı SOYADI (Kurumu)

İmzası

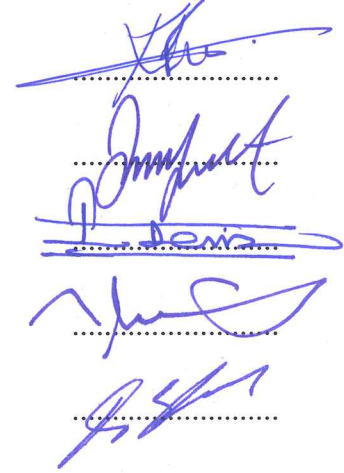
Başkan : Prof. Dr. Ahmet Korhan BİNARK (İZÜ)

Üye : Prof. Dr. Sezayi YILMAZ (KBÜ)

Üye : Doç. Dr. Emrah DENİZ (KBÜ)

Üye : Doç. Dr. Yaşar YETİŞKEN (KBÜ)

Üye : Yrd. Doç. Dr. Okan ERKAYMAZ (BEÜ)



...../...../2018

KBÜ Fen Bilimleri Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Filiz ERSÖZ

Fen Bilimleri Enstitüsü Müdür V.





“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Yusuf KURTÖZ

ÖZET

Doktora Tezi

HAVA KİRLETİCİ, COĞRAFİ VE METEOROLOJİK FAKTÖRLERİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİN PERFORMANSINA ETKİLERİNİN İNCELENMESİ

Yusuf KURTGÖZ

Karabük Üniversitesi

Fen Bilimleri Enstitüsü

Makine Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. Emrah DENİZ

Ocak 2018, 106 sayfa

Yapılan çalışmada, hava kirleticilerden partikül madde 10 (PM₁₀) ve kükürt dioksit (SO₂) parametreleri, coğrafi faktörlerden enlem (Enl), boylam (Byl), rakım (Rkm), yılın günü (nGun), ay, günlük maksimum güneşlenme süresi (N), atmosfer öncesi güneş ışınımı (H_o) ve deklinasyon açısının sinüsü (SinD) parametreleri ve meteorolojik verilerden ise atmosfer havasının ortalama nem (R_{hum}), minimum sıcaklık (T_{min}), ortalama sıcaklık (T_{avg}), maksimum sıcaklık (T_{max}) parametreleri ile ortalama toprak sıcaklığı (T_s), ortalama rüzgâr hızı (WS), günlük güneşlenme süresi (n) ve günlük güneşlenme süresinin maksimum güneşlenme süresine oranı (nN) parametrelerinin güneş ışınım şiddetinin (GSR) yapay sinir ağı (YSA) tahmin performansına etkileri incelenmiştir. Çalışmada kullanılan veriler Çevre ve Şehircilik Bakanlığı kurumlarından Çevre Referans Laboratuvarı Merkezi ve Orman ve Su İşleri Bakanlığı kurumlarından Meteoroloji Genel Müdürlüğü'nden alınmıştır. Bu

parametrelerin, GSR tahmini üzerine etkilerini incelemek amacıyla farklı YSA modelleri geliştirilmiştir. Bu modeller ile elde edilen sonuçları değerlendirmek için korelasyon katsayısı (R), ortalama mutlak yüzde hata (MAPE) ve hata kareleri ortalamasının karekökü (RMSE) performans göstergeleri kullanılmıştır.

Günlük veriler üzerinde hava kirleticiler ile coğrafi-meteorolojik parametrelerin GSR tahmin performansına etkileri ayrı ayrı incelenmiştir. Bir konum için PM₁₀ ve SO₂ ortalaması yükseldiğinde hava kirletici ile GSR arasındaki korelasyon ters yönde artmaktadır. Ortalama ve GSR korelasyonu yüksek olan bölgelerin YSA tahmin performansları, düşük olan bölgelere göre artış göstermiştir. Başka bir ifade ile PM₁₀ ve SO₂ ortalama değerlerinin yüksek olduğu bölgelerde güneş enerjisinden yararlanma performansının düşme eğiliminde olduğu tespit edilmiştir.

Coğrafi ve meteorolojik faktörler açısından en iyi performans gösteren 1-10 ve 16'lı girdi kombinasyonlarına bakıldığında, üçlü kombinasyon ve sonrasında YSA tahmin performansında önemli bir gelişme olmadığı gözlenmiştir. Girdi sayısı arttıkça YSA eğitim veri seti performans göstergelerinde küçük iyileşmeler olsa da, test veri seti kombinasyon sayısı üçü geçtikten sonra performans göstergelerinde düşüş gözlenmiştir. Test veri setindeki bu düşüş, özellikle MAPE performans göstergesinde daha belirgin olarak ortaya çıkmıştır.

Yapılan çalışmada literatürdeki çalışmalardan farklı olarak, bir konumun aylık GSR tahmininde, üç çevre istasyonunun GSR verilerinin de modelde girdi olarak kullanılmasının tahmin performansını artırdığı gösterilmiştir. Günlük GSR tahmininde ise uzayan tahmin süresi modelin hesaplama performansını düşürdüğü için üç çevre istasyonun GSR verisini modele ayrı ayrı eklemek yerine bu verilerin ortalama değerleri hesaplanarak tek girdi olarak modele eklenmiş ve yine eklenmediği modellere kıyasla daha iyi sonuçlar verdiği görülmüştür.

Anahtar Sözcükler : Güneş enerjisi, güneş ışınım şiddeti, yapay sinir ağı, tahmin, hava kirleticiler, coğrafi-meteorolojik parametreler.

Bilim Kodu : 914.1.233

ABSTRACT

Ph. D. Thesis

THE INVESTIGATION OF THE EFFECTS OF AIR POLLUTANT, GEOGRAPHICAL AND METEOROLOGICAL FACTORS ON THE ESTIMATION PERFORMANCE OF SOLAR RADIATION

Yusuf KURTGÖZ

Karabük University

Graduate School of Natural and Applied Sciences

Department of Mechanical Engineering

Thesis Advisor:

Assoc. Prof. Dr. Emrah DENİZ

January 2018, 106 pages

In this study, the effects of the air pollutants (PM_{10} and SO_2), geographical parameters (latitude, longitude, altitude, day of the year, month, maximum daily sunshine duration, extraterrestrial radiation and sine of declination angle) and meteorological factors (average humidity, minimum temperature, average temperature, maximum temperature, average soil temperature, average wind speed, daily sunshine duration and the ratio of daily sunshine duration to maximum sunshine duration) on the prediction performance of the global solar radiation (GSR) with artificial neural network (ANN) is investigated. The data used in the study are taken from Environment and Urban Ministry/Environmental Reference Laboratory Center and Ministry of Forestry and Water Management/General Directorate of Meteorology. Different ANN models are developed to analyze the effects of these parameters on the GSR estimation. Correlation coefficient (R), mean absolute percentage error (MAPE) and root mean

square error (RMSE) performance indicators are used to evaluate the results obtained by these models.

The effects of air pollutants and geo-meteorological parameters on the estimation of the daily GSR were investigated separately. When the average of PM₁₀ and SO₂ for a location increases, the correlation between air pollutant and GSR increases in the negative direction. As the mean and GSR correlation values increase for a region, ANN prediction performance also increased. In other words, this result showed that the solar energy utilization performance tends to decrease in regions where the average values of PM₁₀ and SO₂ are high.

According to the different input combinations (1-10, 16) that give the best performance for geo-meteorological parameters, the results showed no significant improvement in the ANN prediction performance after triple combination. Although increasing the number of inputs produces a slight improvement in the performance indicators of the ANN training data set, there is a decrease in the performance indicators after the triple combination of test data set. This decrease in the test data set has become more evident especially for the MAPE performance indicator.

Different from the literature, it has been shown that the use of GSR data of three nearby stations as inputs to the model improves the monthly GSR prediction performance of a location. In the daily GSR estimation, since the increasing calculation time reduces the calculation performance of the model, instead of adding the GSR data of the three nearby stations separately, the mean values of these data are calculated and added to the model as a single input, which again produced better results than the models not added.

Key Word : Solar energy, global solar radiation, artificial neural networks, estimation, air pollutants, geo-meteorological parameters.

Science Code : 914.1.233

TEŐEKKÜR

Bu tez alıőmasının planlanması, araőtırılması, yrtlmesi ve sonulandırılması aőamalarında tecrbelerinden yararlandıėım ve nemli katkılar sunan danıőman hocam Do. Dr. Emrah DENİZ'e, tez izleme aőamasında bilgilendirmeleriyle alıőmamın őekillenmesine yardımcı olan deėerli hocalarım Prof. Dr. Sezayi YILMAZ ve Do. Dr. Yaőar YETİŐKEN'e sonsuz teőekkrlerimi sunarım.

Bu tez alıőmasında kullandıėım verileri temin ettiėim Orman ve Su İőleri Bakanlıėı kurumlarından Meteoroloji Genel Mdrlė ve evre ve őehircilik Bakanlıėı kurumlarından evre Referans Laboratuvarı Merkezi yetkililerine teőekkr ederim.

Tez alıőmam boyunca bana destek veren mesai arkadaőlarıma ve katkılarından dolayı deėerli arkadaőlarım Yrd. Do. Dr. İlker TRKER, ėr. Gr. Murat KOŐAR ve Nuri TUN'a teőekkr ederim.

Sevgili anneme, babama ve aileme maddi ve manevi hibir yardımı esirgemedен yanımda olduklarından dolayı itenlikle teőekkr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	4
LİTERATÜR ARAŞTIRMASI	4
BÖLÜM 3	10
YAPAY SİNİR AĞLARI	10
3.1. YSA TARİHÇESİ	11
3.2. BİYOLOJİK SİNİR SİSTEMİ	12
3.3. YAPAY SİNİR HÜCRESİ.....	13
3.3.1. Girdiler.....	14
3.3.2. Ağırlıklar.....	14
3.3.3. Toplama (Birleştirme) Fonksiyonu	15
3.3.4. Aktivasyon Fonksiyonu	16
3.3.5. Hücrenin Çıktısı.....	16
3.4. YSA MODELLERİNİN GENEL YAPISI.....	17
3.4.1. YSA Öğrenme Stratejileri.....	18
3.4.2. En Çok Kullanılan YSA Modelleri.....	19

	<u>Sayfa</u>
3.5. YSA UYGULAMA ALANLARI	20
BÖLÜM 4	21
MATERYAL ve METOT	21
4.1. VERİLER	21
4.1.1. Hava Kirletici Parametreleri İçin Veri Seti	26
4.1.2. Coğrafi-Meteorolojik Parametreler İçin Veri Seti	34
4.2. PERFORMANS GÖSTERGELERİ.....	35
4.3. GSR TAHMİNİNDE ÇEVRE İSTASYON YAKLAŞIMI	36
4.4. GÜNLÜK GSR TAHMİNİ İÇİN YSA MODELLERİ.....	41
4.4.1. Hava Kirletici Faktörlerin Girdi Olarak Kullanıldığı Modeller	42
4.4.2. Coğrafi-Meteorolojik Faktörlerin Girdi Olarak Kullanıldığı Modeller ..	45
BÖLÜM 5	52
UYGULAMA SONUÇLARI ve TARTIŞMA	52
5.1. HAVA KİRLETİCİLERİN GSR TAHMİNİ ÜZERİNE ETKİLERİ.....	52
5.1.1. PM ₁₀ Parametresinin GSR Tahmini Üzerindeki Etkisi	53
5.1.2. SO ₂ Parametresinin GSR Tahmini Üzerindeki Etkisi	59
5.2. COĞRAFİ VE METEOROLOJİK PARAMETRELERİN GSR TAHMİNİ ÜZERİNE ETKİLERİ.....	64
BÖLÜM 6	74
SONUÇ ve ÖNERİLER.....	74
KAYNAKLAR	77
EK AÇIKLAMALAR A. COĞRAFİ ve METEOROLOJİK PARAMETRELERİN TEKLİ KOMBİNASYONLARINA AİT TAHMİN PERFORMANSLARI	83
EK AÇIKLAMALAR B. BEŞ COĞRAFİ PARAMETRENİN TÜM KOMBİNASYONLARINA AİT TAHMİN PERFORMANSLARI.....	85
EK AÇIKLAMALAR C. SEKİZ METEOROLOJİK PARAMETRENİN TÜM KOMBİNASYONLARINA AİT TAHMİN PERFORMANSLARI.....	88
ÖZGEÇMİŞ	106

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Tipik bir biyolojik sinir hücresi.	13
Şekil 3.2. Bir yapay sinir hücresinin yapısı [43].	14
Şekil 3.3. Bir YSA modeli.	17
Şekil 4.1. Parametreler için tarih eşleştirmesi yapan sorgunun tasarım görünümü. 23	
Şekil 4.2. Ortalama PM ₁₀ değerleri ile PM ₁₀ -GSR korelasyonları dağılım grafiği. 30	
Şekil 4.3. Ortalama SO ₂ değerleri ile SO ₂ -GSR korelasyonları dağılım grafiği. 33	
Şekil 4.4. Merkez ve çevre istasyonları.	34
Şekil 4.5. Geliştirilen yaklaşım için seçilen istasyon ve çevresindeki istasyonlar. . 36	
Şekil 4.6. 2003 yılı YSA modellerinin tahmin sonuçları ve ölçülmüş veriler arasındaki dağılım grafikleri.	39
Şekil 4.7. YSA-1 ve YSA-2 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması.	40
Şekil 4.8. YSA-3 ve YSA-4 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması.	41
Şekil 4.9. PM ₁₀ parametresi için YSA modeli.	43
Şekil 4.10. SO ₂ parametresi için YSA modeli.	43
Şekil 4.11. Hava kirletici faktörlerin etkisi için MATLAB kodları akış diyagramı. . 45	
Şekil 4.12. Tekli girdi kombinasyonları için YSA modeli.	47
Şekil 4.13. Rkm sabit olmak üzere diğer parametrelerin farklı kombinasyonlarına ait YSA modeli.	47
Şekil 4.14. Rkm ve nGun sabit olmak üzere meteorolojik faktörlerin tüm kombinasyonlarına ait YSA modeli.	48
Şekil 4.15. Coğrafi-meteorolojik faktörler için MATLAB kodları akış diyagramı. ... 50	
Şekil 4.16. 4 farklı günlük GSR YSA tahmin modelinin yapıları a) YSAcm1 modeli, b) YSAcm2 modeli, c) YSAcm3 modeli, d) YSAcm4 modeli.	49
Şekil 5.1. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu düşük olan gruba ait dağılım grafiği.	55
Şekil 5.2. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu düşük olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.	56
Şekil 5.3. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu düşük olan gruba ait test verileri karşılaştırma ve hata grafiği.	56
Şekil 5.4. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu yüksek olan gruba ait dağılım grafiği.	57

Sayfa

Şekil 5.5. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu yüksek olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.	58
Şekil 5.6. PM ₁₀ ortalaması ve PM ₁₀ -GSR korelasyonu yüksek olan gruba ait test verileri karşılaştırma ve hata grafiği.	58
Şekil 5.7. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu düşük olan gruba ait dağılım grafiği.....	60
Şekil 5.8. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu düşük olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.	61
Şekil 5.9. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu düşük olan gruba ait test verileri karşılaştırma ve hata grafiği.	61
Şekil 5.10. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu yüksek olan gruba ait dağılım grafiği.....	62
Şekil 5.11. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu yüksek olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.	63
Şekil 5.12. SO ₂ ortalaması ve SO ₂ -GSR korelasyonu yüksek olan gruba ait test verileri karşılaştırma ve hata grafiği.	63
Şekil 5.13. Farklı kombinasyonlara ait eğitim ve test performansları.	68
Şekil 5.14. R _{km} , n _{Gun} , n ve H _{avg} girdi parametrelerine göre ölçüm ve tahmin değerleri dağılım grafiği.	70
Şekil 5.15. R _{km} , n _{Gun} , n ve H _{avg} girdi parametrelerine göre ölçüm ve tahmin değerleri karşılaştırma ve hata grafiği.	71

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1. GSR tahmininde MAPE, RMSE ve MBE ortalamaları.	4
Çizelge 2.2. Difüz güneş ışınım şiddeti tahmininde MAPE, RMSE ve MBE ortalamaları.	4
Çizelge 2.3. Geliştirilen modeller için RMSE değerleri.	7
Çizelge 3.1. Toplama fonksiyonu örnekleri [38].	15
Çizelge 3.2. Bazı aktivasyon fonksiyonları [43].	16
Çizelge 4.1. Çalışmada kullanılan girdi parametreleri.	25
Çizelge 4.2. Hava kirletici verileri için seçilen istasyonlar.	26
Çizelge 4.3. PM ₁₀ aykırı değerleri için alt ve üst sınırlar.	28
Çizelge 4.4. İllere göre ortalama PM ₁₀ değerleri ve PM ₁₀ -GSR korelasyonları.	29
Çizelge 4.5. Tahmin modelinde PM ₁₀ etkisi için oluşturulan veri grupları.	30
Çizelge 4.6. SO ₂ aykırı değerleri için alt ve üst sınırlar.	31
Çizelge 4.7. İllere göre ortalama SO ₂ değerleri ve SO ₂ -GSR korelasyonları.	32
Çizelge 4.8. Tahmin modelinde SO ₂ etkisi için oluşturulan veri grupları.	33
Çizelge 4.9. GSR tahmin modeli için seçilen istasyonlar ve çevre istasyonları.	34
Çizelge 4.10. Geliştirilen modeller için seçilen YSA yapıları.	38
Çizelge 4.11. Geliştirilen modellerin RMSE, MAPE ve R performans değerleri.	39
Çizelge 4.12. YSA eğitimi için kullanılan performans parametreleri.	42
Çizelge 4.13. Hava kirletici veri gruplarına göre oluşturulan YSA modelleri.	44
Çizelge 4.14. Veri yılları ve sayıları.	46
Çizelge 4.15. Veri setleri ve oranları.	46
Çizelge 4.16. Coğrafi-meteorolojik faktörler için oluşturulan 4 YSA tahmin modeli.	51
Çizelge 5.1. Hava kirletici veri grupları için tahmin performansları.	53
Çizelge 5.2. PM ₁₀ veri grupları için tahmin performansları.	54
Çizelge 5.3. SO ₂ veri grupları için tahmin performansları.	59
Çizelge 5.4. Konum parametrelerinin YSA tahmin performansları.	64
Çizelge 5.5. Coğrafi ve meteorolojik parametrelerin YSA tahmin performansları.	65
Çizelge 5.6. nGun, Ay, N, H ₀ ve SinD parametrelerinin tüm kombinasyonlarına ait performans değerleri.	66

Sayfa

Çizelge 5.7. Farklı kombinasyonlara ait iyi performans sonuçları.	67
Çizelge 5.8. Çevre istasyonlara ait ortalama GSR verisinin girdi olarak eklendiği modellerin performansları.	69
Çizelge 5.9. Literatürdeki aylık GSR tahmin modellerinin karşılaştırılması.....	72
Çizelge 5.10. Literatürdeki günlük GSR tahmin modellerinin karşılaştırılması.....	73
Çizelge Ek A.1. Coğrafi ve meteorolojik parametrelerin tekli kombinasyonlarına ait tahmin performansları.	84
Çizelge Ek B.1. Rakım parametresine ilave olarak diğer beş coğrafi parametrenin tüm kombinasyonlarına ait tahmin performansları.	86
Çizelge Ek C.1. Sekiz meteorolojik parametrenin tüm kombinasyonlarına ait tahmin performansları.	89

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

- AS : alt sınır
- Byl : boylam
- Enl : enlem
- G_{sc} : güneş sabiti
- GSR_e : tahmin edilen GSR (MJ/m^2)
- GSR_m : ölçülen GSR (MJ/m^2)
- H : merkez istasyona ait günlük GSR (MJ/m^2)
- H1 : birinci çevre istasyona ait günlük GSR (MJ/m^2)
- H2 : ikinci çevre istasyona ait günlük GSR (MJ/m^2)
- H3 : üçüncü çevre istasyona ait günlük GSR (MJ/m^2)
- H_{avg} : çevre istasyonlara ait ortalama günlük GSR (MJ/m^2)
- H_{ie} : veri setindeki i. tahmin edilen GSR değeri (MJ/m^2)
- \bar{H}_{ie} : veri setindeki tahmin edilen GSR değerlerinin ortalaması (MJ/m^2)
- H_{im} : veri setindeki i. ölçülen GSR değeri (MJ/m^2)
- \bar{H}_{im} : veri setindeki ölçülen GSR değerlerinin ortalaması (MJ/m^2)
- H_o : atmosfer öncesi günlük GSR (MJ/m^2)
- I : YSA girdi parametreleri sayısı
- k : veri sayısı
- k_t : açıklık indeksi
- n : gün içi güneşlenme süresi (h)
- N : gün içi maksimum güneşlenme süresi (h)
- NET : sinir hücrelerinin net girdisi
- nGun : yılın günü (1..366)
- NN : gizli katman nöron sayısı
- nN : gün içi güneşlenme süresinin maksimum güneşlenme süresine oranı
- O : YSA çıktı parametreleri sayısı

- PM₁₀ : partikül madde 10 ($\mu\text{g}/\text{m}^3$)
- R : korelasyon katsayısı
- R² : determinasyon katsayısı
- R_{hum} : nem
- R_{km} : rakım
- S : YSA eğitim seti veri sayısı
- SinD : deklinasyon açısının sinüsü
- SO₂ : kükürt dioksit ($\mu\text{g}/\text{m}^3$)
- T_{avg} : ortalama günlük sıcaklık ($^{\circ}\text{C}$)
- T_{max} : maksimum günlük sıcaklık ($^{\circ}\text{C}$)
- T_{min} : minimum günlük sıcaklık ($^{\circ}\text{C}$)
- T_s : ortalama günlük toprak sıcaklığı ($^{\circ}\text{C}$)
- ÜS : üst sınır
- w_{ij} : i ve j sinir hücreleri arasındaki bağlantı ağırlığı
- WS : rüzgâr hızı (m/s)
- w_{ss} : gün batımı saat açısı
- x : YSA parametreleri için orijinal değerler
- x' : YSA parametreleri için normalize edilmiş değerler
- x_i : i sinir hücresinin çıktısı
- x_{max} : YSA parametreleri için maksimum değerler
- x_{min} : YSA parametreleri için minimum değerler
- δ : deklinasyon açısı
- θ_j : eşik değeri
- μ : kombinasyon katsayısı

KISALTMALAR

- ANN : Artificial Neural Network (Yapay Sinir Ađı)
- ÇRLM : Çevre Referans Laboratuvarı Merkezi
- GSR : Global Solar Radiation (Global Güneş Işınım Şiddeti)
- LM : Levenberg–Marquardt
- MAE : Mean Absolute Error (Ortalama Mutlak Hata)
- MAPE : Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
- MGM : Meteoroloji Genel Müdürlüğü
- MLP : Multilayer Perceptron (Çok Katmanlı Algılayıcı)
- MSE : Mean Square Error (Hata Kareleri Ortalaması)
- RBF : Radial Basis Function (Radyal Tabanlı Fonksiyon)
- RMSE : Root Mean Square Error (Hata Kareleri Ortalamasının Karekökü)
- SQL : Structured Query Language (Yapısal Sorgulama Dili)
- YSA : Yapay Sinir Ađı

BÖLÜM 1

GİRİŞ

Dünyada enerji ihtiyacının karşılanması konusunda önemli ölçüde bağımlılığın olduğu fosil yakıtlar, tükenebilir ve çevre kirliliğine sebep olmalarının yanı sıra, giderek daha pahalı hale gelmektedirler [1]. Günümüzde ve gelecekte sürdürülebilir bir ortam sağlama potansiyeline sahip olan yenilenebilir enerji kaynakları ise hem fosil yakıtlara olan bağımlılığın hem de çevre kirliliğinin azaltılmasına katkı sağlayacaklardır. Güneş enerjisi, potansiyeli oldukça yüksek, sistem maliyetleri diğer enerji kaynaklarına göre oldukça düşük çevre dostu önemli bir yenilenebilir enerji kaynağıdır.

Güneş enerjisi ile ilgili yapılan çalışmalar, ağırlıklı olarak aşağıdaki beş alanın araştırılmasına odaklanmıştır [2]:

- a. Fotovoltaik termal veya güneş kolektör sistemlerinin verimliliğinin artırılması
- b. Tek veya hibrid enerji dönüşüm sistemlerinden faydalanarak güneş enerjisi tabanlı elektrik üretim sistemleri
- c. Güneş enerjili sistemler kullanarak hidrojen üretimi
- d. Sürdürülebilir enerji binaları veya sıfır enerji için güneş enerjisi kullanımı
- e. Endüstriyel uygulamalar için güneş enerjisi kullanımının fizibilitesi

Herhangi bir bölgede yukarıda belirtilen çalışmaların yapılabilmesi için, ilgili bölgenin GSR potansiyelinin bilinmesi önemlidir. Bu potansiyel GSR tahmin modelleri ile ortaya çıkarılabilmektedir. Literatürde GSR tahmin modelleri kabaca üç farklı gruba ayrılabilir. Birinci grup tahmin modelleri deneysel modellerdir. Bu modeller genellikle birkaç ölçülebilir güneş ışınımı parametresinden oluşmakta ve kolayca kullanılabilirlerdir. İkinci gruptaki modeller, karmaşık coğrafi ve meteorolojik parametrelere gereksinim duyan ışımsal transfer modelleridir. Bu matematiksel modeller önemli ölçüde doğru çıktılar vermektedir. Ancak bu modeller için karmaşık

hesaplamalara ve her yerde bulunamayan bazı sayısal girdi parametrelerine ihtiyaç duyulduğundan dolayı sınırlı olarak kullanılabilirler. Üçüncü gruptaki modeller ise YSA modelleridir. Bu modellerde önceki iki grubun sahip olduğu basitlik ve doğruluk özellikleri birleştirilmeye çalışılmıştır. YSA modelleri güvenilir bir hata oranı ile daha doğru sonuçlar vermektedir [3]. Bu modellerde enlem, boylam, rakım, güneşlenme süresi, minimum sıcaklık, ortalama sıcaklık, maksimum sıcaklık, nem, rüzgâr hızı gibi çeşitli coğrafi ve meteorolojik değişkenler girdi olarak kullanılmıştır.

Ayrıca, canlıların sağlıklı olarak hayatlarını sürdürebilmeleri için temel unsurların başında yaşadıkları çevredeki hava kalitesi gelmekte ve hava kalitesindeki azalma hava kirliliği olarak adlandırılmaktadır. Hava kirliliği, havadaki yabancı maddelerin canlı sağlığını olumsuz yönde etkileyecek şekilde normal değerlerinin üzerindeki bir miktar ve yoğunluk seviyesine ulaşmasıdır.

İnsanların üretim ve tüketim faaliyetleri sonucunda ortaya çıkan zararlı atıklar yaşadığımız hava tabakasının kirlenmesine sebep olurken, insan sağlığını ve diğer canlıların yaşamlarını tehlikeye sokmaktadır. Özellikle insan faaliyetleri sonucunda atmosfere salınan başta CO₂ olmak üzere, CH₄, N₂O gibi sera gazları dünyadan yayılan uzun dalgalı ışınları tuttuğundan, tutulan bu enerji atmosferin alt kısımlarını ısıtır. Bu ısınma atmosferin sera etkisi olarak ortaya çıkmaktadır [4].

Sera gazlarının olumsuz etkileri sebebi ile dünyada iklim değişikliği meydana gelmektedir. Dolayısı ile alternatif enerji kaynakları kullanım oranının artırılması gerekmektedir. Alternatif enerji kaynaklarından olan güneş enerjisinden maksimum seviyede faydalanma noktasında hava kirliliği olumsuz bir unsur olarak karşımıza çıkmaktadır.

Bu çalışmada, hava kirleticilerden PM₁₀ ve SO₂ ile meteorolojik ve coğrafi parametrelerin GSR tahmin performansına olan etkilerinin incelenmesi amaçlanmaktadır. Bu faktörlerin etkilerini incelemek üzere farklı veri setleri oluşturulmuş ve farklı YSA modelleri geliştirilmiştir. Geliştirilen modeller, test verileri kullanılarak birbirleri ile kıyaslanarak elde edilen sonuçlar paylaşılmıştır. Literatürden farklı olarak bir konuma ait GSR tahmininde, bu konuma ait çevre 3

istasyona ait GSR verilerinin de girdi olarak kullanılmasının tahmin performansını nasıl etkilediđi araştırılmıřtır. Bu alıřmada kullanılan veriler Orman ve Su İřleri Bakanlıđı kurumlarından Meteoroloji Genel Mdrlđ (MGM) ve evre ve Őehircilik Bakanlıđı'na bađlı evre Referans Laboratuvarı Merkezinden (RLM) alınmıřtır.

alıřmanın ikinci blmnde, literatrdeki aylık ve gnlk GSR tahmin alıřmaları hakkında bilgi verilmiřtir. nc blmde, GSR modellemesinde sıklıkla kullanılan YSA'ları hakkında genel bir bilgilendirme yapılmıřtır. alıřmada kullanılan veriler, bu verilerin nasıl dzenlendiđi, geliřtirilen modellerin neler olduđu, farklı girdi kombinasyonlarına ait model sonularının elde edilmesi iin kullanılan algoritma "Materyal ve Metot" bařlıđı altında drdnc blm olarak dzenlenmiřtir. Son olarak beřinci ve altıncı blmlerde ise bu tez alıřması ile elde edilen sonu ve bulgular paylařılarak tartıřılmıř, literatrdeki diđer alıřmalarla karřılařtırılmıř ve gelecekte yapılabilecek alıřmalar hakkında nerilere yer verilmiřtir.

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

Bir konum için GSR tahmini yapmak üzere pek çok çalışma yapılmıştır. Bu çalışmalar genellikle tahmin performansını artırmak üzerine odaklanmıştır. Yeni yaklaşımlar geliştirilmiş, farklı yöntemler birbirleri ile karşılaştırılmıştır [5–17]. Literatürde genel olarak GSR tahminini gerçekleştirmek için ampirik, regresyon, YSA, bulanık mantık, genetik programlama modelleri gibi çeşitli yöntemler kullanılmaktadır.

Çizelge 2.1 ve Çizelge 2.2’de Malezya’da 5 bölge için yapılan çalışma sonucunda global ve difüz güneş ışınım şiddetlerinin tahmininde farklı yöntemlerin performansları gösterilmiştir [18].

Çizelge 2.1. GSR tahmininde MAPE, RMSE ve MBE ortalamaları.

Model	MAPE	RMSE	%RMSE	MBE	%MBE
Lineer model	8,13	0,44	9,32	-0,014	-0,30
Lineer olmayan model	6,93	0,41	8,73	-0,013	-0,31
Bulanık mantık modeli	6,71	0,42	8,80	0,019	0,32
YSA modeli	5,38	0,35	7,37	-0,019	-0,42

Çizelge 2.2. Difüz güneş ışınım şiddeti tahmininde MAPE, RMSE ve MBE ortalamaları.

Model	MAPE	RMSE	%RMSE	MBE	%MBE
Lineer model	4,35	0,146	5,22	0,003	0,094
Lineer olmayan model	3,74	0,136	4,85	0,003	0,090
YSA modeli	1,53	0,056	2,01	-0,0009	-0,062

Global ve difüz güneş ışınım şiddetlerinin tahmininde diğer yöntemlere göre kıyaslandığında, Malezya’da yapılan bu çalışmada olduğu gibi, en iyi sonuçlar farklı

arařtırmacılar tarafından da YSA modelleri ile elde edilmiřtir [5–10, 19]. Bařarılı bir yntem olduėundan dolayı, mevcut tez alıřmasında YSA kullanılmıř ve bu blmde, aylık ve gnlk GSR tahmini iin literatrde YSA modellerinin geliřtirildiėi alıřmalara yer verilmiřtir.

Őenkal tarafından 2010 yılında yapılan alıřmada, aylık GSR deėerini tahmin etmek zere Enl, Byl, Rkm, iki tip emisivite ve T_s parametrelerinin girdi olarak kullanıldıėı bir YSA modeli geliřtirilmiřtir. Test verileri iin R ve RMSE deėerleri sırası ile 0,9341 ve 0,32 olarak elde edilmiřtir [20].

Jiang vd. (2015) tarafından yapılan alıřmada, T_{avg} , T_{max} , T_{min} , R_{hum} gibi 12 meteorolojik parametre girdi olarak kullanılmıřtır. Radyal tabanlı fonksiyon (RBF) kullanılan sinir aėı oklu lineer regresyon problemine dnřtrlerek aylık GSR tahmini yapılmıřtır. MAPE deėerleri 5,44 ve 7,64 aralıėında ve RMSE deėerleri ise 1,01 ve 1,42 aralıėında elde edilmiřtir [21].

Elminir vd. 2001 yılına ait llmř GSR deėerlerini kullanarak eėittikleri YSA modeli ile 2002 yılı lmlerini test etmiřlerdir. Geliřtirilen model sonu olarak, test veri setinde %96 oranında doėru tahminde bulunmuřtur [22]. Mellit vd. 2005 yılında yaptıkları alıřmada GSR verilerini YSA ve Markov geiř matrisleri arasında birleřtirerek tahmin etmek zere hibrid bir model geliřtirmiřlerdir. Bu modelde Cezayir’de bulunan 60 farklı meteoroloji istasyonuna ait 1991–2000 yılları arasındaki GSR verilerini kullanmıřlardır. Elde edilen sonulara gre R deėeri 0,90-0,92 aralıėında gerekleřmiřtir [23]. Tymvios vd. Ångstrm eřitlikleri ve YSA modellerini kullanarak GSR deėerlerini tahmin etmeye alıřmıřlardır [19]. Szen vd. 2005 yılında YSA modelleri ile aylık GSR tahmini yapmıřlardır. 2000-2003 yılları arasındaki 9 istasyona ait verileri eėitim seti; 3 istasyona ait verileri ise test seti olarak kullanmıřlardır. R ve MAPE deėerleri sırası ile 0,9972-0,9989 ve 3,63-6,78 aralıėında gerekleřmiřtir [24].

Rehman ve Mohandes (2008), Suudi Arabistan Abha řehrinde 1998 ve 2002 yılları arasında llmř olan hava sıcaklıėı ve baėıl nem deėerleri ile YSA yntemini kullanarak GSR deėerini tahmin etmeye alıřmıřlardır. GSR tahmini  farklı veri seti

üzerinde yapılmıştır: (i) Girdiler: Yılın günü ve günlük maksimum hava sıcaklığı, Çıktı: GSR. (ii) Girdiler: Yılın günü ve günlük ortalama hava sıcaklığı, Çıktı: GSR. (iii) Girdiler: Yılın günü, günlük ortalama hava sıcaklığı ve bağıl nem, Çıktı: GSR. 1998 ve 2001 yıllarına ait veriler eğitim için, 2002 yılına ait 240 günlük veri ise test için kullanılmıştır. Yılın günü, günlük ortalama hava sıcaklığı ve bağıl nem değerlerinin girdi olarak kullanıldığı durumda en düşük MAPE ile GSR tahmin edilmiştir [25].

Azadeh vd. (2009), iklimsel değişkenler ile GSR değerinin tahmini için bir entegre YSA yaklaşımı geliştirmişlerdir. Geliştirilen YSA modeli, en düşük MAPE değerine sahip çok katmanlı algılayıcı (MLP) ile verileri eğitip test etmektedir. Uygulama için 1995 ve 2000 yılları arasında İran'daki altı şehre ait aylık veriler toplanmıştır. Geliştirilen model %94 doğruluk ile GSR değerlerini tahmin etmiştir [3].

Ozgoren vd. (2012), yaptıkları çalışmada Türkiye'de herhangi bir yer için aylık ortalama günlük GSR değerini tahmin etmek üzere çoklu doğrusal olmayan regresyon modeline dayalı bir YSA modeli geliştirmeyi amaçlamışlardır. Çalışmada 2000-2006 yıllarına ait 31 istasyondan toplanan meteorolojik verilerden faydalanılmıştır. 27 istasyona ait olan veriler eğitim sırasında ve 4 istasyona ait olan veriler ise test esnasında kullanılmıştır. YSA ile elde edilen sonuçlar gerçek veriler ile karşılaştırıldığında MAPE %5,34 ve R ise 0,9936 olarak bulunmuştur [26].

Alvaro vd. (2013), günlük GSR ile ilgili güncel literatürdeki sonuçlarda iyileştirme yapacak şekilde, YSA ve uydudan elde edilmiş ışınım değerleri aracılığı ile günlük GSR değerinin mekânsal tahmini için yeni bir yöntem geliştirmeyi amaçlamışlardır. Burada iki önemli iyileştirme elde edilmiştir: 1) YSA topluluk modeli optimizasyon prosedürü 2) Meteosat kanallarındaki ek bilgilerin kullanımı. Çalışmada Endülüs bölgesi (87000km²) 2008 yılına ait açık hava tahminleri ve uydu görüntüleri kullanılmıştır. 83 istasyondan 65'ine ait veriler ile YSA eğitilmiştir, 18'ine ait veriler ise ağın testinde kullanılmıştır. Çalışma, YSA ve YSA topluluk modelleri ile gerçekleştirilmiştir. YSA topluluk modelini ise en iyi sonucu veren 5 YSA modelinin birleştirildiği model olarak tanımlamışlardır. YSA topluluk modeline ait RMSE

değerleri eğitim verilerinde 1,24 ve test verilerinde ise 1,25 olarak gerçekleşmiştir [27].

Amrouche ve Le Pivert (2014) tarafından yapılan çalışmada, yüzeydeki GSR tahmini için yeni bir YSA tabanlı model geliştirilmiştir. Çalışmada, iki tür veri kullanılmıştır. Birincisi, iki konum için bir yıl boyunca 5'er dakika ara ile yapılan ölçümler ve ikincisi ise Ulusal Okyanus ve Atmosfer İdaresi tarafından sağlanan dünya üzerinde ağ şeklinde yapılan hava tahminleridir. Tahmin yapılacak iki konuma en yakın 4 ağ kesişim noktası için yapılan sıcaklık ve GSR tahminleri, ilgili konumun GSR tahmininde girdi olarak kullanılmıştır. Geliştirilen modelin testinde en düşük RMSE değeri 33,1 W/m² olarak elde edilmiştir [28].

Mohandes vd. (1998) GSR'ni modellemek üzere girdi olarak enlem, boylam, rakım ve güneşlenme süresi verilerini kullanmışlardır. Geri yayılım algoritmasının kullanıldığı çok katmanlı ileri beslemeli bir YSA oluşturulmuştur. Geliştirilen YSA'nda girdi katmanında 4, gizli katmanda 10 ve çıktı katmanında 1 nöron bulunmaktadır. Test istasyonlarında MAPE değerleri 6,5-19,1 arasında elde edilmiştir [29].

Şenkal ve Kuleli (2009) Türkiye'de 12 şehir için enlem, boylam, rakım, ay, ortalama difüz ışınım şiddeti ve ortalama direkt ışınım şiddeti verilerini kullanarak GSR değerlerini tahmin etmeyi amaçlamışlardır. Bu amaçla çok katmanlı YSA modeli ve fiziksel model geliştirmişlerdir. 9 şehir eğitim için, 3 şehir ise test için kullanılmıştır. Geliştirilen modeller için RMSE değerleri Çizelge 2.3'te gösterildiği gibi elde edilmiştir [30].

Çizelge 2.3. Geliştirilen modeller için RMSE değerleri.

Model	RMSE (Eğitim verileri)	RMSE (Test verileri)
Çok katmanlı YSA modeli	2,32	3,94
Fiziksel model	2,75	5,37

Koca vd. (2011) GSR'ni tahmin etmek üzere Akdeniz bölgesinde enlem, boylam, rakım, ay, ortalama sıcaklık, ortalama bulutluluk, ortalama rüzgâr hızı ve güneşlenme süresi girdilerinin altı farklı kombinasyonun kullanıldığı YSA modelleri

geliştirmişlerdir. Girdi parametrelerinin sayısının, GSR tahmininde R^2 değerini etkilediği sonucuna varmışlardır [31].

Behrang vd. (2010) günlük GSR'ni modellemek için yılın günü, günlük ortalama sıcaklık, nem, güneşlenme süresi, buharlaşma ve rüzgâr hızı verilerini girdi olarak kullanmışlardır. İran'da Dezful şehrine ait 2002-2006 yılları arasındaki verileri kullanarak MLP YSA ve RBF YSA modellerini geliştirmişlerdir. 2002-2005 arasındaki verileri eğitim seti, 2006 yılına ait 214 günlük veri ise test seti olarak kullanılmıştır. Rüzgâr hızı, yılın günü, günlük ortalama sıcaklık, nem ve güneşlenme süresi girdilerinin kullanıldığı MLP ağı diğer YSA modellerine göre daha iyi sonuç vermiştir. En iyi sonucu veren MLP ağında MAPE değeri %5,21 ve R^2 değeri %99,57 olarak elde edilmiştir [32].

Al-Alawi ve Al-Hinai (1998) GSR'ni tahmin etmek üzere ay, ortalama basınç, ortalama sıcaklık, ortalama buhar basıncı, ortalama nem, ortalama rüzgâr hızı ve ortalama güneşlenme süresi verilerini girdi olarak kullanmışlardır. Geri yayılım algoritmasının kullanıldığı çok katmanlı ileri beslemeli bir YSA modeli geliştirilmiştir. MAPE değeri 5,43-7,30 aralığında elde edilmiştir [33].

Rahimikhoob 2010 yılında yaptığı çalışmada 1994 ve 2001 yılları arasındaki H_o , T_{max} ve T_{min} meteorolojik verileri kullanarak günlük GSR tahmini için YSA modeli geliştirmiştir. Test verileri üzerinde elde edilen R^2 ve RMSE değerleri sırası ile 0,845-0,889 ve 2,53-2,55 aralığında gerçekleşmiştir [34].

Landeras vd. (2012), GSR tahmini için ampirik eşitlikler, YSA, ANFIS ve gen ifade programlama sistemlerini karşılaştırmışlardır. nGun, H_o , T_{max} , T_{min} ve açık hava ışınımı girdilerinin kullanıldığı YSA modeli, test verileri üzerinde 2,93 RMSE değeri ile en iyi sonucu veren yöntem olmuştur [7].

Ramedani vd. günlük GSR tahmini yapmak amacıyla bulanık lineer regresyon ve destek vektör regresyonu yöntemlerini karşılaştırmıştır. Çalışmada nGun, H_o , n, N, T_{max} , T_{min} ve açık hava ışınımı faktörleri girdi olarak kullanılmıştır. Destek vektör regresyonu modelleri olarak RBF ve polinom fonksiyonunun kullanıldığı modelleri

geliştirmişlerdir. Yöntemler birbiri ile karşılaştırıldığında RBF kullanılan destek vektör regresyonu en iyi sonucu vermiştir. İlgili model, test verilerinde R ve RMSE değerlerini sırası ile 0,889 ve 3,3 olarak vermiştir [35].

Mohammadi vd. (2015) tarafından yapılan çalışmada günlük GSR tahmini için destek vektör makinesi, YSA, genetik programlama ve otoregresif hareketli ortalamalar yöntemleri karşılaştırılmıştır. H_o , nN , $T_{max}-T_{min}$, T_{avg} , R_{hum} ve su buhar basıncı parametrelerinin girdi olarak kullanıldığı YSA modelinin test aşamasında MAPE değeri 9,31 ve RMSE değeri 1,84 olarak elde edilmiştir [36].

Yadav ve Chandel 2014 yılında yaptıkları çalışmada, gelecek araştırmalar için GSR tahmininde girdi parametrelerinin etkisinin dikkate alınması ve ölçüm yapılmayan bölgeler için farklı YSA modelleri geliştirilmesi gerektiğini belirtmişlerdir [37]. Bu tez çalışmasında literatürde GSR tahmininde sıklıkla kullanılan ve genel olarak başarılı sonuçlar üreten YSA modelleri kullanılmıştır. Hava kirletici, coğrafi ve meteorolojik parametrelerin GSR tahmini üzerindeki etkileri incelenmiştir. Literatürden farklı olarak, bir konuma ait GSR tahmini yapılırken üç çevre istasyonun ölçülmüş GSR verilerinin girdi olarak eklenmesinin tahmin performansını nasıl etkileyeceğini ortaya koymak için çevre istasyon verilerinin eklendiği ve eklenmediği farklı YSA modelleri geliştirilmiştir. Aylık GSR tahminde üç çevre istasyonun GSR verisi üç farklı girdi olarak modele dahil edilmiştir. Günlük GSR tahmininde ise üç çevre istasyonun GSR verisini ayrı ayrı eklemek yerine bu verilerin ortalama değerlerinin hesaplanarak tek girdi olarak eklendiği modeller geliştirilmiştir. Son olarak bu modellerin sonuçları birbiri ile kıyaslanmıştır.

BÖLÜM 3

YAPAY SİNİR AĞLARI

Günümüzde teknolojik gelişmeler çok hızlı bir şekilde artarken, insanın düşünebilme, öğrenebilme ve karar verme yeteneklerini nasıl gerçekleştirdiğine dair araştırmalar da yapılmaktadır. Bilgisayarlar, insanlara göre rutin işlemleri çok hızlı bir şekilde gerçekleştirebilmektedir. Ancak, herhangi bir durum hakkında çıkarım yapma, yorumlama ve karar verme işlemlerini gerçekleştiremezler. İşte bu noktada, insan zekâsının bilgisayarlar tarafından taklit edilebilmesini sağlayan bu çalışmalar bütününe Yapay Zekâ denmektedir.

Yapay Zekâ teknolojilerinden birisi de insan beyninin çalışmasını taklit eden YSA teknolojisidir. Biyolojik sinir sistemi YSA ile modellenmektedir. Bir YSA, birbiri ile bağlanmış sinir hücrelerinden oluşur ve öğrendiğini hafızada tutma ve faktörler arasındaki ilişkiyi belirleme yeteneğine sahiptir. YSA ile insanın zihinsel yeteneklerinin kullanılmasını gerektiren problemlerin çözülmesi amaçlanmaktadır.

Sinir hücreleri arasındaki sinaptik bağlantılar ayarlanarak, biyolojik sistemlerde öğrenme gerçekleşir. İnsan beyni yaşayıp tecrübe edinerek bir öğrenim süreci yaşar. Bu süreç içinde beyin sürekli gelişerek hücreler arasındaki sinaptik bağlantılar ayarlanır. Benzer durum YSA'nda da gerçekleşmektedir. YSA eğitim algoritması, örnek veri setlerini işleyerek belirlenen kısıtlar altında öğrenme gerçekleşene kadar hücreler arası bağlantı ağırlıklarını sürekli değiştirir. YSA modelleri eğitim sonrasında kendisine hiç gösterilmeyen farklı veri setleri için çıkarımda bulunabilir.

YSA modellerinin genel özellikleri aşağıda sıralanmıştır [38]:

- a. Makine öğrenmesini sağlarlar.
- b. Geleneksel programlama yöntemlerine benzemezler.

- c. Bilgi bağlantı ağırlıklarında saklanır.
- d. Örnekler ile öğrenme gerçekleştirirler.
- e. Önce eğitilmeli ve performansları test edilmelidir.
- f. Eğitimden sonra görülmeyen örnekler hakkında çıktı üretebilirler.
- g. İlişkilendirme ve sınıflandırma için kullanılabilirler.
- h. Yeni durumlara adapte olarak öğrenmenin sürekliliği mümkündür.
- i. Bilgiler eksik olsa da çalışabilirler.
- j. Bilgiler ağı yayıldığı için dağıtık belleğe sahiptirler.
- k. Girdi ve çıktıların sayısal olarak ifade edilmesi gerekmektedir.

3.1. YSA TARİHÇESİ

YSA tarihçesi, nörobiyoloji konusuna olan ilginin artması ve elde edilen sonuçların bilgisayar bilimine uygulanması ile başlamaktadır. YSA tarihçesi 1970 öncesi ve sonrası yapılan çalışmalar şeklinde ikiye ayrılabilir. 1970'ten sonra çözülemeyen problemler çözüme kavuşmaya başlamış ve YSA tekrardan doğmuştur [38]. YSA'nın gelişiminde önemli yeri olan bazı çalışmalar aşağıda listelenmiştir [38–41]:

1943: McCulloch ve Pitts, biyolojik sinir hücresinin basit matematiksel modelini geliştirerek ilk yapay sinir hücresini oluşturdu. Sinir hücrelerinin birbirleri ile senkronize çalıştığını ortaya koymuşlardır.

1949: Psikolog Donald Hebb, "The Organization of Behaviour" isimli kitabında, yapay hücrelerden oluşan bir YSA'nın ağırlık değerlerini geliştiren bir öğrenme kuralını açıklamıştır. Hebb Öğrenme Kuralı olarak adlandırılan bu kural, günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır.

1958: Rosenblatt tarafından yeni bir danışmanlı öğrenme metodu olan algılayıcı (perceptron) modeli geliştirilmiştir. Tek katmanlı bu algılayıcı model, YSA modellerinin gelişiminde önemli bir aşama olan MLP'lerin temelini oluşturmuştur.

1959 ve 1962: Widrow ve öğrencisi Hoff, ADALINE (Adaptive Linear Elements) ve MADALINE (Multiple Adaptive Linear Elements) olarak isimlendirdikleri

algılayıcıya benzeyen iki modelde en küçük ortalama kareler algoritmasını kullanmışlardır.

1969: Minsky ve Papert, yaptıkları çalışmaları “Perceptrons (Algılayıcılar)” isimli kitapta toplamışlardır. Algılayıcıların bilimsel bir değerinin olmadığı iddiasını ortaya atmışlar ve bu durumu ispatlamak için XOR mantık probleminin çözülemediğini göstermişlerdir. Bu noktadan itibaren YSA ile ilgili çalışmalar duraklama dönemine girmiştir. Fakat bazı bilim adamları bu alandaki çalışmalarına devam etmişlerdir.

1970 ve 1980’li yıllar: Özellikle Anderson, Kohonen, Grossberg, Carpenter, Fukushima, Hopfield ve Rumelhart gibi araştırmacıların yaptıkları çalışmalar YSA tarihçesinde bir dönüm noktası oluşturmuştur. Rumelhart vd. ileri beslemeli YSA modelleri için yeni bir öğrenme modeli olan hatanın geriye yayılma algoritmasını geliştirmişlerdir. Böylelikle, tek katmanlı algılayıcının çözemediği XOR problemi, MLP’ler ile çözülebilmıştır. Yapılan bu çalışmalar YSA’larına olan ilgiyi artırmıştır.

1985: Amerikan Fizik Enstitüsü tarafından “Bilgi İşleme İçin Sinir Ağları” isimli yıllık toplantılar yapılmaya başlanmıştır.

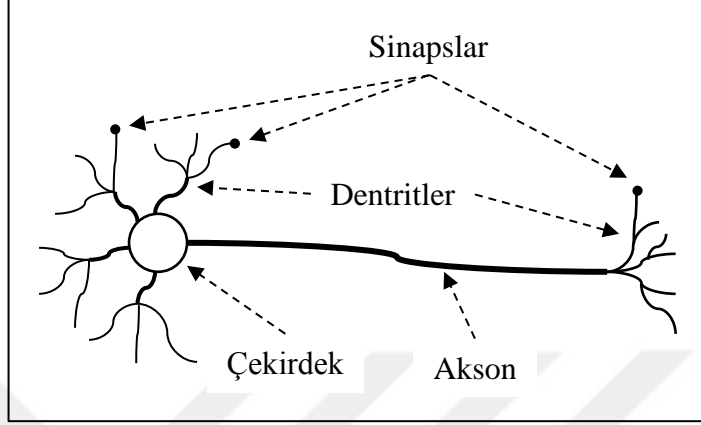
1987: Elektrik ve Elektronik Mühendisleri Enstitüsünün (IEEE) düzenlediği 1. Uluslararası Sinir Ağları Konferansında 1800’den fazla katılımcı çalışmalarını paylaşmıştır.

Günümüzde, YSA ile ilgili çalışmalar yaygın bir şekilde yapılmaktadır. Bilgisayar donanım teknolojisinin de sürekli olarak gelişim göstermesi ile YSA uygulamalarının yapılması daha kolay hale gelmiştir. [38, 41].

3.2. BİYOLOJİK SİNİR SİSTEMİ

Bir sinir ağı insan beynine dayalı bir mantık modeli şeklinde tanımlanabilir. İnsan beyni yoğun bir şekilde birbirine bağlı sinir hücrelerinden oluşmaktadır. İnsan beyninin yaklaşık olarak 10 milyar sinir hücresi ve bu hücreler arasındaki 60 trilyon bağlantıdan oluştuğu tahmin edilmektedir. Bu çoklu sinir hücreleri eş zamanlı olarak

çalışarak, en hızlı bilgisayardan daha hızlı bir şekilde beynin fonksiyonlarını yerine getirmesini sağlamaktadır. Şekil 3.1’de 4 farklı parçadan oluşan tipik bir biyolojik sinir hücresi gösterilmektedir [42].



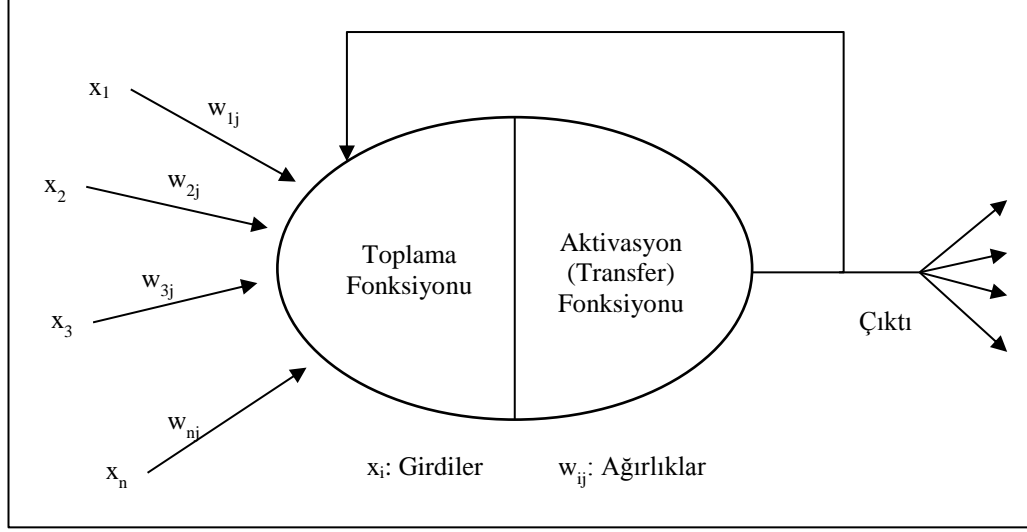
Şekil 3.1. Tipik bir biyolojik sinir hücresi.

Sinapslar sinir hücreleri arasındaki bağlantıyı sağlamaktadır. Aslında bu bağlantılar bir sinir hücresinden diğerine elektrik sinyallerin aktarıldığı boşluklardır. Bu sinyaller çekirdeğe gönderilir, burada işlendikten sonra sinir hücresi kendine ait elektrik sinyalini oluşturur ve akson üzerinden dentritlere iletilir. Daha sonra bu sinyaller sinapslar ile diğer bağlantılı sinir hücrelerine taşınır [38].

3.3. YAPAY SİNİR HÜCRESİ

Biyolojik sinir sisteminde sinir hücreleri olduğu gibi YSA modellerinde de yapay sinir hücreleri bulunmaktadır. Bu hücreler işlem elemanları olarak da isimlendirilmektedir [38]. Bu hücreler birbirlerine bağlanarak YSA'nı oluşturur. Şekil 3.2’de bir sinir hücresinin yapısı verilmiştir [41].

Bir sinir hücresi girdi bağlantıları üzerinden gelen sinyalleri alır, toplama ve aktivasyon fonksiyonları ile bir çıktı sinyali üretir. Hücreye gelen sinyal dışarıdan gelen bir bilgi olabileceği gibi diğer hücrelerden gelen bir sinyal de olabilir. Çıktı sinyali ise problemin son çözümü veya diğer hücrelere iletilen bir sinyaldir [42].



Şekil 3.2. Bir yapay sinir hücresinin yapısı [43].

Her bir yapay sinir hücresi, girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere 5 bileşenden oluşmaktadır [38]. Bu bileşenler aşağıdaki gibi açıklanabilir:

3.3.1. Girdiler

Hücreye dışarıdan veya diğer hücrelerden gelen sinyallerdir. Bir hücre genel olarak aynı anda çok sayıda girdi alabilmektedir.

3.3.2. Ağırlıklar

Bağlantı ağırlık değerleri, hücreye giren sinyalin önemini ve hücre üzerindeki etkisini gösterirler. Şekil 3.2’de w_1 ağırlığı, x_1 girdisinin bu hücre üzerindeki etkisini temsil etmektedir. Ağırlık değerinin sıfırdan büyük veya küçük olması o girdinin etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise ilgili girdinin hücre üzerinde herhangi bir etkisinin olmadığını göstermektedir. Bağlantı ağırlık değerlerinin büyük veya küçük olması önemli veya önemsiz olduğunu göstermez.

3.3.3. Toplama (Birleştirme) Fonksiyonu

Toplama fonksiyonu, bir hücreye dışarıdan gelen sinyallere ait net girdiyi hesaplamaktadır. Bunun için farklı fonksiyonlar kullanılmaktadır. Ancak yaygın olarak kullanılan ağırlıklı toplamın hesaplandığı fonksiyondur [38]. Burada hücreye gelen her girdi sinyali kendi ağırlığı ile çarpılarak toplanır. Böylece hücreye gelen net girdi hesaplanır [39].

$$NET = \sum_{i=1}^n w_{ij}x_i + \theta_j \quad (3.1)$$

Eşitlik 3.1’de ifade edilen toplama fonksiyonunda;

- NET : sinir hücresinin net girdisini,
w_{ij} : i ve j sinir hücreleri arasındaki bağlantının ağırlığını,
x_i : i sinir hücresinin çıktısını,
θ_j : eşik değerini ifade etmektedir.

Ancak YSA modellerinde her zaman ağırlıklı toplam fonksiyonunun kullanılması zorunlu değildir. Çizelge 3.1’de literatürde yapılan araştırmalarda kullanılan diğer farklı toplama fonksiyonları verilmektedir [38].

Çizelge 3.1. Toplama fonksiyonu örnekleri [38].

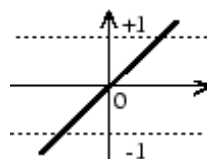
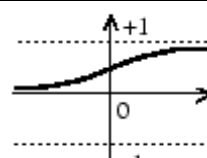
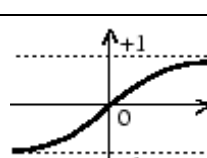
Çarpım	$NET = \prod_i w_{ij}x_i$
Minimum	$NET = \min(w_{ij}x_i)$
Maksimum	$NET = \max(w_{ij}x_i)$
Çoğunluk	$NET = \sum_i \text{sgn}(w_{ij}x_i)$

Tüm hücreler için aynı toplama fonksiyonu kullanılabilceği gibi farklı fonksiyonlar da kullanılabilir. Hangi toplama fonksiyonunun kullanılacağını belirlemesi tasarımcının kendi öngörüsü ile vereceği karara bağlıdır.

3.3.4. Aktivasyon Fonksiyonu

Toplama fonksiyonu ile hesaplanan net girdiyi işledikten sonra bu hücrenin vereceği çıktıyı belirleyen fonksiyon aktivasyon fonksiyonudur. Farklı toplama fonksiyonları bulunduğu gibi, aktivasyon fonksiyonlarında da farklı formüller kullanılabilir. Hücrelerin tümünde aynı aktivasyon fonksiyonunun kullanılması zorunlu değildir. Uygun fonksiyon tasarımcının yapacağı denemeler ile belirlenir. Çizelge 3.2’de literatürdeki bazı aktivasyon fonksiyonları verilmiştir. Günümüzde yaygın olarak kullanılan MLP modellerinde aktivasyon fonksiyonu olarak sigmoid veya hiperbolik tanjant fonksiyonları tercih edilmektedir.

Çizelge 3.2. Bazı aktivasyon fonksiyonları [43].

Aktivasyon Fonksiyonu	Matematiksel Gösterimi	Grafiksel Gösterimi
Lineer Fonksiyon	$F(NET) = NET$	
Sigmoid Fonksiyonu	$F(NET) = \frac{1}{1 + e^{-NET}}$	
Hiperbolik Tanjant Fonksiyonu	$F(NET) = \frac{e^{NET} + e^{-NET}}{e^{NET} - e^{-NET}}$	

3.3.5. Hücrenin Çıktısı

Aktivasyon fonksiyonu hesaplanmış olan çıktı değeridir. Üretilen çıktı, problemin çözümü olabileceği gibi başka hücrelere gönderilen bir sinyal de olabilir. Hücre kendi


çıktısını kendisine girdi olarak da gönderebilir. Aslında bir sinir hücresi tek bir çıktı üretir. Aynı çıktı değeri bir veya birden fazla hücreye girdi olarak gönderilmektedir.

3.4. YSA MODELLERİNİN GENEL YAPISI

Yapay sinir hücreleri belli bir düzen içinde birleşerek YSA'nı oluştururlar. Bu düzen hücrelerin katmanlar halinde gruplandırılması ile gerçekleştirilmektedir. Genellikle YSA modelleri üç katmandan oluşmaktadır. Girdi katmanında yer alan hücreler dışarıdan verilerin ağı alınmasını sağlar. Çıktı katmanındaki hücreler ise, ağ ile elde edilen sonuçların dışarıya verilmesinde kullanılır. Diğer hücreler ise, gizli katmanda yer alır [38, 39].

Şekil 3.3'te 3 katmandan oluşan bir YSA modeli gösterilmektedir. Bu katmanlar kısaca aşağıdaki gibi açıklanabilir:

Girdi Katmanı: Bu katmandaki sinir hücreleri, dışarıdan gelen bilgileri alırlar ve gizli katmandaki hücrelere iletirler. Bazı ağlarda girdi katmanında herhangi bir işlem yapılmaz. Sadece dışarıdan alınan girdileri sonraki katmana aktarırlar.



Şekil 3.3. Bir YSA modeli.

Gizli (Ara) Katman: Bu katman ile girdi katmanından alınan sinyaller işlenir ve çıktı katmanına yönlendirilir. Bir YSA modelinde gizli katman, tek katman veya birden fazla katman şeklinde düzenlenebilir. Ağdaki gizli katman sayısı ve bu katmanlardaki hücre sayıları ağın büyüklüğünün belirlenmesi ve performansı açısından önemlidir.

Çıktı Katmanı: Gizli katmandan gelen bilgiler, bu katmanda işlenerek ağa verilen girdi seti için bir çıktı üretilir. Elde edilen bu çıktı ağın dışına gönderilir.

YSA modellerinde genellikle bulunan bu üç katmandaki sinir hücreleri ve bu katmanlar arası ilişkiler Şekil 3.3'te gösterilmiştir. Daire şeklindeki düğüm noktaları sinir hücrelerini temsil etmektedir. Tüm katmanlarda birbirine paralel sinir hücreleri bulunmaktadır ve çizgiler ile bu hücreler birbirine bağlanmıştır. Bu bağlantılara ait ağırlık değerleri kullanılarak ağa verilen girdilerin çıktısı elde edilir. YSA modeli ile doğru çıktılar elde edebilmek için bu ağırlık değerlerinin doğru olması gerekmektedir. İşte, bu bağlantılara ait doğru ağırlık değerlerinin belirlenmesi işlemi ağın eğitilmesi olarak adlandırılmaktadır. Eğitime başlamadan önce bu ağırlık değerleri rasgele verilir. Hücreler arasındaki bağlantıların ağırlık değerleri, ağın eğitimi esnasında eğitim veri setindeki her bir örnek için doğru sonuç elde edilene kadar öğrenme kuralına göre tekrar tekrar değiştirilir. Eğitim sonrasında ağ test veri seti için de doğru sonuçlar üretirse ağın eğitildiği kabul edilir [38].

3.4.1. YSA Öğrenme Stratejileri

Öğrenme yeteneği YSA'nın temel özelliklerinden birisidir. Öğrenmedeki temel mantık, eğitim veri setini kullanarak girdi ve çıktılar arasındaki ilişkileri ortaya çıkarmak ve bu ilişkiye göre de test veri seti için doğru çıktılar elde edilebilmesidir. Burada eğitim veri setinin, sistemin genelini temsil edecek bilgiler içermesi önemlidir. YSA gibi örneklerden öğrenen sistemlerde, genellikle danışmanlı, danışmansız ve destekleyici 3 öğrenme stratejisi kullanılmaktadır [38]:

Danışmanlı Öğrenme: Bu stratejide, bir öğretmen veya danışman yardımı ile sistemin öğrenmesi sağlanmaktadır. Danışman, öğrenilmesi istenen olay ile ilgili girdi ve çıktı örneklerini eğitim seti olarak sisteme verir. Eğitim esnasında ağ, her bir girdi için hangi

çıktının üretilmesi gerektiğini bilmektedir. Bu şekilde YSA modeli, istenen istatistiksel doğruluk sağlanana kadar olayın girdileri ile çıktıları arasındaki ilişkileri öğrenmektedir. Delta Kuralı, Genelleştirilmiş Delta Kuralı veya geriye yayılım algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir [38–40].

Danışmansız Öğrenme: Bu yöntemde, sistemin öğrenmesine yardım eden bir danışman veya öğretmen bulunmamaktadır. Sisteme sadece girdi değerleri gösterilir. Parametreler arasındaki bağlantı durumlarını sistemin kendisinin öğrenmesi beklenir. Çoğunlukla sınıflandırma problemlerinde kullanılan bir stratejidir. Yalnız öğrenme tamamlandığında çıktıların ne anlama geldiğini gösteren etiketlendirmeyi kullanıcı yapmaktadır. ART ağları bu öğrenme stratejisine örnek olarak verilebilir [38, 40].

Destekleyici Öğrenme: Bu öğrenme yönteminde, sinir ağına bir öğretmen yardımcı olmaktadır. Fakat danışman üretilmesi gereken çıktıları sisteme göstermez, sadece sistem çıktısını ürettikten sonra üretilen bu çıktının doğru veya yanlış olduğunu sisteme bir sinyal ile bildirir. Sistem, danışmandan gelen bu doğru veya yanlış sinyaline göre öğrenme sürecini tamamlar. Doğrusal vektör parçalama modeli bu stratejiye örnek olarak verilebilir [38].

3.4.2. En Çok Kullanılan YSA Modelleri

YSA’nda sinir hücrelerinin bağlanması ile oluşan ağ topolojisi, hücrelerde kullanılan toplama ve aktivasyon fonksiyonları ile öğrenme stratejisi ve kuralı ağın modelini belirlemektedir. Günümüzde pratik hayatta yaygın olarak kullanılan YSA modelleri aşağıda listelenmiştir:

- a. Algılayıcı modelleri
- b. ÇKA modelleri
- c. Doğrusal vektör parçalama modelleri
- d. Adaptif rezonans teorisi modelleri
- e. Kendi kendini organize eden model
- f. Hopfield ağları
- g. Neocognitron ağı

- h. Counterpropagation ađı
- i. Boltzman makinesi
- j. Elman ađı
- k. Probabilistik ađlar
- l. RBF ađları

3.5. YSA UYGULAMA ALANLARI

Özellikle son yıllarda YSA'ları, farklı alanlardaki zor ve kompleks problemlerin çözümünde kullanılmış ve geliştirilen bu modeller genel olarak çok başarılı sonuçlar vermiştir. Günümüzde farklı endüstrilerde yaygın olarak kullanılmaktadır. Uygulama alanı açısından herhangi bir sınırlama bulunmamaktadır. Ancak tahmin, modelleme ve sınıflandırma gibi bazı alanlarda daha çok kullanılmaktadır. YSA'ları 1950'li yıllarda geliştirilmeye başlanmıştır, ancak tarihsel sürecindeki bir aksamadan dolayı 1980'li yıllarda genel amaçlı kullanım için yeterli seviyeye gelmiştir. YSA modelleri gerçek hayatta tahmin, sınıflandırma, veri ilişkilendirme ve filtreleme, tanıma ve eşleştirme gibi fonksiyonları gerçekleştirmek üzere aşağıdaki alanlarda uygulanmaktadır [38]:

- a. Endüstriyel uygulamalar (ürün tasarımı, kalite kontrol, optimizasyon çalışmaları, çizelgeleme vb.)
- b. Finansal uygulamalar (makro ekonomik tahminler, kredi değerlendirme, borsa endeks tahminleri, döviz kuru tahminleri vb.)
- c. Askeri uygulamalar (sensör performans analizleri, uçuş yörünge optimizasyonu, mayın detektörleri vb.)
- d. Sağlık uygulamaları (hastalık teşhisi, tıbbi resim işleme, üroloji uygulamaları vb.)
- e. Diğer alanlardaki uygulamalar (uçak parçalarında hata teşhisi, el yazısı ve imza tanıma, veri madenciliđi vb.)

BÖLÜM 4

MATERYAL ve METOT

Bu çalışmada hava kirleticilerden PM₁₀ ve SO₂ parametrelerinin ve 16 coğrafi-meteorolojik faktörün GSR tahmin performansına etkileri incelenmiş ve literatürdeki çalışmalardan farklı olarak GSR tahmin performansını artırmak için çevre istasyonlara ait GSR verileri de girdi olarak kullanılmıştır. Bu bölümde tez çalışmasında kullanılan veriler, bu verilerin nasıl düzenlendiği, geliştirilen modellerin neler olduğu, farklı girdi kombinasyonlarına ait model sonuçlarının elde edilmesi için kullanılan algoritma hakkında bilgiler verilmiştir. Hava kirletici ve meteorolojik parametrelerin etkilerini incelemek üzere farklı veri setleri oluşturulmuştur. İlgili veriler MGM ve ÇRLM'den alınmıştır.

4.1. VERİLER

YSA tahmin modellerin geliştirilmesi için 2005-2015 yılları arasına ait veriler kullanılmıştır. Ancak istasyonlarda hem hava kirletici hem de meteorolojik ölçümlerin yapılmadığı yıllar bulunduğundan, istasyonlar bazında 2005-2015 yılları arasında farklı aralıklara ait veriler kullanılabilmiştir. MGM'den alınan meteorolojik veriler ve ÇRLM'den alınan hava kirletici verileri aşağıda listelenmiştir.

MGM'den alınan veriler:

- a. Günlük ortalama nem (R_{hum})
- b. Günlük minimum sıcaklık (T_{min})
- c. Günlük ortalama sıcaklık (T_{avg})
- d. Günlük maksimum sıcaklık (T_{max})
- e. Günlük ortalama toprak sıcaklığı (T_s)
- f. Günlük ortalama rüzgâr hızı (WS)

- g. Günlük toplam güneşlenme süresi (n)
- h. Günlük toplam global güneş ışınım şiddeti (H)

ÇRLM'den alınan veriler:

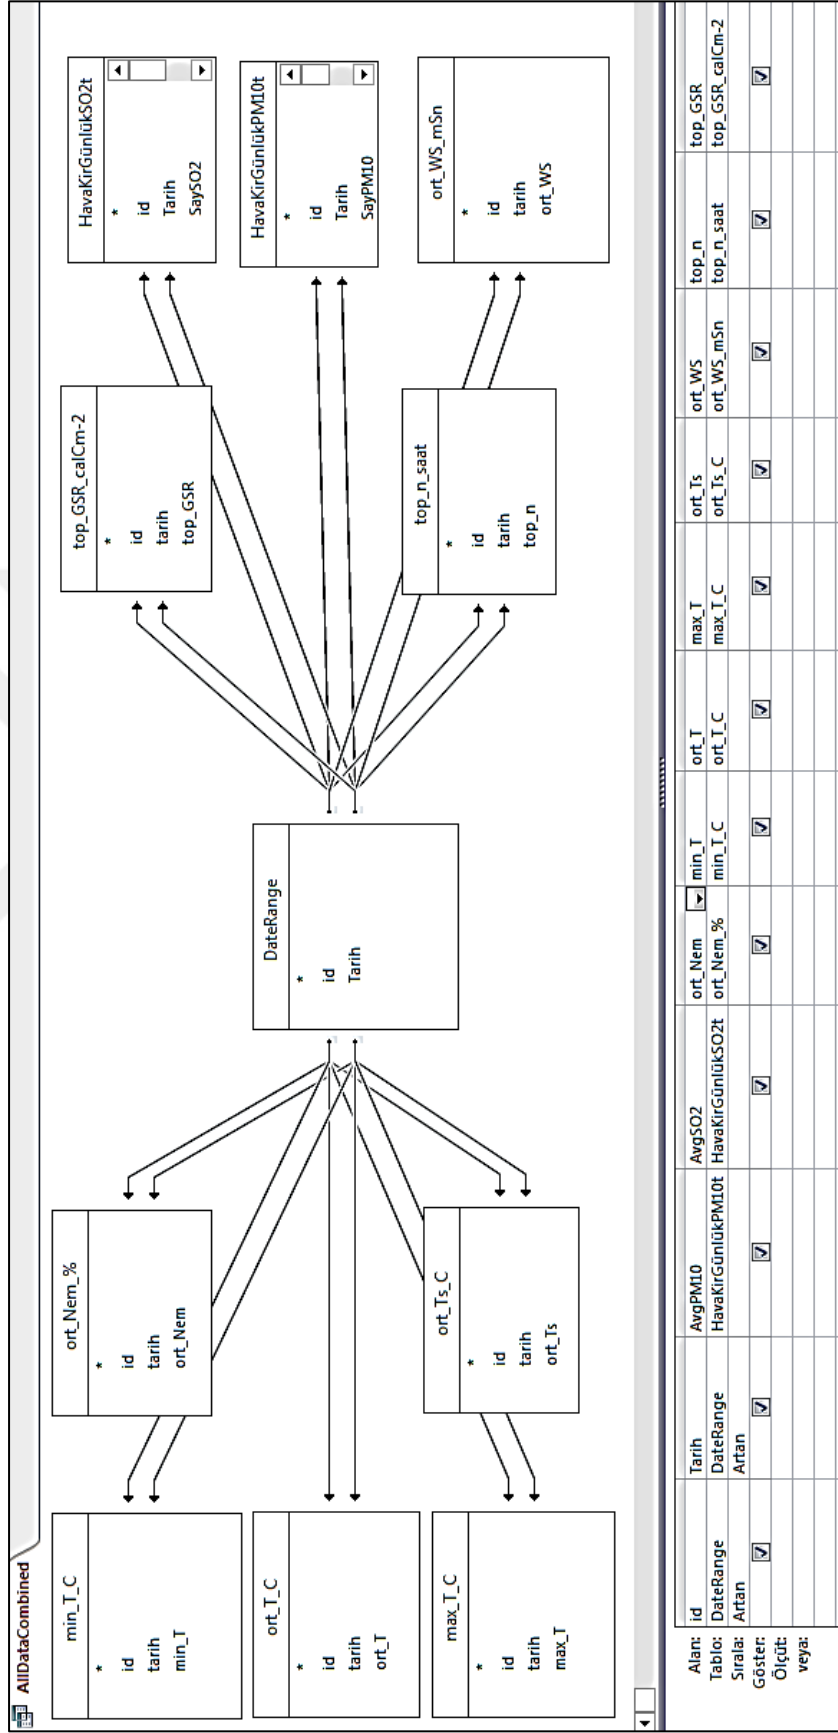
- a. Partikül madde 10 (PM₁₀)
- b. Kükürt dioksit (SO₂)

Meteorolojik veriler günlük olarak, hava kirletici verileri ise saatlik olarak ilgili kurumlardan her bir istasyon ve parametre için ayrı ayrı Microsoft Excel dosyaları halinde alınmıştır. Bu veriler bir Microsoft Access veritabanında toplanmıştır. SQL sorgusu ile güneşlenme saatlerindeki hava kirletici ölçüm verileri kullanılarak günlük ortalama PM₁₀ ve SO₂ değerleri elde edilmiştir. Gece saatlerinde yapılan ölçüm değerleri günlük hava kirletici ortalama değerlerine dahil edilmemiştir.

Herhangi bir gün için hava kirletici ortalama değeri, 06:00-19:00 saatleri arasındaki yapılan ölçüm değerleri kullanılarak ve bu saatler arasındaki ölçüm sayısı 10 ve üzerinde ise hesaplanmıştır. Aşağıda günlük PM₁₀ değerlerini bu şartlar altında hesaplayan SQL sorgusu verilmiştir:

```
SELECT hava_tum.id, hava_tum.Tarih, Count([PM10]) AS SayPM10, Avg([PM10])
AS AvgPM10
FROM hava_tum
WHERE (((hava_tum.Zaman) Between # 6:0:0# And #19:0:0#))
GROUP BY hava_tum.id, hava_tum.Tarih
HAVING (((Count([PM10]))>=10));
```

Hava kirletici veriler için günlük ortalama değerler hesaplandıktan sonra Şekil 4.1'de gösterilen sorgu ile bir istasyona ait herhangi bir tarihte ölçüm yapılan hava kirliliği verileri ve meteorolojik veriler aynı tabloda birleştirilmiştir.



Şekil 4.1. Parametreler için tarih eşleştirme yapan sorgunun tasarım görünümü.

İstasyonun bulunduğu enlem ve/veya ölçüm yapılan yılın günü bilgileri ile hesaplanan deklinasyon açısının sinüsü (SinD), atmosfer öncesi güneş ışınımı (H_o) ve gün içi maksimum güneşlenme süresi (N) parametreleri de geliştirilen modellerde coğrafi parametreler olarak kullanılmıştır. Deklinasyon açısı (δ) Eşitlik 4.1; gün batımı saat açısı (w_{ss}) Eşitlik 4.2; H_o Eşitlik 4.3 ve N değeri Eşitlik 4.4 ile hesaplanmaktadır [44, 45].

$$\delta = 23,45 \sin \left(360 \frac{284 + n_{Gun}}{365} \right) \quad (4.1)$$

$$w_{ss} = \cos^{-1}(-\tan(Enl)\tan(\delta)) \quad (4.2)$$

$$H_o = \frac{24 \cdot 3600 \cdot G_{sc}}{\pi} \left(1 + 0,033 \cos \frac{360 \cdot n_{Gun}}{365} \right) \quad (4.3)$$

$$\left(\cos(Enl) \cos \delta \sin w_{ss} + \frac{\pi \cdot w_{ss}}{180} \sin(Enl) \sin \delta \right)$$

$$N = \frac{2}{15} \cos^{-1}(-\tan(Enl)\tan(\delta)) \quad (4.4)$$

Burada, G_{sc} güneş sabitini göstermektedir.

Ayrıca bulutlu, parçalı bulutlu ve açık günler açısından, GSR tahmin modellerinde değerlendirmeye alınacak verilerin belirlenmesi önemlidir. Hava durumunun sınıflandırılmasında genel olarak Eşitlik 4.5 ile hesaplanan açıklık indeksi kullanılmaktadır [46–49].

$$k_t = \frac{H}{H_o} \quad (4.5)$$

Bendt vd. ve Ahmed vd. tarafından k_t değeri 0,5'ten büyük ise hava açık olarak sınıflandırılmıştır [47, 48]. Alves vd. tarafından ise k_t değeri 0,3'ten küçük ise hava bulutlu, 0,3-0,65 arasında ise parçalı bulutlu ve 0,65'ten büyük ise açık olarak kategorize edilmiştir [49]. Bu çalışmada hava kirletici parametrelerin GSR üzerinde

etkilerini incelerken k_t deęerinin 0,5'ten byk olduęu aık gnler; coęrafi-meteorolojik faktrler iin oluřturulan veri setinde ise k_t deęerinin 0,3'ten byk olduęu paralı bulutlu ve aık gnler dikkate alınmıřtır.

Merkez olarak belirlenen istasyona ait gnlk H deęerinin tahmini zerine etkilerini incelemek iin, RLM'den alınan hava kirletici parametreleri, MGM'den alınan meteorolojik parametreler ve yukarıdaki eřitlikler kullanılarak elde edilen parametreler izelge 4.1'deki gibi gruplanmıřtır.

izelge 4.1. alıřmada kullanılan girdi parametreleri.

Parametre Grubu	Parametreler
Coęrafi parametreler	Enl (Konumsal parametre) Byl (Konumsal parametre) Rkm (Konumsal parametre) nGun Ay N H _o SinD
Hava kirletici parametreleri	PM ₁₀ SO ₂
Meteorolojik parametreler	R _{hum} T _{min} T _{avg} T _{max} T _s WS n nN H _{avg}

4.1.1. Hava Kirletici Parametreleri İçin Veri Seti

PM₁₀ ve SO₂ parametrelerinin YSA ile GSR tahmin performansını incelemek amacı ile Çizelge 4.2’de gösterilen illere ait veriler kullanılmıştır. Enl, Byl, Rkm, PM₁₀, SO₂ ve GSR verilerinin bulunduğu 28 istasyona ait toplamda 32004 kaydın bulunduğu bilgiler bir tabloda birleştirilmiştir. Bu verilerin illere göre hava kirletici ortalamaları ve standart sapmaları hesaplanarak Z-Skor yöntemi ile iller bazında PM₁₀ ve SO₂ verileri açısından aykırı değerler için alt ve üst sınırlar belirlenmiştir. Daha sonra aykırı değerlerin bulunduğu satırlar analiz tablosundan çıkarılmıştır.

Çizelge 4.2. Hava kirletici verileri için seçilen istasyonlar.

İstasyon	Enl	Byl	Rkm
Adana	37,00	35,34	20
Adıyaman	37,76	38,28	672
Ağrı	39,72	43,04	1646
Aksaray	38,37	34,01	970
Ankara	39,97	32,86	891
Artvin	41,18	41,82	613
Aydın	37,84	27,84	56
Bingöl	38,88	40,50	1139
Bolu	40,73	31,60	743
Bursa	40,23	29,04	100
Çanakkale	40,14	26,41	6
Erzincan	39,74	39,50	1216
Gaziantep	37,06	37,35	854
Gümüşhane	40,46	39,48	1216
Isparta	37,78	30,55	997
İçel	36,81	34,64	7
Kahramanmaraş	37,58	36,90	690
Kars	40,61	43,10	1795
Kastamonu	41,37	33,76	800
Kırklareli	41,72	27,21	232
Niğde	37,97	34,68	1211
Rize	41,02	40,53	55
Sinop	42,03	35,15	30
Şanlıurfa	37,16	38,79	550
Tekirdağ	40,98	27,51	4
Tokat	40,33	36,56	611
Van	38,51	43,37	1680
Yozgat	39,82	34,81	1301

Aykırı deęerlerin ıkarılmıř olduęu veriler zerinde illere gre ortalama deęerler ve ilgili hava kirletici ile GSR arasındaki korelasyon deęerleri elde edilmiřtir. Bu ortalama deęerler ile korelasyon deęerlerinin daęılımına gre PM₁₀ ve SO₂ parametrelerinin GSR tahmini zerine etkisini incelemek zere son analiz tablosu ierisinden 4 ayrı grup oluřturulmuřtur. Bu grupların 2'si ile PM₁₀, dięer ikisi ile de SO₂ parametrelerinin GSR tahmini zerine etkileri incelenmiřtir.

Z-Skor ynteminde verinin ortalama deęerden ne kadar uzak olup olmadıęına gre aykırı deęer kararı verilmektedir. Bu yntemde aykırı deęerler iin alt sınır (AS) ve st sınır (S) Eřitlik 4.6 ve 4.7 ile elde edilir [50–52]:

$$AS = ortalama - 3(Standart Sapma) \quad (4.6)$$

$$S = ortalama + 3(Standart Sapma) \quad (4.7)$$

PM₁₀ parametresine ait illere gre ortalama ve standart sapma deęerleri izelge 4.3'te gsterilmiřtir. Yine aynı izelgede, ilgili iller iin Z-Skor yntemine gre hesaplanan alt ve st sınırlar verilmiřtir.

PM₁₀ verisi iin illere gre izelge 4.3'de gsterilen st sınırların zerindeki kayıtlar silinerek illere gre ortalama PM₁₀ deęerleri ve PM₁₀ ile GSR arasındaki korelasyon deęerleri hesaplanmıřtır (izelge 4.4).

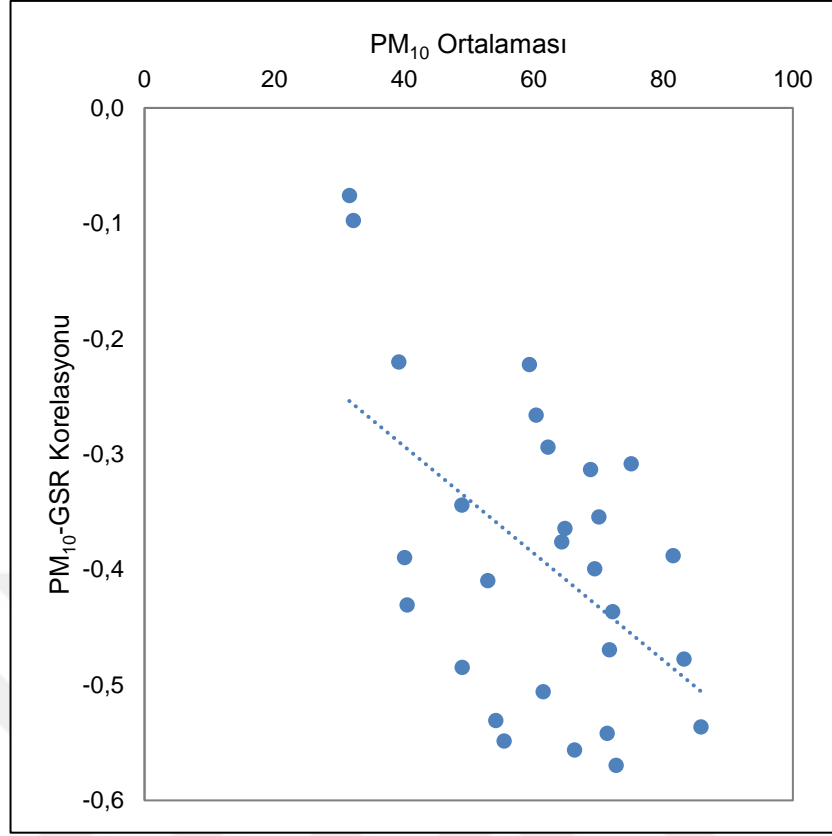
İllere gre ortalama PM₁₀ deęerleri ile PM₁₀-GSR korelasyonları arasındaki daęılım grafięine gre PM₁₀ ortalaması dřk olan blgelerde PM₁₀ ile GSR arasındaki doęrusal iliřkinin az olduęu, fakat PM₁₀ ortalaması arttıķa PM₁₀ ile GSR arasındaki doęrusal iliřkinin negatif ynde arttıęı grlmektedir (řekil 4.2). PM₁₀ kirletici ortalamasının yksek olduęu yerlerde PM₁₀ deęeri arttıķa GSR azalmakta, PM₁₀ deęeri azaldıkķa GSR deęeri artmaktadır. PM₁₀ kirletici ortalamasının dřk olduęu yerlerde ise PM₁₀ ve GSR arasında doęrusal bir iliřki bulunmamaktadır.

Çizelge 4.3. PM₁₀ aykırı değerleri için alt ve üst sınırlar.

İl	Ortalama (PM₁₀)	Standart Sapma (PM₁₀)	Alt Sınır	Üst Sınır
Adana	64,4	37,0	-46,5	175,3
Adıyaman	75,5	49,2	-72,2	223,2
Ağrı	77,2	62,2	-109,3	263,8
Aksaray	73,6	36,0	-34,3	181,5
Ankara	55,8	41,2	-67,9	179,5
Artvin	33,9	20,4	-27,3	95,0
Aydın	71,8	34,5	-31,7	175,4
Bingöl	64,9	49,9	-84,8	214,6
Bolu	74,7	68,9	-131,8	281,3
Bursa	84,2	45,0	-50,9	219,2
Çanakkale	33,7	24,1	-38,7	106,1
Erzincan	76,9	51,8	-78,5	232,2
Gaziantep	65,5	50,2	-85,1	216,0
Gümüşhane	51,4	29,5	-37,1	139,9
Isparta	62,3	60,0	-117,7	242,4
İçel	93,5	93,9	-188,1	375,2
Kahramanmaraş	90,4	45,8	-47,0	227,8
Kars	87,5	146,6	-352,4	527,5
Kastamonu	40,9	24,7	-33,3	115,0
Kırklareli	52,2	29,9	-37,6	142,0
Niğde	64,9	44,1	-67,3	197,1
Rize	46,6	75,4	-179,7	272,8
Sinop	41,7	22,9	-27,0	110,3
Şanlıurfa	76,8	46,7	-63,2	216,9
Tekirdağ	67,5	31,8	-27,8	162,9
Tokat	60,2	61,7	-125,1	245,4
Van	74,4	52,6	-83,4	232,2
Yozgat	77,7	36,6	-32,0	187,3

Çizelge 4.4. İllere göre ortalama PM₁₀ değerleri ve PM₁₀-GSR korelasyonları.

İl	Ortalama PM ₁₀	PM ₁₀ -GSR Korelasyonu
Adana	62,2	-0,2939
Adıyaman	71,3	-0,5420
Ağrı	71,7	-0,4697
Aksaray	70,0	-0,3545
Ankara	52,9	-0,4097
Artvin	32,2	-0,0976
Aydın	69,4	-0,3993
Bingöl	59,3	-0,2225
Bolu	66,3	-0,5564
Bursa	81,5	-0,3879
Çanakkale	31,6	-0,0759
Erzincan	72,7	-0,5697
Gaziantep	61,5	-0,5060
Gümüşhane	48,9	-0,3443
Isparta	54,1	-0,5309
İçel	83,2	-0,4777
Kahramanmaraş	85,8	-0,5363
Kars	64,3	-0,3760
Kastamonu	39,2	-0,2201
Kırklareli	49,0	-0,4849
Niğde	60,4	-0,2663
Rize	40,5	-0,4308
Sinop	40,1	-0,3896
Şanlıurfa	72,2	-0,4364
Tekirdağ	64,8	-0,3645
Tokat	55,4	-0,5487
Van	68,8	-0,3135
Yozgat	75,0	-0,3083



Şekil 4.2. Ortalama PM_{10} değerleri ile PM_{10} -GSR korelasyonları dağılım grafiği.

Yukarıda açıklanan durumun GSR tahmini üzerindeki etkisini incelemek üzere Çizelge 4.5'te görülen iki ayrı istasyon grubu üzerinde YSA tahmin modelleri geliştirilmiştir.

Çizelge 4.5. Tahmin modelinde PM_{10} etkisi için oluşturulan veri grupları.

Grup	İl	Ortalama PM_{10}	PM_{10} -GSR Korelasyonu
PM_{10} ortalaması ve PM_{10} -GSR korelasyonu düşük olarak seçilen iller	Artvin	32,2	-0,0976
	Çanakkale	31,6	-0,0759
	Kastamonu	39,2	-0,2201
PM_{10} ortalaması ve PM_{10} -GSR korelasyonu yüksek olarak seçilen iller	Adıyaman	71,3	-0,5420
	Erzincan	72,7	-0,5697
	Kahramanmaraş	85,8	-0,5363

Benzer şekilde SO₂ parametresine ait illere göre ortalama ve standart sapma deęerleri ve ilgili iller için Z-Skor yöntemine göre hesaplanan alt ve üst sınırlar Çizelge 4.6'da verilmiştir.

Çizelge 4.6. SO₂ aykırı deęerleri için alt ve üst sınırlar.

İl	Ortalama (SO ₂)	Standart Sapma (SO ₂)	Alt Sınır	Üst Sınır
Adana	5,6	5,2	-10,0	21,2
Adıyaman	14,3	24,4	-59,0	87,5
Ağrı	17,8	38,1	-96,6	132,3
Aksaray	13,4	22,8	-54,9	81,7
Ankara	11,5	9,4	-16,8	39,9
Artvin	5,8	5,4	-10,4	22,0
Aydın	43,2	38,3	-71,5	158,0
Bingöl	18,1	26,0	-60,0	96,1
Bolu	28,8	48,2	-115,7	173,4
Bursa	9,4	13,7	-31,7	50,5
Çanakkale	26,8	48,4	-118,4	172,0
Erzincan	16,1	16,1	-32,1	64,3
Gaziantep	15,9	30,9	-76,7	108,5
Gümüşhane	6,3	9,4	-22,0	34,6
Isparta	27,0	36,7	-83,1	137,2
İçel	7,2	7,5	-15,4	29,8
Kahramanmaraş	43,7	53,5	-116,9	204,3
Kars	25,0	38,1	-89,3	139,3
Kastamonu	8,9	9,4	-19,3	37,2
Kırklareli	16,5	31,2	-77,2	110,1
Niğde	16,7	21,0	-46,1	79,6
Rize	11,4	19,6	-47,4	70,3
Sinop	9,6	15,4	-36,6	55,8
Şanlıurfa	14,1	31,7	-81,0	109,1
Tekirdağ	53,3	91,8	-222,2	328,8
Tokat	12,8	16,8	-37,6	63,2
Van	39,8	68,7	-166,3	245,9
Yozgat	28,8	36,4	-80,4	137,9

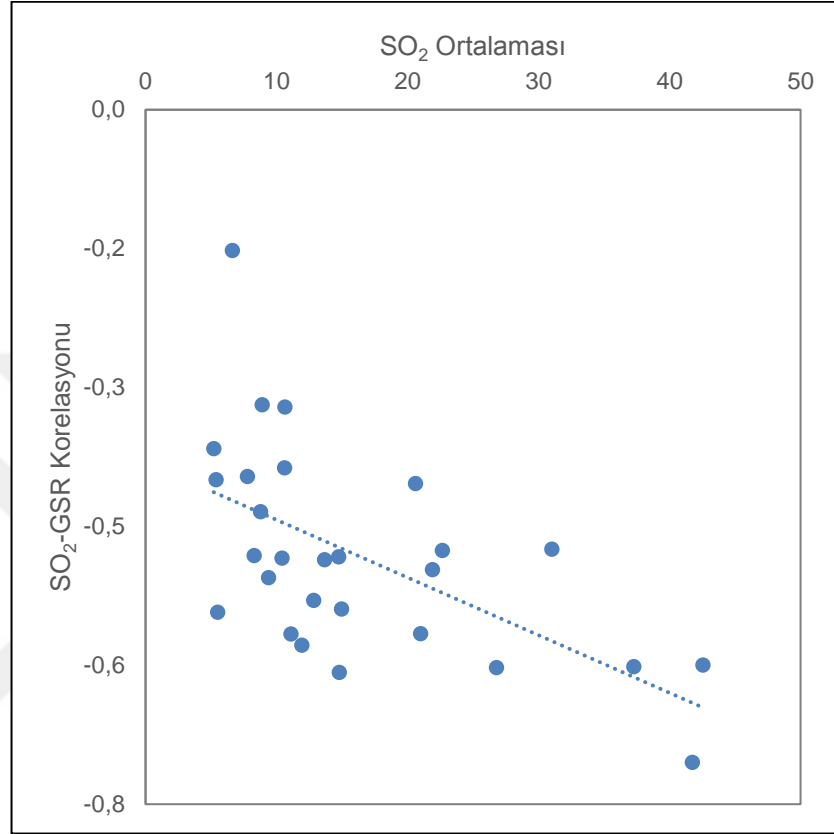
SO₂ verisi için illere göre Çizelge 4.6'da gösterilen üst sınırların üzerindeki kayıtlar silinerek illere göre ortalama SO₂ deęerleri ve SO₂ ile GSR arasındaki korelasyon deęerleri hesaplanmıştır (Çizelge 4.7).

Çizelge 4.7. İllere göre ortalama SO₂ değerleri ve SO₂-GSR korelasyonları.

İl	Ortalama SO ₂	SO ₂ -GSR Korelasyonu
Adana	5,2	-0,3906
Adıyaman	10,6	-0,3426
Ağrı	13,7	-0,5185
Aksaray	10,4	-0,5165
Ankara	10,6	-0,4126
Artvin	5,5	-0,5790
Aydın	41,8	-0,7519
Bingöl	15,0	-0,5751
Bolu	22,6	-0,5078
Bursa	8,8	-0,4632
Çanakkale	20,6	-0,4307
Erzincan	14,8	-0,6481
Gaziantep	11,9	-0,6168
Gümüşhane	5,4	-0,4262
Isparta	21,9	-0,5298
İçel	6,6	-0,1622
Kahramanmaraş	37,3	-0,6415
Kars	21,0	-0,6038
Kastamonu	7,8	-0,4225
Kırklareli	12,8	-0,5653
Niğde	14,7	-0,5151
Rize	8,9	-0,3399
Sinop	8,3	-0,5139
Şanlıurfa	9,4	-0,5393
Tekirdağ	42,6	-0,6397
Tokat	11,1	-0,6040
Van	31,0	-0,5064
Yozgat	26,8	-0,6426

İllere göre ortalama SO₂ değerleri ile SO₂-GSR korelasyonları arasındaki dağılım grafiğine göre SO₂ ortalaması düşük olan bölgelerde SO₂ ile GSR arasındaki doğrusal ilişkinin az olduğu, fakat SO₂ ortalaması arttıkça SO₂ ile GSR arasındaki doğrusal ilişkinin negatif yönde arttığı görülmektedir (Şekil 4.3). SO₂ kirletici ortalamasının yüksek olduğu yerlerde SO₂ değeri arttıkça GSR azalmakta, SO₂ değeri azaldıkça GSR değeri artmaktadır. SO₂ kirletici ortalamasının düşük olduğu yerlerde ise SO₂ ve GSR arasında doğrusal bir ilişki bulunmamaktadır.

SO₂ parametresi ile ilgili olarak yukarıda açıklanan durumun GSR tahmini üzerindeki etkisini incelemek üzere Çizelge 4.8’de görülen iki ayrı istasyon grubu üzerinde YSA tahmin modelleri geliştirilmiştir.



Şekil 4.3. Ortalama SO₂ değerleri ile SO₂-GSR korelasyonları dağılım grafiği.

Çizelge 4.8. Tahmin modelinde SO₂ etkisi için oluşturulan veri grupları.

Grup	İl	Ortalama SO ₂	SO ₂ -GSR Korelasyonu
SO ₂ ortalaması ve SO ₂ -GSR korelasyonu düşük olarak seçilen iller	Adana	5,2	-0,3906
	İçel	6,6	-0,1622
	Rize	8,9	-0,3399
SO ₂ ortalaması ve SO ₂ -GSR korelasyonu yüksek olarak seçilen iller	Aydın	41,8	-0,7519
	Kahramanmaraş	37,3	-0,6415
	Tekirdağ	42,6	-0,6397

4.1.2. Coğrafi-Meteorolojik Parametreler İçin Veri Seti

Coğrafi ve meteorolojik parametrelerin GSR tahmin performansı üzerindeki etkilerini ve literatürden farklı olarak bir konuma ait çevre istasyonlarının ortalama GSR verilerinin girdi olarak kullanılıp kullanılmamasının tahmin performansına etkilerini incelemek üzere seçilen merkez istasyonlar ve çevre istasyonları Çizelge 4.9'da listelenmiştir.

Çizelge 4.9. GSR tahmin modeli için seçilen istasyonlar ve çevre istasyonları.

İstasyon	Enl	Byl	Rkm	Çevre İstasyonlar
Adıyaman	37,76	38,28	672	Gaziantep, Malatya, Şanlıurfa
Ankara	39,97	32,86	891	Aksaray, Bolu, Kastamonu
Gaziantep	37,06	37,35	854	Adıyaman, Hatay, Şanlıurfa
Kayseri	38,72	35,52	1053	Kahramanmaraş, Niğde, Yozgat
Malatya	38,35	38,34	1000	Adıyaman, Kahramanmaraş, Tunceli

Seçilen merkez istasyonlar ve çevre istasyonları Türkiye haritası üzerinde Şekil 4.4'te gösterilmiştir.



Şekil 4.4. Merkez ve çevre istasyonları.

4.2. PERFORMANS GÖSTERGELERİ

Yapılan çalışmaların pek çoğunda modelleri değerlendirmek ve karşılaştırmak için farklı istatistiksel performans göstergeleri kullanılmıştır. Bu göstergeler, farklı çalışmalardaki benzer ve farklı modelleri karşılaştırmak için bir referans oluşturmaktadır [53]. Bu çalışmada, R, MAPE ve RMSE göstergeleri ölçülen ve tahmin edilen GSR değerlerini karşılaştırmak için istatistiksel performans göstergeleri olarak kullanılmıştır. -1 veya +1'e daha yakın R değeri, daha küçük MAPE ve RMSE değeri modelin daha iyi sonuçlar verdiğini göstermektedir.

R performans göstergesi, geliştirilen modele ait sonuçların ölçülmüş değerlere ne kadar iyi uyduğunu temsil etmektedir. R değeri -1 ve +1 aralığında değer almaktadır. R değeri -1 veya +1'e ne kadar yakınsa iki değişken arasında kuvvetli bir korelasyon olduğu anlaşılmaktadır. R değeri 0'a yaklaştıkça iki değişken arasındaki doğrusal korelasyon azalmaktadır [54]. R değeri, Eşitlik 4.8 kullanılarak hesaplanmaktadır [55].

$$R = \frac{\sum_{i=1}^k (H_{ie} - \bar{H}_{ie})(H_{im} - \bar{H}_{im})}{\sqrt{\sum_{i=1}^k (H_{ie} - \bar{H}_{ie})^2 \sum_{i=1}^k (H_{im} - \bar{H}_{im})^2}} \quad (4.8)$$

MAPE, ölçülen ve tahmin edilen değerler arasındaki mutlak sapmayı yüzde olarak ifade eder ve Eşitlik 4.9 yardımı ile hesaplanır [56]. RMSE, ölçülen ve tahmin edilen veriler arasındaki sapmayı karşılaştırarak modelin hassasiyetini ortaya koyan bir performans göstergesidir. RMSE değeri her zaman pozitiftir ve Eşitlik 4.10 ile hesaplanmaktadır [53, 56].

$$MAPE = \frac{1}{k} \sum_{i=1}^k \left(\frac{|H_{ie} - H_{im}|}{H_{im}} \right) 100 \quad (4.9)$$

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (H_{ie} - H_{im})^2} \quad (4.10)$$


Bu eşitliklerde k veri sayısını, \bar{H}_{ie} ve \bar{H}_{im} sırası ile tahmin edilen ve ölçülen GSR değerlerinin ortalamasını göstermektedir.

4.3. GSR TAHMİNİNDE ÇEVRE İSTASYON YAKLAŞIMI

Bir konuma ait GSR'nin tahmin edilmesinde uygun parametrelerin belirlenmesinin yanı sıra çevre istasyonların GSR verilerinin de kullanıldığı bir yaklaşım geliştirilmiştir. Mevcut yaklaşım önce aylık meteorolojik veriler kullanılarak, aylık GSR tahmini üzerinde uygulanmıştır [13]. Bu kısımda yaklaşım hakkında bilgiler verilmiştir. Geliştirilen bu yaklaşım günlük veriler üzerinde de uygulanmıştır.

Aylık GSR değerini tahmin etmek üzere Eşitlik 4.1'den δ , Eşitlik 4.2'den w_{ss} ve Eşitlik 4.3'den H_o hesaplanarak ve MGM'den elde edilen veriler kullanılarak H_o , n , SinD , WS , T_{avg} , T_s , $H1$, $H2$ ve $H3$ parametreleri girdi, H parametresi ise çıktı olarak belirlenmiştir.

Şekil 4.5'te gösterilen Göksun ($38^{\circ}1'N$, $36^{\circ}29'E$) ve çevresindeki Adana ($37^{\circ}0'N$, $35^{\circ}19'E$), Malatya ($38^{\circ}21'N$, $38^{\circ}18'E$) ve Pınarbaşı ($38^{\circ}43'N$, $36^{\circ}24'E$) istasyonlarına ait n , WS , T_{avg} , T_s ve H verileri MGM'den alınmıştır.



Şekil 4.5. Geliştirilen yaklaşım için seçilen istasyon ve çevresindeki istasyonlar.

GSR tahmininde uygun girdi parametrelerinin seçimi önemli bir konudur. En az etkiye sahip parametreler belirlenmeli ve çıkarılmalıdır. Bu çalışmada, Waikato Üniversitesi tarafından geliştirilen Weka isimli yazılım girdi parametresi seçiminde kullanılmıştır [57]. Weka veri ön işleme, sınıflandırma, kümeleme ve birliktelik kurallarının çıkarımı gibi işlemlerin yapılabilmesine yönelik farklı algoritmaların kullanılabilmesine imkân veren bir veri madenciliği programıdır.

Göksun için 1998 ve 2002 yıllarına ait $[H_o, n, SinD, WS, T_{avg}, T_s, H]_{60 \times 7}$ matrisi Weka programında uygun parametreleri seçmek üzere açılmıştır. Yapılan analiz sonucunda $H_o, n, SinD$ ve T_{avg} parametreleri seçilmiş ve WS ve T_s parametreleri çıkarılmıştır. Bu parametrelerin çıkarılması ve eklenmesi arasındaki farkı göstermek için farklı YSA modelleri geliştirilmiştir.

Bu çalışmada, öğretmenli öğrenme stratejisini kullanan MLP YSA'nda geri yayılım algoritması kullanılarak tahminler gerçekleştirilmiştir. Gizli katman ve çıktı katmanında aktivasyon fonksiyonu olarak lojistik sigmoid transfer fonksiyonu kullanılmıştır.

Modeller üzerindeki farklı denemeler sonucunda öğrenme ve momentum katsayısı 0,3 ve 0,2 olarak belirlenmiştir. MLP ağının eğitimi, 50000 iterasyon (epoch) sayısının tamamlanması veya hatanın 0,0001 değerinin altına düşmesi halinde durdurulmuştur.

Eğitim ve test verileri Eşitlik 4.11 ile ölçeklendirilmiştir. Bu sayede 0-1 aralığında olmayan veriler aynı ölçek üzerine indirgenmiştir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4.11)$$

Eğitim ve test sonucunda elde edilen ölçeklendirilmiş çıktıların tekrar orijinal haline dönüştürülmesi gerekmektedir. Bunun için Eşitlik 4.11 tersine çevrilerek Eşitlik 4.12 elde edilmiştir.

$$x = x'(x_{max} - x_{min}) + x_{min} \quad (4.12)$$

Java programlama dili ve Java Encog kütüphanesi [58] kullanılarak Göksun GSR tahmini için en az etkiye sahip parametrelerin ve çevredeki üç istasyona ait GSR değerlerinin girdi olarak kullanıldığı ve kullanılmadığı 4 farklı YSA modeli geliştirilmiştir.

Gizli katman nöron sayısı Eşitlik 4.13 ile belirlenmiştir [59–61]:

$$NN = \frac{I + O}{2} + \sqrt{S} \quad (4.13)$$

Eşitlik 4.13’de, NN gizli katman nöron sayısını, S eğitim seti veri sayısını, I girdi parametreleri sayısını ve O çıktı parametreleri sayısını temsil etmektedir.

Eşitlik 4.13 kullanılarak belirlenen gizli katman nöron sayısı ± 5 olacak şekilde farklı nöron sayıları için duyarlılık testi yapılmış ve RMSE göstergesi değerlerine göre modeller için seçilen YSA yapıları Çizelge 4.10’da gösterilmiştir.

Çizelge 4.10. Geliştirilen modeller için seçilen YSA yapıları.

Model	Girdiler	Katmanlardaki nöron sayısı		
		Girdi	Gizli	Çıktı
YSA-1	$H_0, n, \text{SinD}, \text{WS}, T_{\text{avg}}, T_s$	6	8	1
YSA-2	$H_0, n, \text{SinD}, T_{\text{avg}}$	4	9	1
YSA-3	$H_0, n, \text{SinD}, \text{WS}, T_{\text{avg}}, T_s, H_1, H_2, H_3$	9	8	1
YSA-4	$H_0, n, \text{SinD}, T_{\text{avg}}, H_1, H_2, H_3$	7	17	1

YSA-1 ve YSA-2 modelleri dört istasyon ve tüm YSA yapıları için uygulanmıştır. Bu sonuçlara göre YSA-1 modeli için 6-8-1, YSA-2 için 4-9-1, YSA-3 için 9-8-1 ve YSA-4 için ise 7-17-1 yapısı seçilmiştir.

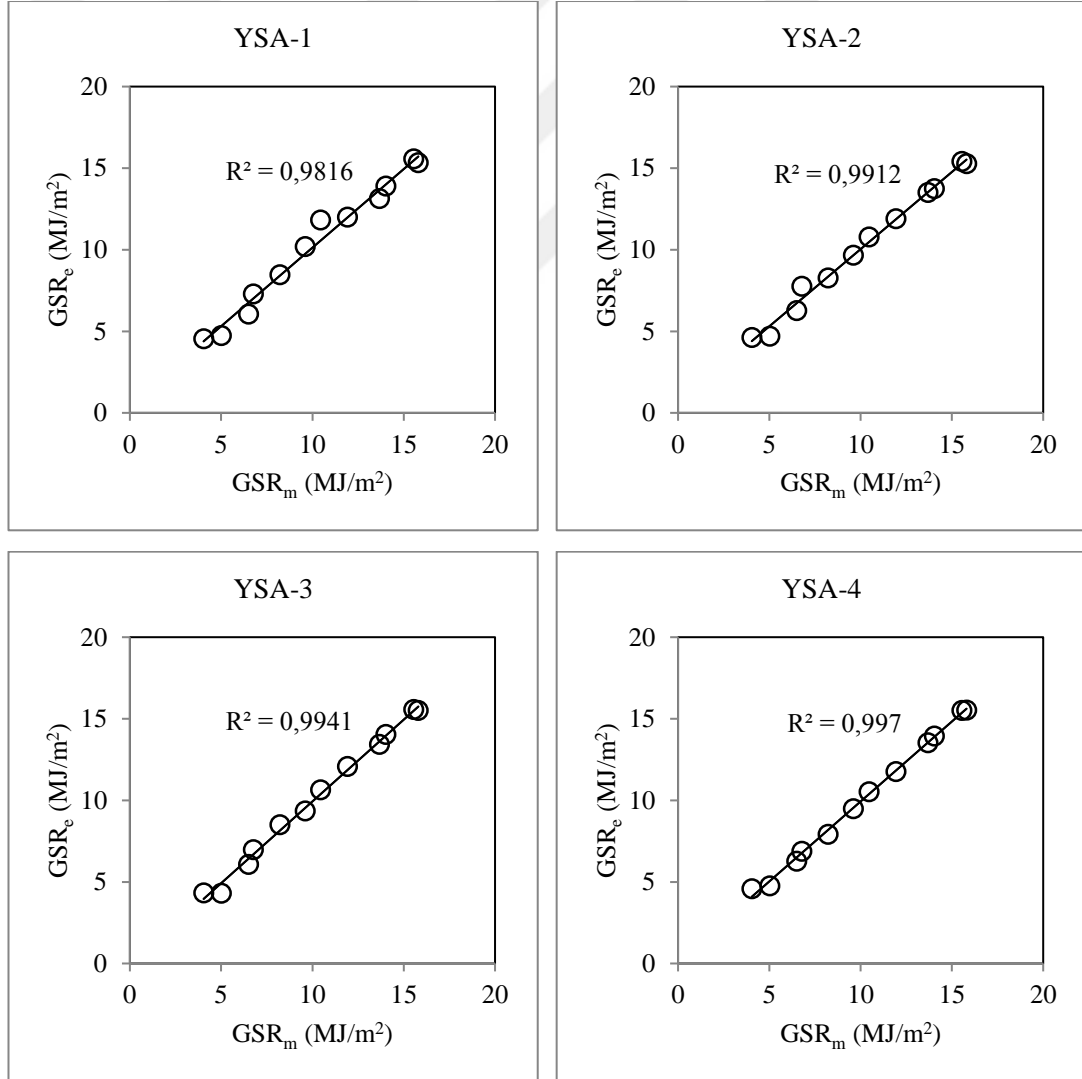
Geliştirilen modeller 2003 yılı ölçülmüş değerleri ile test edilmiştir. Modellerin performansları Çizelge 4.11’de listelenmiştir. Modellerin RMSE, MAPE ve R değerleri sırası ile 0,23-0,55, 3,83-5,27 ve 0,9908-0,9985 aralığında hesaplanmıştır.

Çizelge 4.11. Geliştirilen modellerin RMSE, MAPE ve R performans değerleri.

	YSA-1	YSA-2	YSA-3	YSA-4
RMSE	0,5502	0,4087	0,3110	0,2340
MAPE	5,2693	4,2643	3,6473	2,8328
R	0,9908	0,9956	0,9970	0,9985

%10'un altındaki MAPE değeri yüksek tahmin doğruluğunu işaret ettiğinden [60, 62, 63] dolayı, tüm modeller için elde edilen sonuçların iyi olduğu görülmektedir.


Geliştirilen YSA modellerinin tahmin sonuçları ve ölçülmüş veriler arasındaki dağılım grafiği Şekil 4.6'da gösterilmiştir.



Şekil 4.6. 2003 yılı YSA modellerinin tahmin sonuçları ve ölçülmüş veriler arasındaki dağılım grafikleri.


Şekil 4.6’da görüldüğü üzere maksimum R^2 değeri YSA-4 modeli ile elde edilmiştir. Performans göstergelerine göre H_0 , n , SinD , T_{avg} , H_1 , H_2 ve H_3 parametrelerinin girdi ve H parametresinin çıktı olarak kullanıldığı YSA-4 modeli en iyi model olarak seçilmiştir. Bu modelin RMSE, MAPE ve R değerleri sırası ile 0,23, 2,83 ve 0,9985’tir (Çizelge 4.11).

YSA-2 modelinde Weka kullanılarak WS ve T_s girdi parametreleri çıkarıldığından bu modelin sonuçları YSA-1 modelinden daha iyidir. Göksun için 2003 yılı YSA-1 ve YSA-2 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması Şekil 4.7’de gösterilmiştir. GSR tahmininde en az etkiye sahip parametrelerin çıkarılması ile daha iyi sonuçlar elde edilmektedir.



Şekil 4.7. YSA-1 ve YSA-2 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması.

Weka kullanılarak WS ve T_s girdi parametrelerinin çıkarıldığı ve çevre istasyonların tahmini H değerlerinin girdi olarak kullanıldığı YSA-4 modelinin sonuçları YSA-3 modelinden daha iyidir. Göksun için 2003 yılı YSA-3 ve YSA-4 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması Şekil 4.8’de gösterilmiştir. Çevre istasyonların H değerleri, girdi olarak eklendiğinde daha iyi sonuçlar elde edilmektedir.



Şekil 4.8. YSA-3 ve YSA-4 modellerinin tahmin sonuçları ve ölçülmüş verilerin karşılaştırılması.

Aylık veriler için geliştirilen bu yaklaşım günlük veriler üzerinde de uygulanmıştır. Günlük GSR tahmin modellerinde, çevre istasyonların ortalama GSR değerleri hesaplanarak modele eklenen parametre sayısı 1'e düşürülmüştür.

4.4. GÜNLÜK GSR TAHMİNİ İÇİN YSA MODELLERİ

Bu çalışmada, hava kirlenici, coğrafi ve meteorolojik faktörlerin günlük GSR tahmini üzerindeki etkilerini ortaya koymak üzere farklı YSA modelleri geliştirilmiştir. Literatürde, YSA yapısı (katman sayısı, katmanlardaki nöron sayıları), eğitim algoritması, transfer fonksiyonları gibi unsurlardan dolayı farklı YSA tahmin modelleri geliştirilmiştir. Tahmin performansı açısından gizli katmanda lojistik ve tanjant sigmoid transfer fonksiyonlarının ve eğitim algoritması olarak LM algoritmasının kullanılması başarılı sonuçlar vermektedir [19, 31, 32, 64–68]. Bu çalışmada geliştirilen modellerdeki ortak özellikler aşağıda listelenmiştir:

- YSA modellerinde kullanılacak veriler eğitim, doğrulama ve test olmak üzere 3 ayrı veri seti halinde bölünmüştür.
- Modellerde 1 gizli katman kullanılmıştır.
- Chow vd. tarafından yapılan çalışmada Eşitlik 4.13 ile hesaplanan NN değeri modellerde ± 5 aralığında değiştirilmiştir. Sonuçlar karşılaştırıldığında

istatistiksel olarak modellerin performansının önemli ölçüde farklılık göstermediği belirtilmiştir [59]. Bu nedenle NN değeri, eğitim veri setindeki örnek sayısı dikkate alınarak Eşitlik 4.13 ile belirlenmiştir.

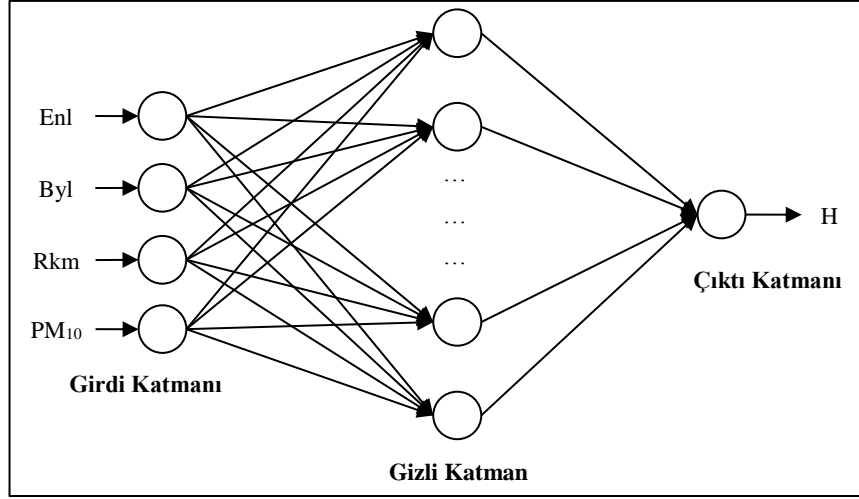
- d. LM eğitim algoritmasının kullanıldığı ileri beslemeli YSA modelleri oluşturulmuştur.
- e. Gizli katmanda tanjant sigmoid ve çıktı katmanında ise lineer transfer fonksiyonları kullanılmıştır.
- f. Modellerin performanslarını değerlendirmek üzere eğitim, doğrulama, test ve tüm veri setleri üzerinde R, MAPE ve RMSE performans göstere değerleri hesaplanarak karşılaştırma yapılmıştır.
- g. Geliştirilen modellerde kullanılan LM eğitim algoritmasına ait eğitim performans parametreleri Çizelge 4.12’de verilmiştir. Eğitim esnasında bu parametrelerden herhangi birisine ulaşılması durumunda ağın eğitimi sonlandırılmaktadır.

Çizelge 4.12. YSA eğitimi için kullanılan performans parametreleri.


Parametre	Hedef
Maksimum iterasyon sayısı	1000
MSE performans hedefi	0
Minimum performans gradyan değeri	1,00e-07
Maksimum μ	1,00+10
Maximum doğrulama hatası	6

4.4.1. Hava Kirletici Faktörlerin Girdi Olarak Kullanıldığı Modeller

PM₁₀ ve SO₂ parametrelerinin günlük GSR tahmini üzerindeki etkilerini incelemek üzere Şekil 4.9 ve Şekil 4.10’da gösterilen YSA modelleri geliştirilmiştir.



Şekil 4.9. PM₁₀ parametresi için YSA modeli.



Şekil 4.10. SO₂ parametresi için YSA modeli.

Her iki hava kirletici faktör için geliştirilen modeller, ikisi PM₁₀ ve diğer ikisi SO₂ kirleticileri için olmak üzere Çizelge 4.13'te gösterilen 4 farklı veri grubu üzerinde çalıştırılmıştır.

PM₁₀ ve SO₂ parametrelerinin günlük GSR tahmini üzerindeki etkilerini incelemek üzere oluşturulan 4 farklı veri grubunun %70'i eğitim, %15'i doğrulama ve kalan %15'i ise test veri seti olarak rasgele bölünmüştür. Gizli katmandaki nöron sayısı, bu %70'lik eğitim veri setindeki örnek sayısı dikkate alınarak Eşitlik 4.13 ile hesaplanmıştır. YSA modelleri 4 farklı veri grubu için 10'ar defa çalıştırılarak her bir veri grubu için eğitim, doğrulama, test ve tüm veri seti üzerinde ortalama R, MAPE ve

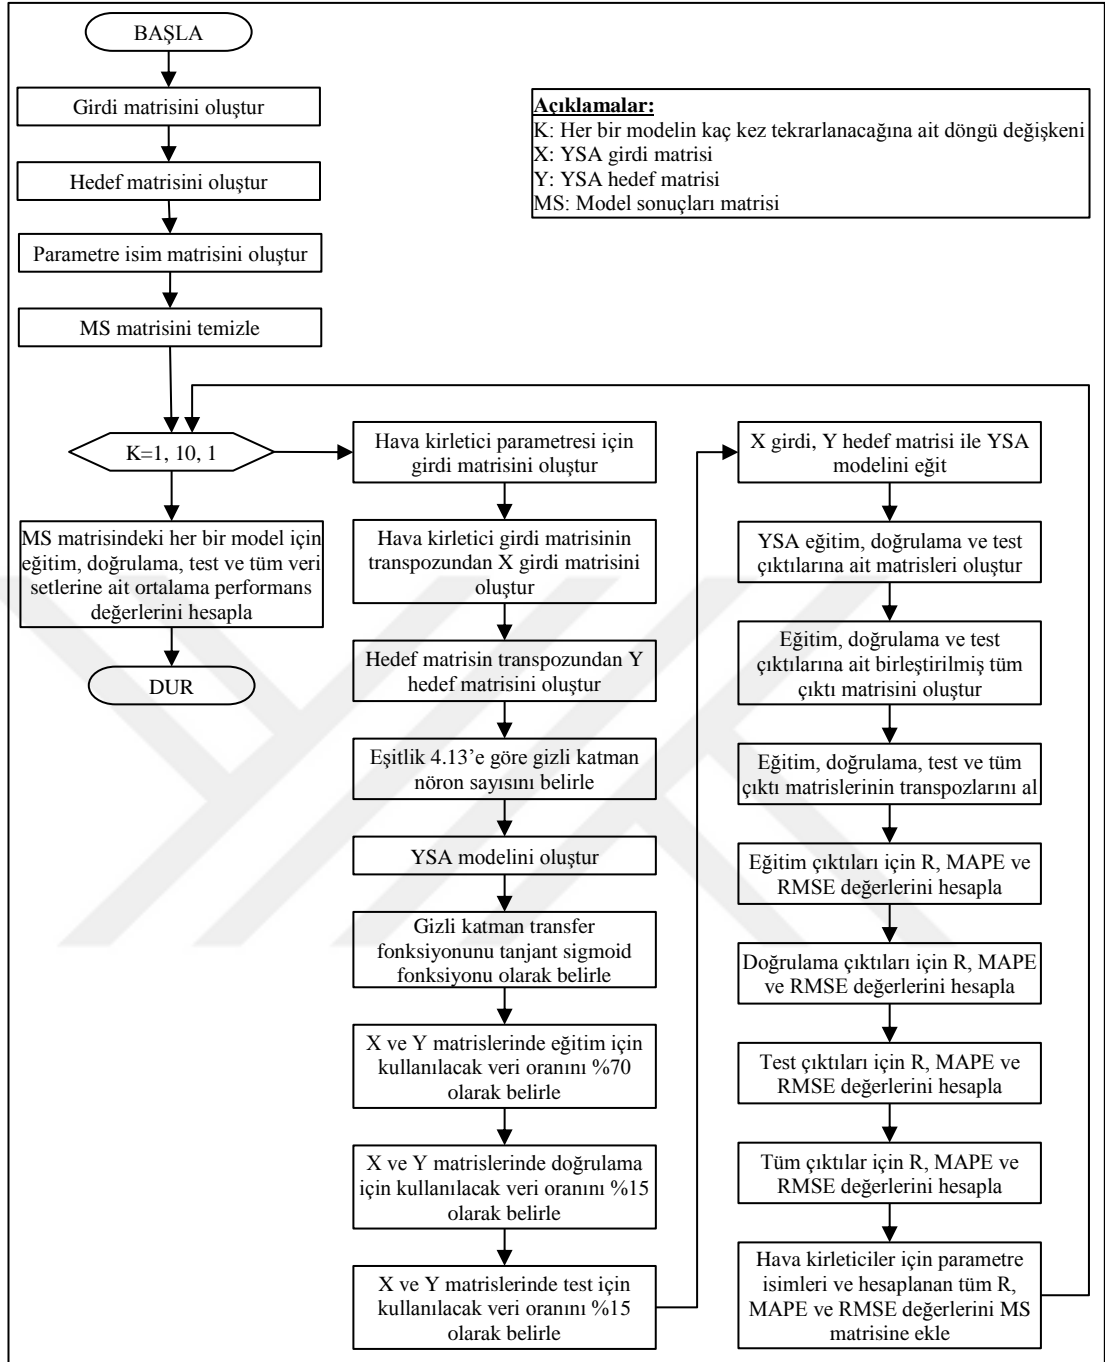
RMSE performans deęerleri hesaplanmıřtır. Bylelikle ilgili hava kirletici ortalaması ve hava kirletici-GSR korelasyonunun yksek ve dřk olduęu blgeler iin hava kirleticinin GSR tahmini zerindeki etkisi tespit edilmiřtir.

izelge 4.13. Hava kirletici veri gruplarına gre oluřturulan YSA modelleri.

Girdiler	Veri Grubu	Model*	Gizli K. Nron Sayısı
Enl, Byl, Rkm, PM ₁₀	Adıyaman Erzincan Kahramanmarař	YSApm10H	44
	Artvin anakkale Kastamonu	YSApm10L	53
	Aydın Kahramanmarař Tekirdaę	YSAso2H	44
Enl, Byl, Rkm, SO ₂	Adana İel Rize	YSAso2L	45

*H ve L: İlgili hava kirletici ortalamasının ve hava kirletici-GSR korelasyonunun sırası ile yksek ve dřk olduęu veri gruplarını temsil etmektedir.

PM₁₀ ve SO₂ hava kirleticilerinin etkisini incelemek zere geliřtirilen modeller MATLAB R2017b srmnde Neural Network Toolbox kullanılarak kodlanmıř ve alıřtırılmıřtır. Bu modeller iin yazılan MATLAB kodlarına ait akıř diyagramı Őekil 4.11'de gsterilmiřtir.



Şekil 4.11. Hava kirletici faktörlerin etkisi için MATLAB kodları akış diyagramı.

4.4.2. Coğrafi-Meteorolojik Faktörlerin Girdi Olarak Kullanıldığı Modeller

Coğrafi ve meteorolojik faktörlerin günlük GSR tahmini üzerindeki etkilerini belirlemek üzere Adıyaman, Ankara, Gaziantep, Kayseri ve Malatya istasyonlarına ait veri seti kullanılarak farklı girdi kombinasyonlarına ait YSA tahmin modelleri geliştirilmiştir. Ayrıca tahmin performansına artırmak için çevre istasyonların GSR

ortalamalarının dahil olduğu YSA modelleri oluşturularak, çevre istasyon verilerinin dahil olmadığı modeller ile karşılaştırmalar yapılmıştır.

İstasyonlar bazında farklı yıllara ait 8325 günlük veri, GSR tahmininde coğrafi ve meteorolojik faktörlerin incelenmesi için kullanılmıştır. Çizelge 4.14'te günlük YSA tahmin modellerinde kullanılacak olan istasyonlara göre eğitim-doğrulama ve test verilerinin hangi yıllara ait olduğu ve veri sayıları görülmektedir.

6698 günlük eğitim-doğrulama veri seti, rasgele %75 ve %25 oranında sırası ile eğitim ve doğrulama veri seti olarak bölünmüştür. Tüm 8325 günlük veri dikkate alındığında, yaklaşık olarak verilerin %60'ı YSA tahmin modellerinin eğitiminde, %20'si doğrulanmasında ve kalan %20'si ise testinde kullanılmıştır (Çizelge 4.15).

Çizelge 4.14. Veri yılları ve sayıları.


İstasyon	Eğitim-doğrulama veri seti		Test veri seti	
	Yıllar	Veri Sayısı	Yıllar	Veri Sayısı
Adıyaman	2005-2009	1502	2010	317
Ankara	2007-2013	1833	2014-2015	580
Gaziantep	2005-2009	1450	2010	299
Kayseri	2005-2007	976	2008	216
Malatya	2005-2007	937	2008	215
<i>Toplam</i>		<i>6698</i>		<i>1627</i>

Çizelge 4.15. Veri setleri ve oranları.

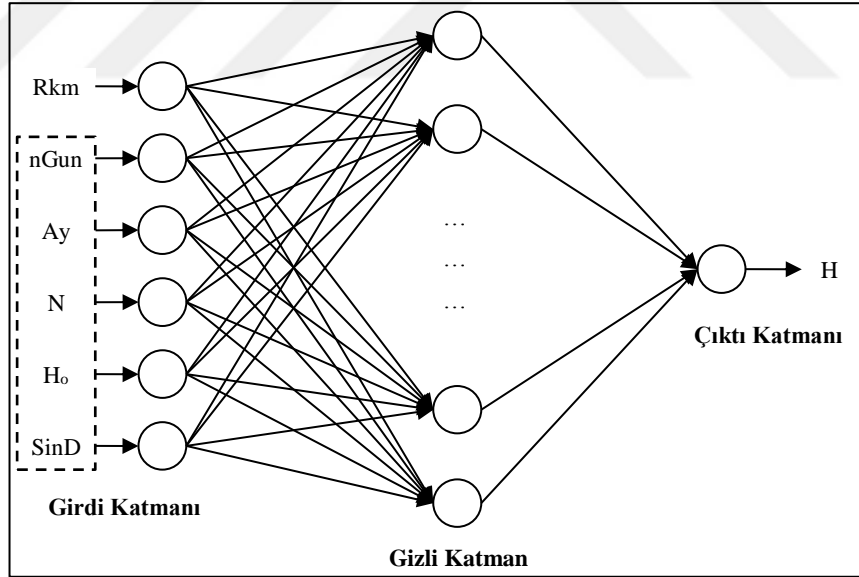
Veri Seti	Veri Sayısı	Oran
Eğitim	5023	%60
Doğrulama	1675	%20
Test	1627	%20
<i>Toplam</i>	<i>8325</i>	<i>%100</i>

Öncelikli olarak bu çalışma kapsamında belirlenen coğrafi ve meteorolojik faktörlerin tekli kombinasyonlarına ait YSA modelleri 10'ar defa çalıştırılmış ve R, MAPE ve RMSE değerleri hesaplanmıştır. Ortalama performans değerleri hesaplanarak her bir parametrenin tek başına günlük GSR tahmini üzerindeki etkileri ortaya çıkarılmıştır (Şekil 4.12).

Tekli kombinasyonlardan elde edilen sonuçlara göre konum parametrelerinden Rkm parametresi sabit kalmak üzere, diğer 5 coğrafi parametrenin tüm girdi kombinasyonlarına ait 31 farklı YSA tahmin modeli oluşturulmuştur (Şekil 4.13).



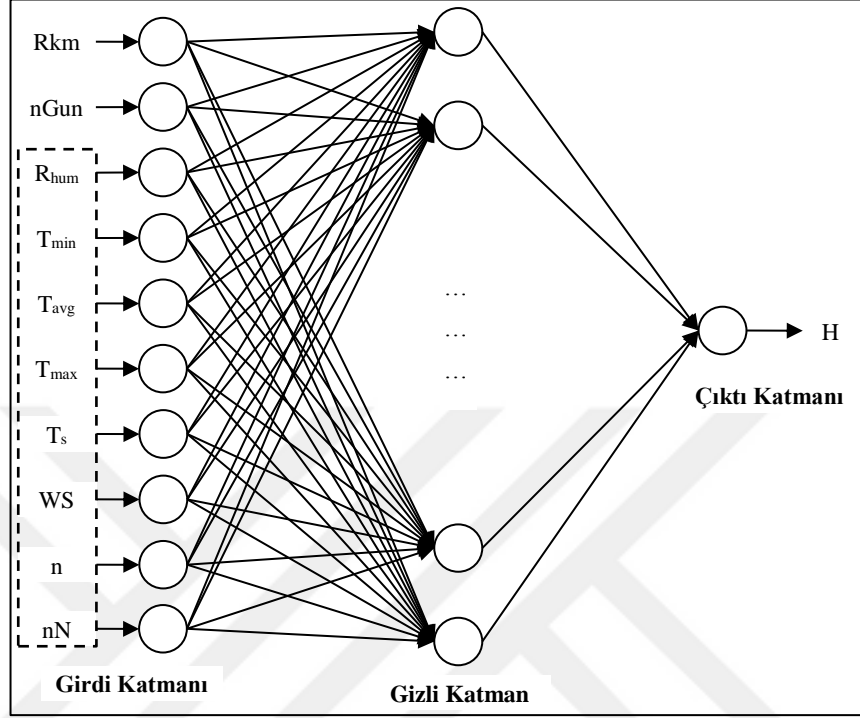
Şekil 4.12. Tekli girdi kombinasyonları için YSA modeli.



Şekil 4.13. Rkm sabit olmak üzere diğer parametrelerin farklı kombinasyonlarına ait YSA modeli.

Tekli kombinasyonlarda olduğu gibi 31 YSA tahmin modeli 10'ar defa çalıştırılarak eğitim, doğrulama, test ve tüm veri setleri için ortalama R, MAPE ve RMSE performans değerleri hesaplanmış ve yapılan karşılaştırmalar sonucunda Rkm ve nGun parametreleri sabit kalmak üzere meteorolojik faktörlerin günlük GSR tahmini üzerine

etkileri incelenmiştir. 8 meteorolojik faktörün tüm 255 girdi kombinasyonuna ait farklı YSA tahmin modelleri Şekil 4.14’te gösterildiği gibi oluşturulmuştur.



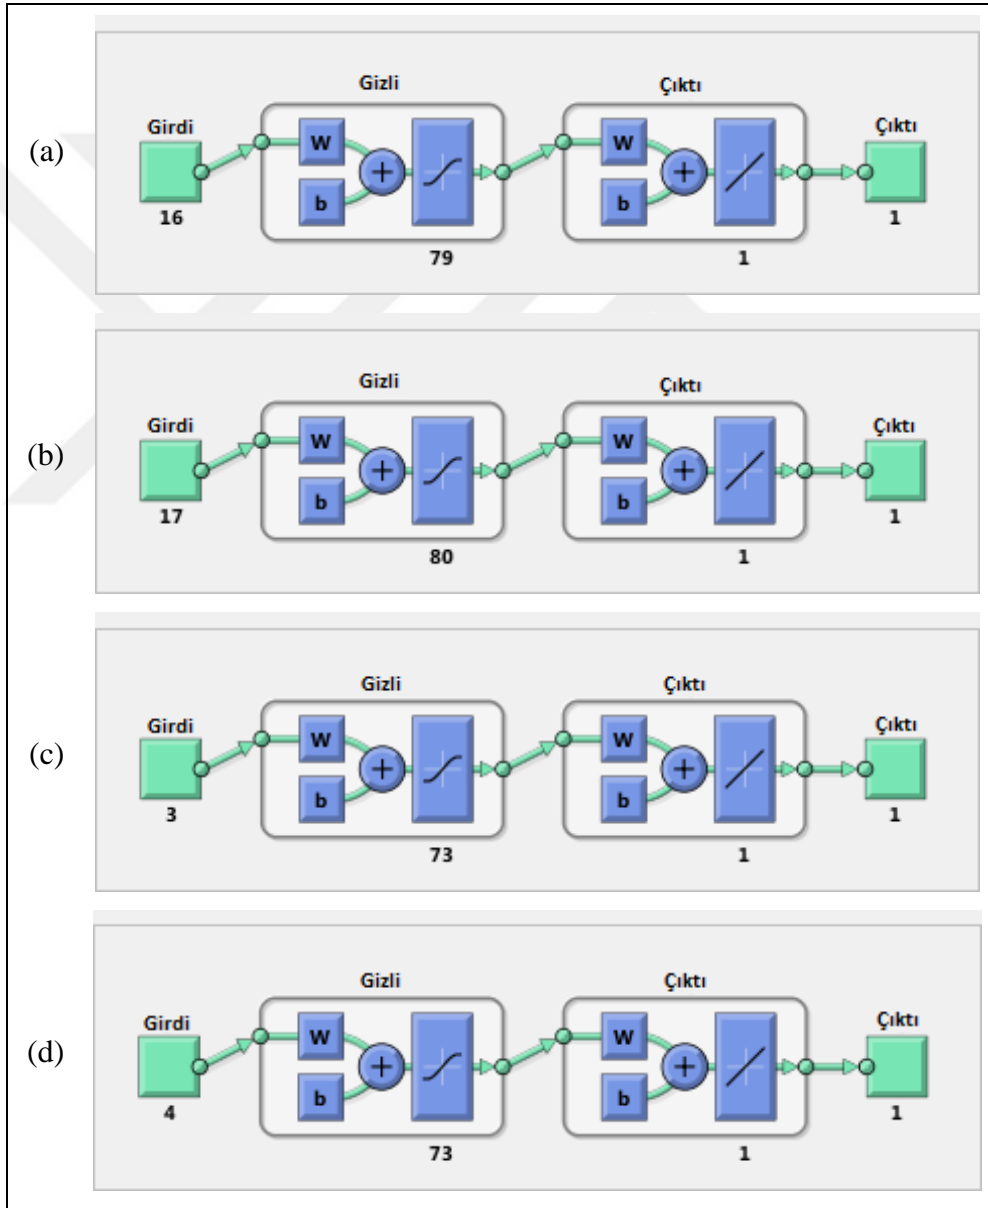
Şekil 4.14. Rkm ve nGun sabit olmak üzere meteorolojik faktörlerin tüm kombinasyonlarına ait YSA modeli.

Diğer modellerde olduğu gibi meteorolojik faktörlerin yer aldığı 255 YSA tahmin modeli 10’ar defa çalıştırılarak, her bir model için eğitim, doğrulama, test ve tüm veri setlerine ait ortalama R, MAPE ve RMSE performans değerleri hesaplanmış ve yapılan karşılaştırmalar sonucunda Rkm, nGun ve n parametrelerinin girdi olarak yer aldığı model, performans açısından iyi model olarak seçilmiştir.

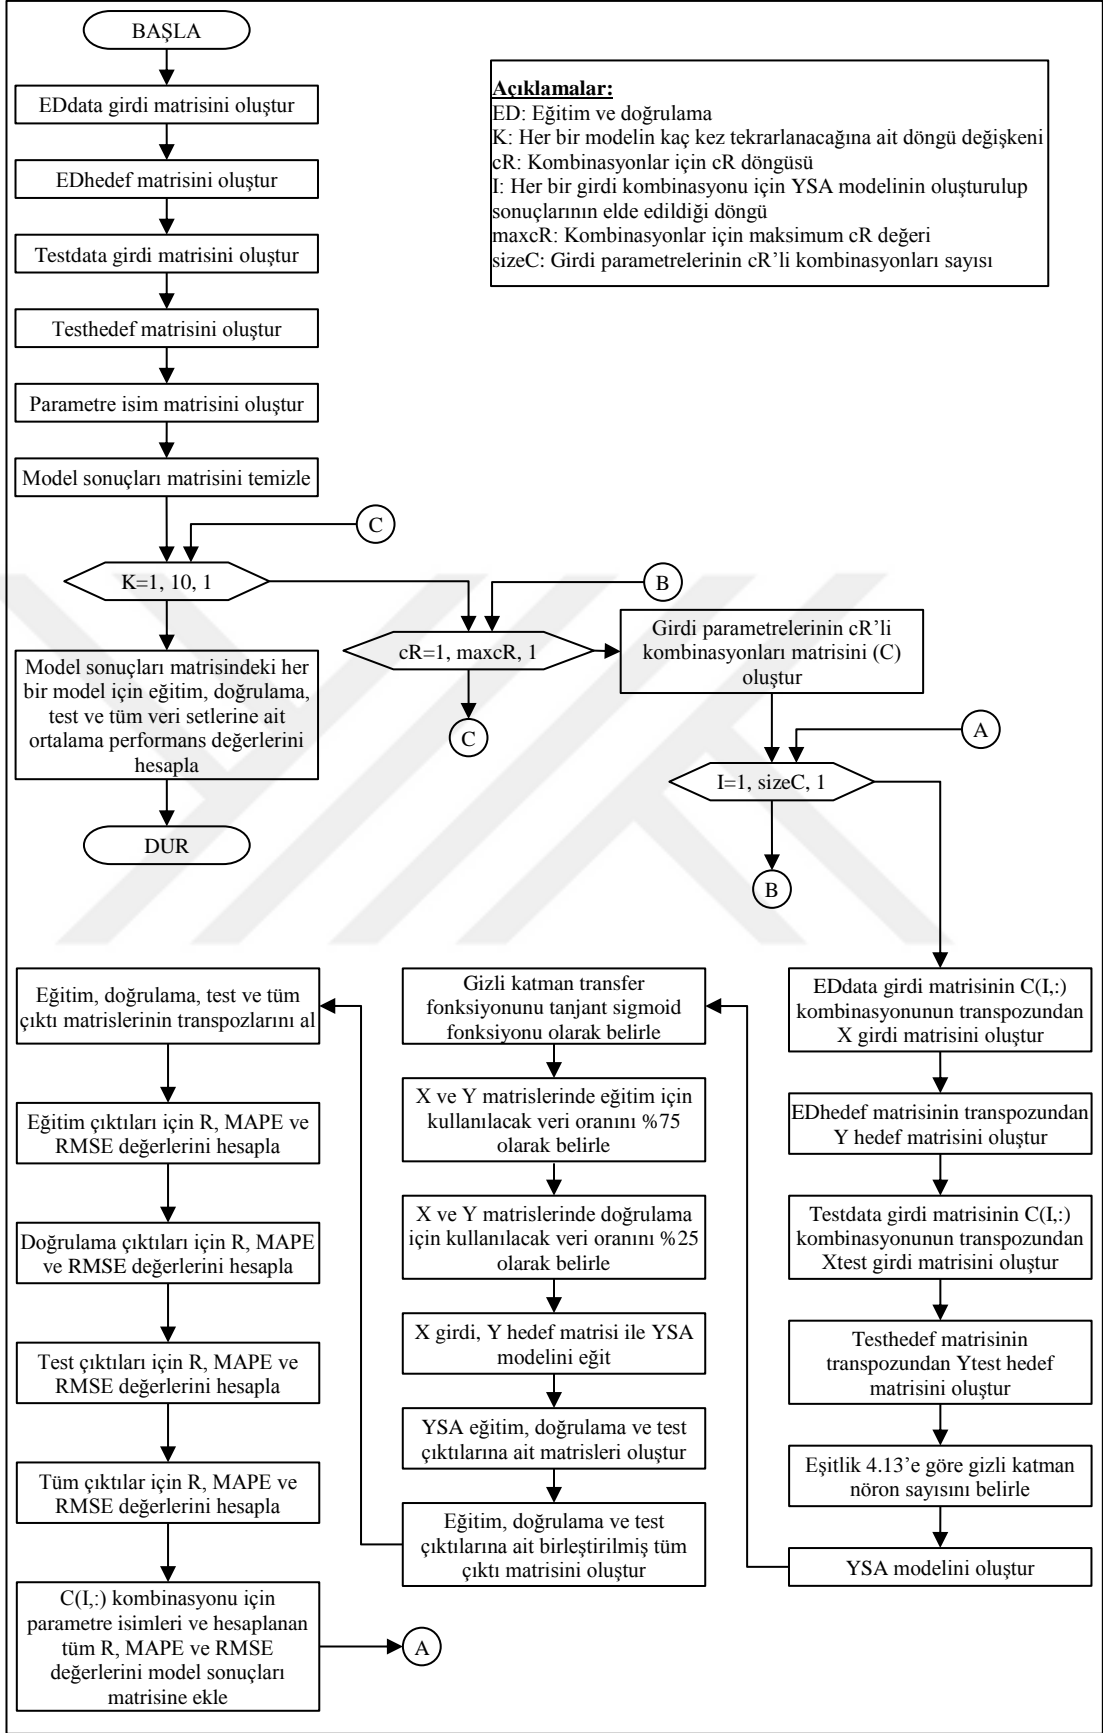
Geliştirilen tüm bu modellere ait elde edilen bulgular “Uygulama Sonuçları ve Tartışma” bölümünde ayrıntılı olarak verilmiştir.

Coğrafi ve meteorolojik parametrelerin günlük GSR tahminine etkisini incelemek üzere geliştirilen modeller MATLAB R2017b sürümünde Neural Network Toolbox kullanılarak kodlanmış ve modellere ait R, MAPE ve RMSE performans sonuçları elde edilmiştir. Farklı girdi kombinasyonlarına sahip bu modeller için yazılan MATLAB kodlarına ait akış diyagramı Şekil 4.16’te gösterilmiştir.

Tüm coğrafi-meteorolojik parametrelerin yer aldığı model (YSAc_{m1}), iyi model olarak seçilen Rkm, nGun ve n parametrelerinin girdi olarak yer aldığı model (YSAc_{m3}) ve bu iki modele literatürden farklı olarak GSR tahmin performansını artırmak üzere çevre istasyonlarının ortalama GSR verilerinin de girdi olarak eklendiği modeller (YSAc_{m2} ve YSAc_{m4}) geliştirilmiş ve bu modellere ait yapılar Şekil 4.15’da gösterilmiştir. Aynı şekilde, bu yapılardaki gizli katman ve çıktı katmanlarında kullanılan aktivasyon fonksiyonları da görülmektedir.



Şekil 4.15. 4 farklı günlük GSR YSA tahmin modelinin yapıları a) YSAc_{m1} modeli, b) YSAc_{m2} modeli, c) YSAc_{m3} modeli, d) YSAc_{m4} modeli.



Şekil 4.16. Coğrafi-meteorolojik faktörler için MATLAB kodları akış diyagramı.

Yapıları Şekil 4.15’da gösterilen modellerde kullanılan girdi parametreleri Çizelge 4.16’da verilmiştir. Bu 4 farklı günlük GSR modelinin çalıştırılması ile elde edilen R, MAPE ve RMSE performans göstergelerine göre karşılaştırılması “Uygulama Sonuçları ve Tartışma” bölümünde yapılmıştır.

Çizelge 4.16. Coğrafi-meteorolojik faktörler için oluşturulan 4 YSA tahmin modeli.

Model	Girdiler	Girdi Sayısı	Gizli K. Nöron Sayısı
YSAcml	Tüm parametreler	16	79
YSAcml2	Tüm parametreler ve H_{avg}	17	80
YSAcml3	Rkm, nGun, n	3	73
YSAcml4	Rkm, nGun, n ve H_{avg}	4	73

BÖLÜM 5

UYGULAMA SONUÇLARI ve TARTIŞMA

Bu tez çalışmasında, PM_{10} ve SO_2 hava kirleticilerinin, coğrafi ve meteorolojik parametrelerin GSR tahmini üzerindeki etkileri incelenmiştir. GSR tahmini farklı YSA modelleri ile yapılmıştır. Hava kirleticiler için ve coğrafi-meteorolojik parametreler için farklı veri setleri oluşturulmuştur. Bu veriler ise YSA modellerinin geliştirilmesi için eğitim, doğrulama ve test veri seti olarak üç gruba ayrılmıştır.

5.1. HAVA KİRLETİCİLERİN GSR TAHMİNİ ÜZERİNE ETKİLERİ

Tez kapsamında, hava kirleticilerden PM_{10} ve SO_2 parametrelerinin GSR tahmini üzerindeki etkileri ayrı ayrı incelenmiştir. 28 istasyona ait Enl, Byl, Rkm, PM_{10} , SO_2 ve GSR verileri bir tabloda birleştirilmiştir. Bu verilerin illere göre hava kirletici ortalamaları ve standart sapmaları hesaplanarak Z-Skor yöntemi ile iller bazında PM_{10} ve SO_2 verileri açısından aykırı değerler için alt ve üst sınırlar belirlenmiştir. Daha sonra aykırı değerlerin bulunduğu satırlar analiz tablosundan çıkarılmıştır.

Aykırı değerlerin çıkarılmış olduğu veriler üzerinde illere göre ortalama değerler ve ilgili hava kirletici ile GSR arasındaki korelasyon değerleri elde edilmiştir. Bu ortalama değerler ile korelasyon değerlerinin dağılımına göre PM_{10} ve SO_2 parametrelerinin GSR tahmini üzerine etkisini incelemek üzere son analiz tablosu içerisinde 4 ayrı grup oluşturulmuştur. Bu grupların 2'si ile PM_{10} , diğer ikisi ile de SO_2 parametrelerinin GSR tahmini üzerine etkileri incelenmiştir.

Oluşturulan bu 4 grup veri seti üzerinde geliştirilen YSA modelleri 10'ar defa çalıştırılarak bu gruplar için elde edilen ortalama performans değerleri ve tahmin performanslarındaki iyileşmeler Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Hava kirletici veri grupları için tahmin performansları.

Girdiler	Veri Grubu	R	MAPE	RMSE
Enl, Byl, Rkm, PM ₁₀	Adıyaman	0,5772	24,64	4,70
	Erzincan			
	Kahramanmaraş			
	Artvin	0,2097	40,22	6,88
Çanakkale				
Kastamonu				
<i>Tahmin performansındaki iyileşme</i>		0,3675	15,59	2,19
Enl, Byl, Rkm, SO ₂	Aydın	0,7224	21,81	4,44
	Kahramanmaraş			
	Tekirdağ			
	Adana	0,3977	30,35	5,40
İçel				
Rize				
<i>Tahmin performansındaki iyileşme</i>		0,3247	8,54	0,96

Bir konum için hava kirletici ortalaması yükseldiğinde hava kirletici ile GSR arasındaki korelasyon ters yönde artmaktadır. Ortalama ve korelasyonun yüksek olduğu bölgelerde, tahmin performansı düşük olan bölgelere göre artmaktadır. Ayrıca SO₂ ile karşılaştırıldığında PM₁₀ parametresi ile tahmin performansında daha fazla iyileşme sağlanmaktadır (Çizelge 5.1).

5.1.1. PM₁₀ Parametresinin GSR Tahmini Üzerindeki Etkisi

PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olan (Kahramanmaraş, Erzincan, Adıyaman) ve düşük olan (Çanakkale, Artvin, Kastamonu) veri grupları üzerinde geliştirilen YSA tahmin modelinin 10'ar defa çalıştırılması sonucunda eğitim, doğrulama ve test veri setleri için elde edilen ortalama performans göstergeleri Çizelge 5.2'de listelenmiştir.

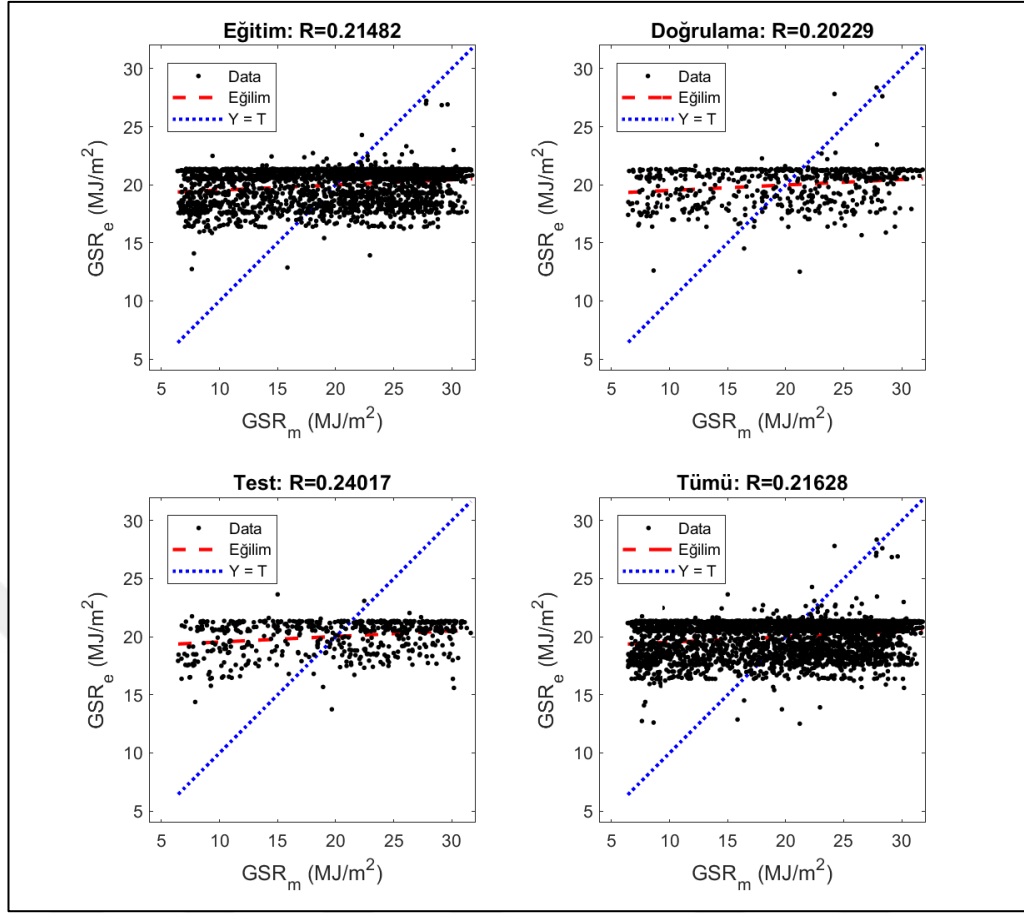
Çizelge 5.2. PM₁₀ veri grupları için tahmin performansları.

Veri Grubu	Eğitim			Doğrulama			Test		
	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
Adıyaman Erzincan Kahramanmaraş	0,5812	24,40	4,66	0,5747	24,87	4,74	0,5596	25,50	4,79
Artvin Çanakkale Kastamonu	0,2111	40,37	6,90	0,2270	40,04	6,84	0,1860	39,71	6,85
<i>Tahmin performansındaki iyileşme</i>	<i>0,3700</i>	<i>15,97</i>	<i>2,23</i>	<i>0,3477</i>	<i>15,17</i>	<i>2,11</i>	<i>0,3735</i>	<i>14,21</i>	<i>2,06</i>

Eğitim, doğrulama ve test veri setleri için PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olan veri grubunun tahmin performansının daha iyi olduğu gözlenmiştir.

Bu iki ayrı veri grubu üzerinde Enl, Byl, Rkm ve PM₁₀ parametrelerinin girdi olarak yer aldığı modellerin çalıştırılması sonucunda elde edilen tahmin değerlerinin ölçülmüş verilerle karşılaştırıldığı birer örnek bu kısımda paylaşılmıştır.

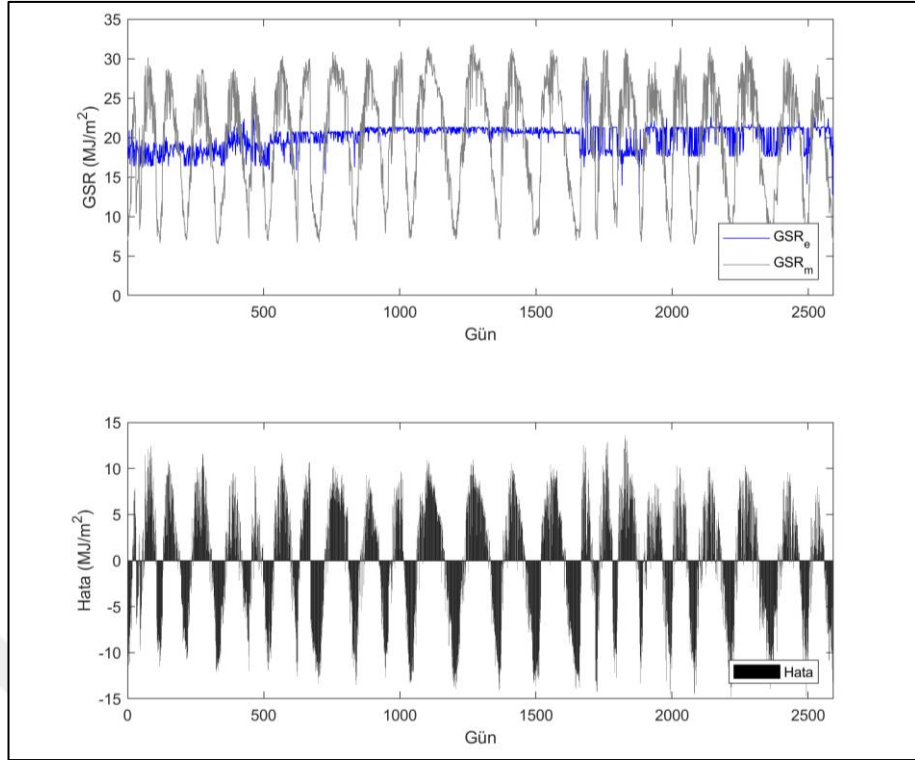
PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu düşük olarak seçilen Artvin, Çanakkale ve Kastamonu illerine ait verilerin kullanıldığı YSA modeline ait eğitim, doğrulama ve test sonuçları dağılım grafiği Şekil 5.1’de görülmektedir. Bu gruba ait sonuçlarda PM₁₀ verisinin GSR tahmin performansına etkisinin az olduğu ortaya çıkmıştır. Bu illerin Enl, Byl, Rkm ve PM₁₀ girdileri ile yapılan tahmin performansına bakıldığında, tüm veriler üzerinde 0,2163 olarak düşük bir korelasyon gerçekleşmiştir.



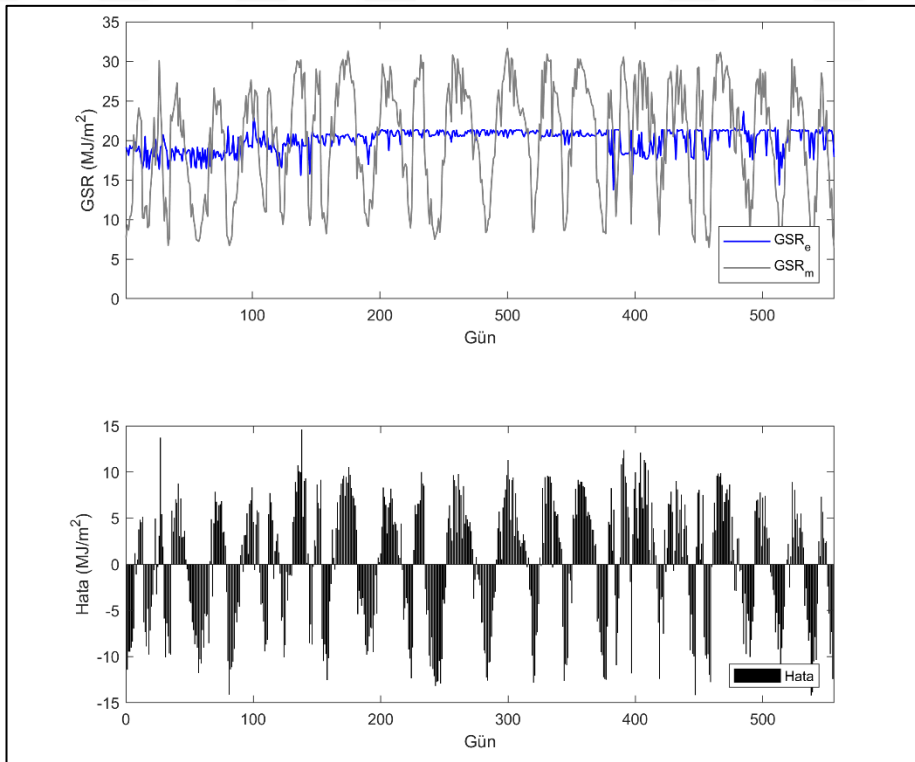
Şekil 5.1. PM_{10} ortalaması ve PM_{10} -GSR korelasyonu düşük olan gruba ait dağılım grafiği.

Şekil 5.1’de sağ alt köşedeki grafik Artvin, Çanakkale ve Kastamonu illerine ait tüm ölçülmüş verilerin tahmin edilen verilerle olan dağılımını; sol üst köşedeki grafik tüm verilerin %70’i olan eğitim veri seti sonuçlarına ait dağılımını; diğer iki grafik ise tüm verilerin %15’i olan doğrulama ve test sonuçlarına ait dağılımını göstermektedir.

Tahmin performansına ait korelasyon düşük olduğundan bu gruptaki illere ait eğitim (Şekil 5.2) ve test (Şekil 5.3) verileri karşılaştırma ve hata grafiklerinde de ölçülen değerler ile tahmin edilen değerlerin yüksek oranda farklı olduğu görülmektedir.

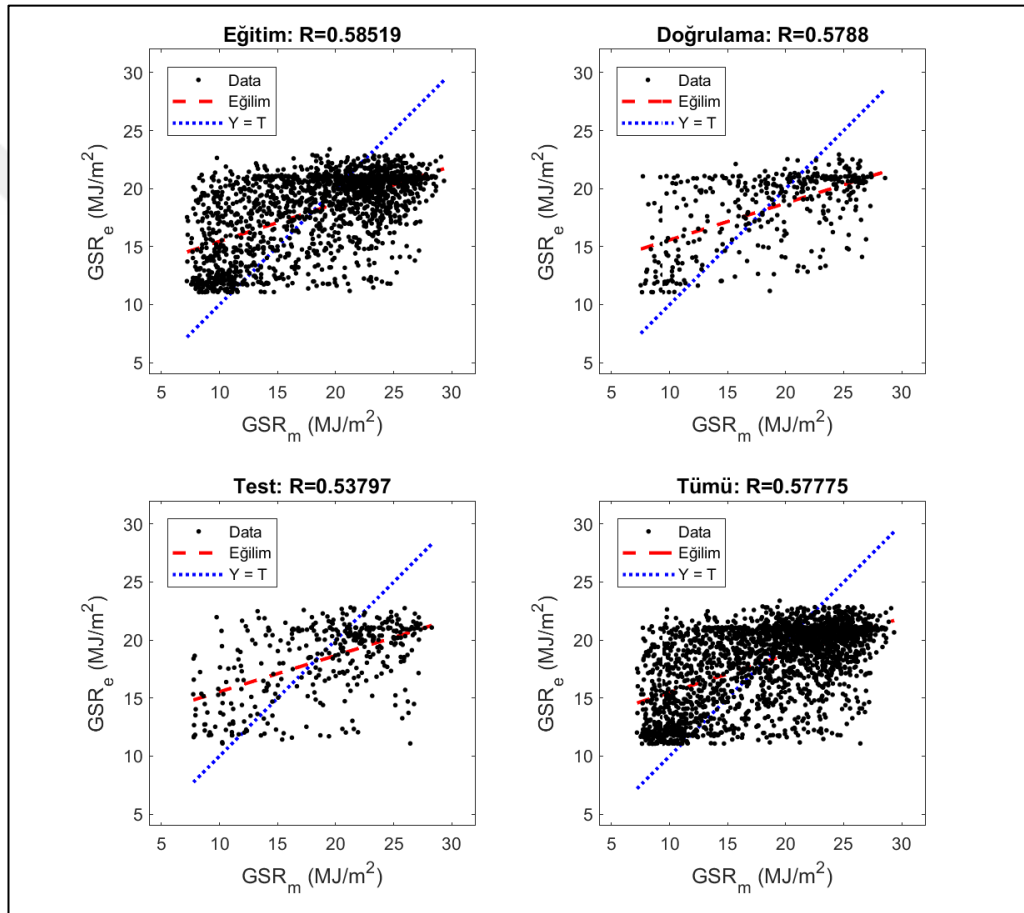


Şekil 5.2. PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu düşük olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.




Şekil 5.3. PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu düşük olan gruba ait test verileri karşılaştırma ve hata grafiği.

PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olarak seçilen Adıyaman, Erzincan ve Kahramanmaraş illerine ait verilerin kullanıldığı YSA modeline ait eğitim, doğrulama ve test sonuçları dağılım grafiği Şekil 5.4'te görülmektedir. Bu gruba ait sonuçlarda, PM₁₀ verisinin GSR tahmin performansına etkisinin Artvin, Çanakkale ve Kastamonu veri grubuna göre daha yüksek olduğu görülmektedir. Tüm veriler üzerinde 0,3615 artışla 0,5778 olarak daha yüksek bir korelasyon elde edilmiştir.

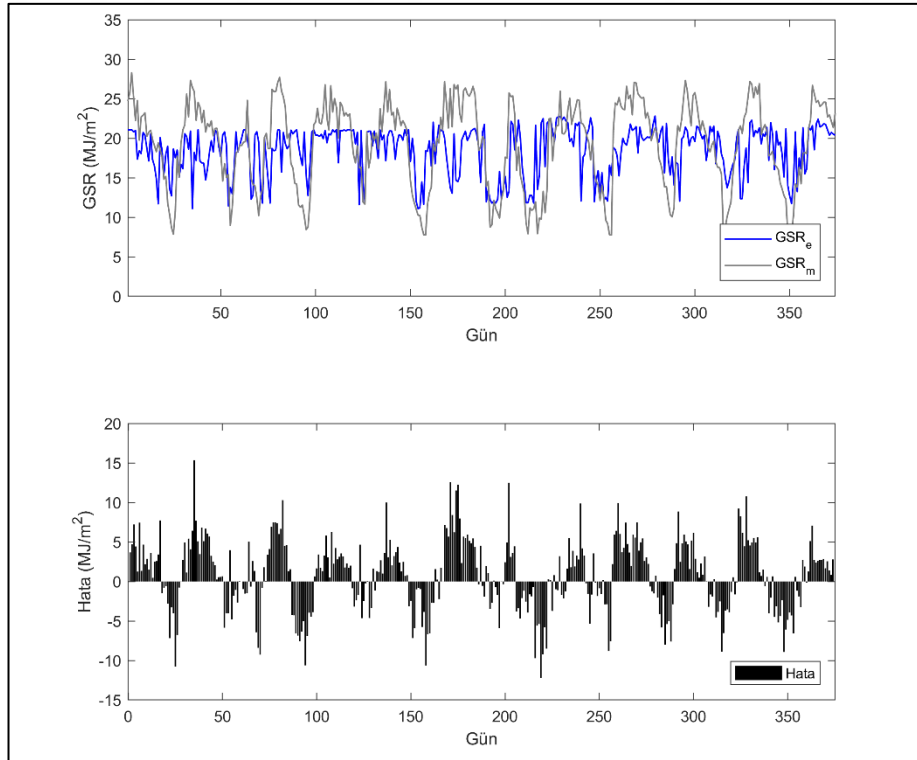


Şekil 5.4. PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olan gruba ait dağılım grafiği.

Tahmin performansına ait korelasyon önceki gruba göre daha yüksek olduğundan bu gruptaki illere ait eğitim (Şekil 5.5) ve test (Şekil 5.6) verileri karşılaştırma ve hata grafiklerinde de ölçülen değerler ile tahmin edilen değerlerin benzerlik oranının daha çok arttığı görülmektedir.



Şekil 5.5. PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.



Şekil 5.6. PM₁₀ ortalaması ve PM₁₀-GSR korelasyonu yüksek olan gruba ait test verileri karşılaştırma ve hata grafiği.

5.1.2. SO₂ Parametresinin GSR Tahmini Üzerindeki Etkisi

SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olan (Aydın, Kahramanmaraş, Tekirdağ) ve düşük olan (Adana, İçel, Rize) veri grupları üzerinde geliştirilen YSA tahmin modelinin 10'ar defa çalıştırılması sonucunda eğitim, doğrulama ve test veri setleri için elde edilen ortalama performans göstergeleri Çizelge 5.3'te listelenmiştir.

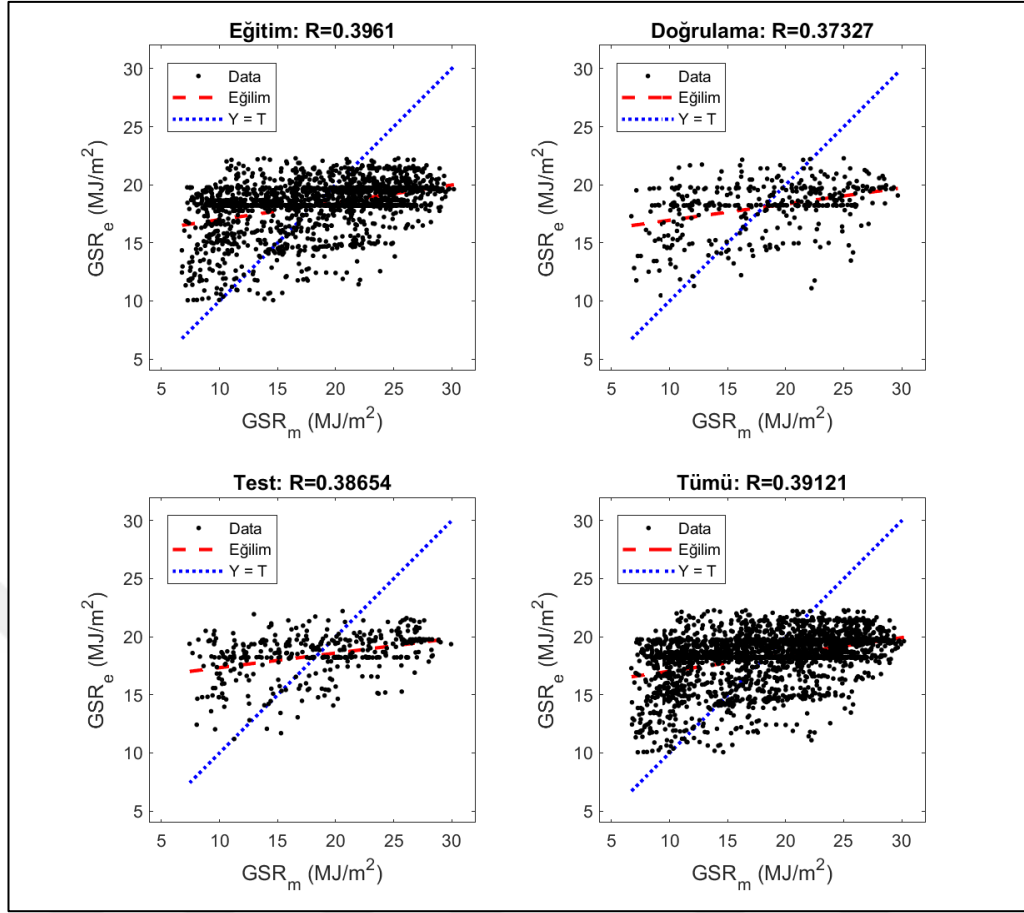
Eğitim, doğrulama ve test veri setleri için SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olan veri grubunun GSR tahmin performansının daha iyi olduğu görülmektedir.

Çizelge 5.3. SO₂ veri grupları için tahmin performansları.

Veri Grubu	Eğitim			Doğrulama			Test		
	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
Aydın Kahramanmaraş Tekirdağ	0,7229	21,64	4,42	0,7325	21,74	4,40	0,7089	22,68	4,56
Adana İçel Rize	0,4032	30,27	5,38	0,3860	30,70	5,44	0,3814	30,37	5,43
<i>Tahmin performansındaki iyileşme</i>	<i>0,3197</i>	<i>8,64</i>	<i>0,96</i>	<i>0,3465</i>	<i>8,96</i>	<i>1,03</i>	<i>0,3275</i>	<i>7,68</i>	<i>0,87</i>

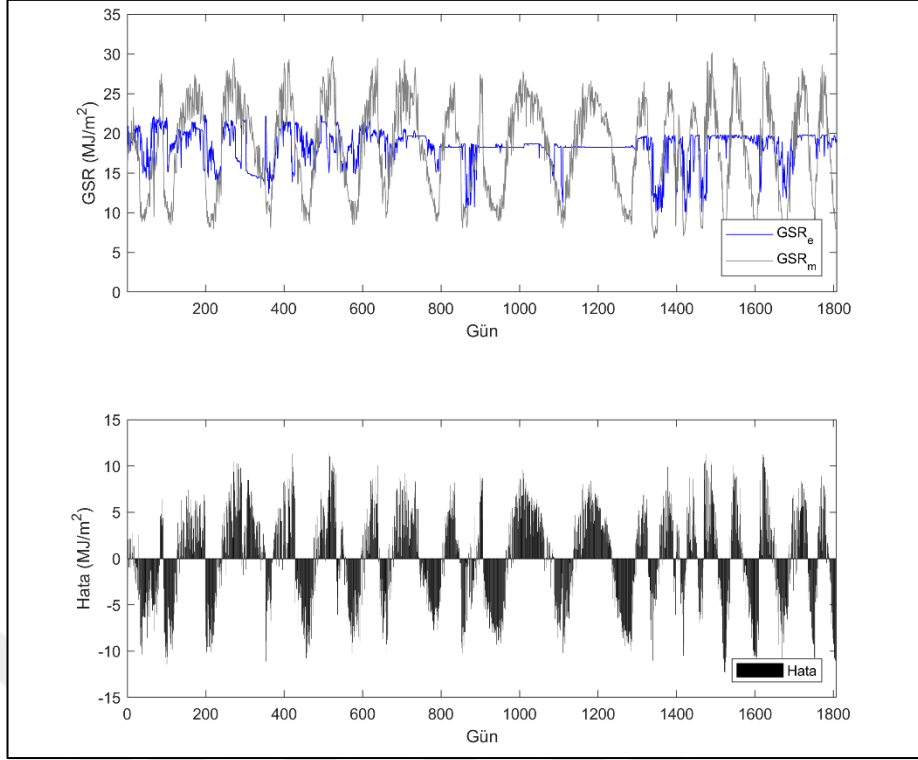
SO₂ etkisi incelemek için oluşturulan Çizelge 5.3'teki iki ayrı veri grubu üzerinde Enl, Byl, Rkm ve SO₂ parametrelerinin girdi olarak yer aldığı modellerin çalıştırılması sonucunda elde edilen tahmin değerlerinin ölçülmüş verilerle karşılaştırıldığı birer örnek bu kısımda paylaşılmıştır.

SO₂ ortalaması ve SO₂-GSR korelasyonu düşük olarak seçilen Adana, İçel ve Rize illerine ait verilerin kullanıldığı YSA modeline ait eğitim, doğrulama ve test sonuçları dağılım grafiği Şekil 5.7'de görülmektedir. Bu gruba ait sonuçlarda SO₂ parametresinin GSR tahmin performansına etkisinin az olduğu ortaya çıkmıştır. Tüm veriler üzerinde 0,3912 olarak düşük bir korelasyon sağlanmıştır.

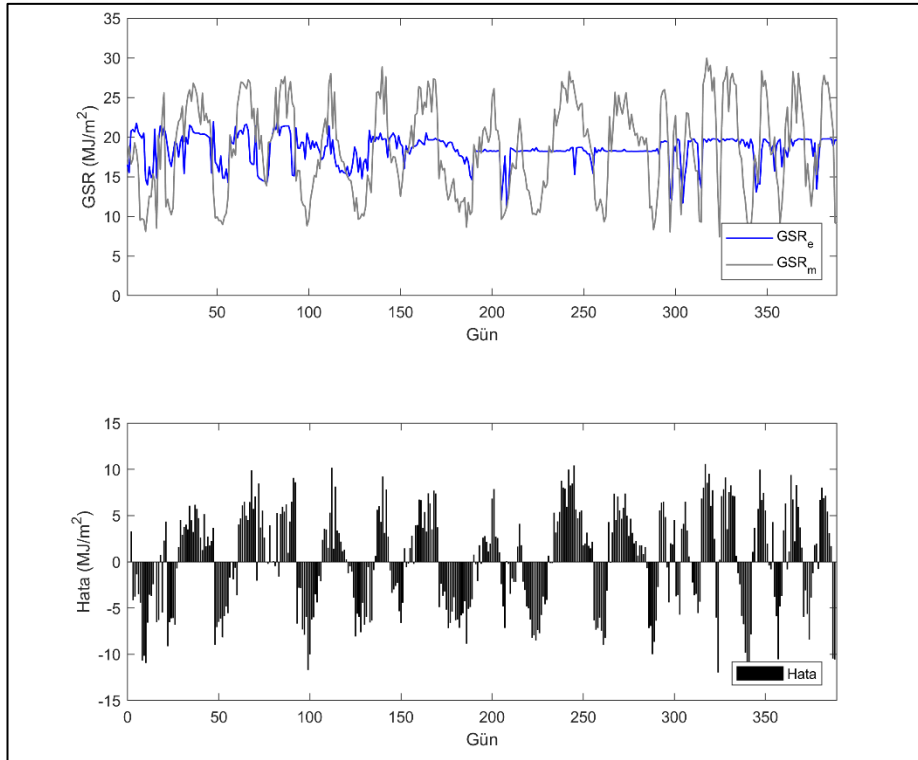


Şekil 5.7. SO₂ ortalaması ve SO₂-GSR korelasyonu düşük olan gruba ait dağılım grafiği.

Tahmin performansına ait korelasyon düşük olduğundan SO₂ ortalaması ve SO₂-GSR korelasyonu düşük olan bu gruptaki illere ait eğitim (Şekil 5.8) ve test (Şekil 5.9) verileri karşılaştırma ve hata grafiklerinde de ölçülen değerler ile tahmin edilen değerlerin yüksek oranda farklı olduğu görülmektedir.

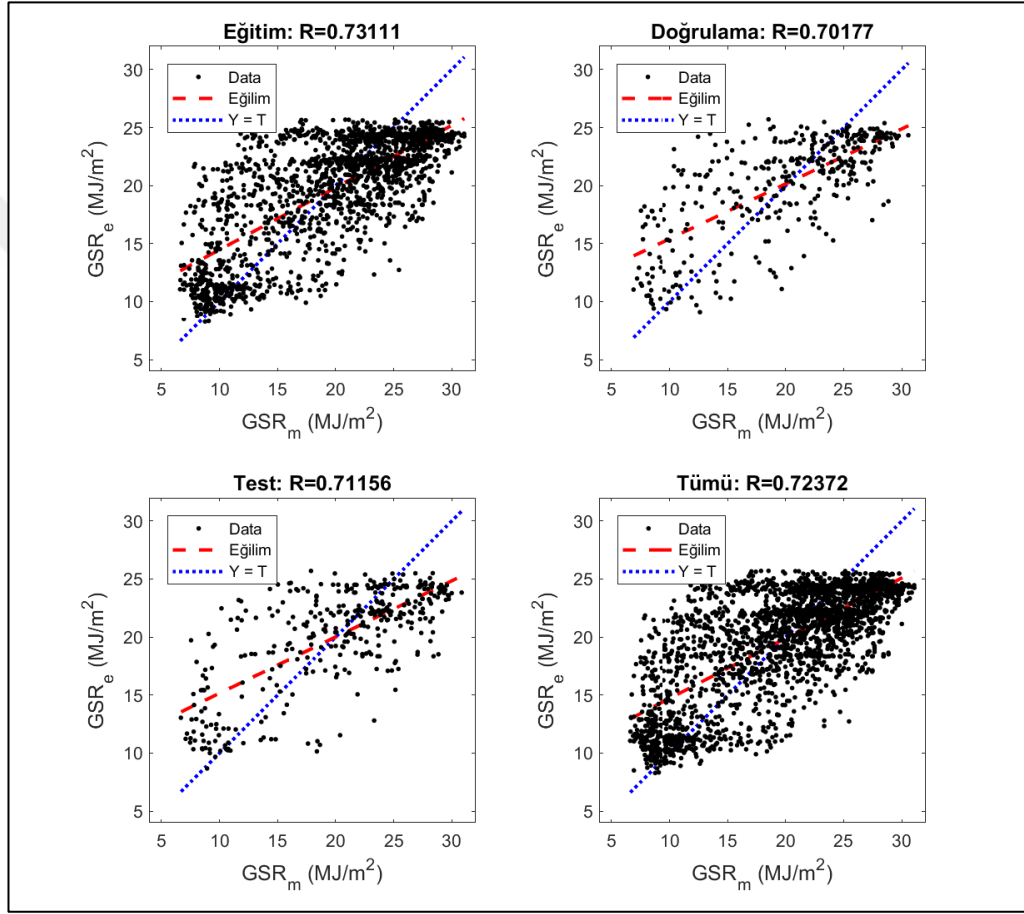


Şekil 5.8. SO₂ ortalaması ve SO₂-GSR korelasyonu düşük olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.




Şekil 5.9. SO₂ ortalaması ve SO₂-GSR korelasyonu düşük olan gruba ait test verileri karşılaştırma ve hata grafiği.

SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olarak seçilen Aydın, Kahramanmaraş ve Tekirdağ illerine ait verilerin kullanıldığı YSA modeline ait eğitim, doğrulama ve test sonuçları dağılım grafiği Şekil 5.10'da görülmektedir. Bu gruba ait sonuçlarda SO₂ verisinin GSR tahmin performansına etkisinin Adana, İçel ve Rize veri grubuna göre daha yüksek olduğu görülmektedir. Tüm veriler üzerinde 0,3325 artışla 0,7237 olarak daha yüksek bir korelasyon elde edilmiştir.




Şekil 5.10. SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olan gruba ait dağılım grafiği.

Tahmin performansına ait korelasyon önceki gruba göre daha yüksek olduğundan bu gruptaki illere ait eğitim (Şekil 5.11) ve test (Şekil 5.12) verileri karşılaştırma ve hata grafiklerinde de ölçülen değerler ile tahmin edilen değerlerin benzerlik oranının daha çok arttığı görülmektedir.



Şekil 5.11. SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olan gruba ait eğitim verileri karşılaştırma ve hata grafiği.



Şekil 5.12. SO₂ ortalaması ve SO₂-GSR korelasyonu yüksek olan gruba ait test verileri karşılaştırma ve hata grafiği.

5.2. COĞRAFI VE METEOROLOJİK PARAMETRELERİN GSR TAHMİNİ ÜZERİNE ETKİLERİ

Coğrafi ve meteorolojik faktörlerin GSR tahmini üzerindeki etkilerini incelemek üzere; Adıyaman, Ankara, Gaziantep, Kayseri ve Malatya istasyonları verileri kullanılarak YSA tahmin modellerinin performansları incelenmiştir. Öncelikle, coğrafi parametrelerden konum bilgilerini içeren Enl, Byl ve Rkm parametrelerinin tekli kombinasyonlarına ait YSA tahmin modelleri 10'ar defa çalıştırılmış ve bu parametrelerin ortalama tahmin performansları elde edilmiştir (Çizelge 5.4).

Çizelge 5.4. Konum parametrelerinin YSA tahmin performansları.

Girdiler	R	MAPE	RMSE
Enl	0,1999	45,44	6,64
Byl	0,1998	45,43	6,64
Rkm	0,2000	45,44	6,64

Konum parametrelerinin YSA tahmin performanslarına bakıldığında birbirlerine yakın olduğu görülmektedir. Aynı model içerisinde 5 konum için tahmin yapıldığından, YSA tarafından sadece istasyonların birbirinden ayırt edilmesi için kullanıldığı düşünülmektedir. Yadav vd. tarafından 2014 ve 2015 yıllarında yapılan çalışmalarda rakım parametresinin enlem ve boylam parametrelerine göre daha uygun olduğu belirtilmiştir [60, 61, 69]. Bundan dolayı bu çalışmada da konum parametrelerinden Rkm tercih edilmiştir.

Konum parametreleri haricindeki diğer coğrafi ve meteorolojik parametrelerin tekli kombinasyonlarına ait YSA modelinin 10'ar defa çalıştırılmasından sonra elde edilen ortalama performans değerleri Çizelge 5.5'te listelenmiştir.

Diğer coğrafi ve meteorolojik parametrelerin tekli kombinasyonlarına ait performans değerleri incelendiğinde en iyi tahmin performansı nGun parametresi ile en kötü tahmin performansı ise WS parametresi ile elde edilmiştir. nGun parametresi daha iyi olmak üzere Ay, N, H_o ve SinD coğrafi parametrelerinin tekli kombinasyonlarında performans açısından yakın sonuçlar verdiği görülmektedir. Tekli kombinasyonlarda

meteorolojik parametreler ise MAPE performans göstergesine göre n , T_s , T_{avg} , T_{max} , T_{min} , R_{hum} , nN ve WS sıralamasında daha iyi sonuçlar vermiştir.

Çizelge 5.5. Coğrafi ve meteorolojik parametrelerin YSA tahmin performansları.

Girdiler	R	MAPE	RMSE
<i>nGun</i>	<i>0,8860</i>	<i>16,81</i>	<i>3,14</i>
Ay	0,8714	17,98	3,32
N	0,8816	17,30	3,20
H _o	0,8722	17,90	3,31
SinD	0,8770	17,49	3,25
R _{hum}	0,6385	31,91	5,22
T _{min}	0,6638	29,66	5,07
T _{avg}	0,7474	25,65	4,50
T _{max}	0,7362	25,96	4,59
T _s	0,7804	23,66	4,24
<i>WS</i>	<i>0,3637</i>	<i>41,83</i>	<i>6,31</i>
n	0,8443	21,17	3,63
nN	0,5880	33,10	5,48

Tekli kombinasyonlara ait eğitim, doğrulama, test ve tüm veri seti üzerindeki YSA ortalama tahmin performans değerleri Çizelge Ek A.1’de verilmiştir.

Konum parametrelerinden Rkm parametresine ilave olarak diğer $nGun$, Ay, N, H_o ve SinD parametrelerinin tüm kombinasyonlarına ait YSA modelleri 10’ar defa çalıştırılarak tüm veri seti üzerinde Çizelge 5.6’da gösterilen performans değerleri elde edilmiştir.

Rkm parametresine ilave olarak diğer $nGun$, Ay, N, H_o ve SinD parametrelerinin tekli kombinasyon sonuçlarına bakıldığında en iyi sonuç Rkm, $nGun$ girdi parametreleri ile elde edilmiştir. Tüm kombinasyon sonuçlarına bakıldığında ise çok küçük farklar ile daha iyi sonuçlar elde edilse de YSA çalışma performansı açısından daha az girdi

kullanılması uygun olacağından coğrafi parametreler olarak Rkm ve nGun ikilisi ile meteorolojik faktörlerin analizine devam edilmiştir.

Çizelge 5.6. nGun, Ay, N, H₀ ve SinD parametrelerinin tüm kombinasyonlarına ait performans değerleri.

Girdiler	R	MAPE	RMSE
Rkm, nGun	0,9146	14,35	2,74
Rkm, Ay	0,9018	15,53	2,93
Rkm, N	0,9055	15,09	2,88
Rkm, H ₀	0,9041	15,20	2,89
Rkm, SinD	0,9056	15,08	2,87
Rkm, H ₀ , SinD	0,9147	14,32	2,74
Rkm, N, SinD	0,9054	15,12	2,88
Rkm, N, H ₀	0,9146	14,35	2,74
Rkm, Ay, SinD	0,9147	14,30	2,74
Rkm, Ay, H ₀	0,9148	14,29	2,74
Rkm, Ay, N	0,9149	14,30	2,73
Rkm, nGun, SinD	0,9148	14,29	2,74
Rkm, nGun, H ₀	0,9148	14,31	2,74
Rkm, nGun, N	0,9149	14,30	2,74
Rkm, nGun, Ay	0,9149	14,32	2,73
Rkm, N, H ₀ , SinD	0,9146	14,34	2,74
Rkm, Ay, H ₀ , SinD	0,9150	14,27	2,73
Rkm, Ay, N, SinD	0,9146	14,31	2,74
Rkm, Ay, N, H ₀	0,9150	14,29	2,73
Rkm, nGun, H ₀ , SinD	0,9147	14,32	2,74
Rkm, nGun, N, SinD	0,9148	14,32	2,74
Rkm, nGun, N, H ₀	0,9148	14,30	2,74
Rkm, nGun, Ay, SinD	0,9152	14,27	2,73
Rkm, nGun, Ay, H ₀	0,9150	14,27	2,73
Rkm, nGun, Ay, N	0,9151	14,28	2,73
Rkm, nGun, Ay, N, H ₀	0,9153	14,27	2,73
Rkm, nGun, Ay, N, SinD	0,9150	14,29	2,73
Rkm, nGun, Ay, H ₀ , SinD	0,9152	14,26	2,73
Rkm, nGun, N, H ₀ , SinD	0,9148	14,31	2,74
Rkm, Ay, N, H ₀ , SinD	0,9148	14,29	2,74
Rkm, nGun, Ay, N, H ₀ , SinD	0,9150	14,29	2,73

Konum parametrelerinden Rkm parametresine ilave olarak diğer nGun, Ay, N, H₀ ve SinD parametrelerinin tüm kombinasyonlarına ait YSA modellerinin 10'ar defa

çalıştırılması sonucunda elde edilen eğitim, doğrulama, test ve tüm veri seti üzerindeki YSA ortalama tahmin performans değerleri Çizelge Ek B.1’de listelenmiştir.

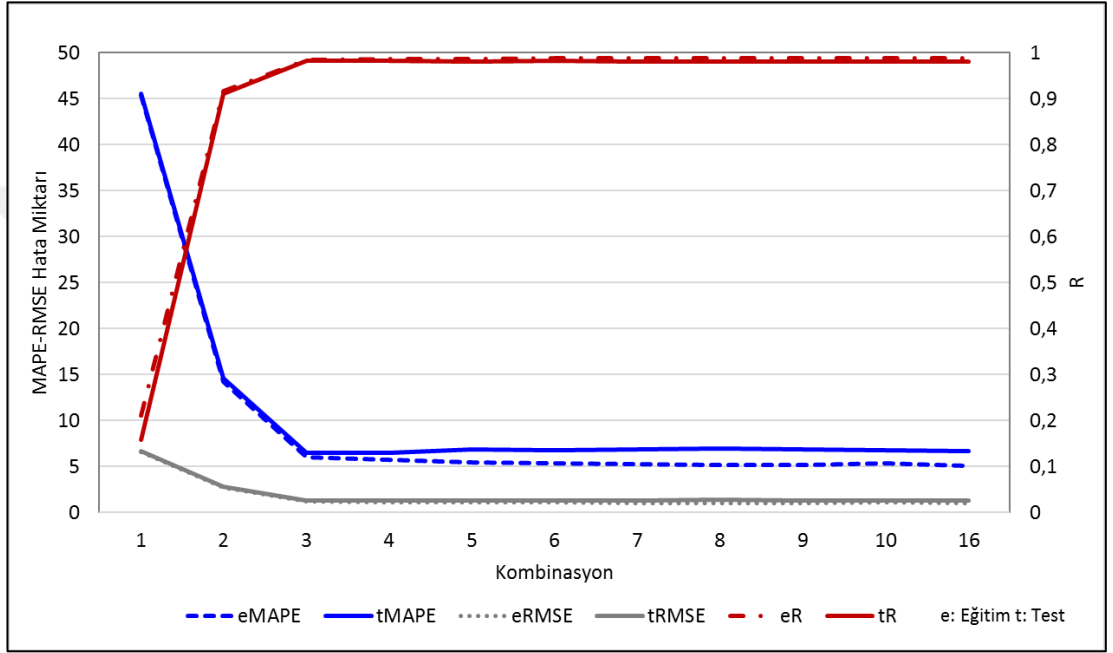
Rkm ve nGun parametrelerine ilaveten 8 meteorolojik değişkenin farklı kombinasyonları içerisinde iyi sonuç veren girdi parametrelerine ait eğitim ve test veri setleri üzerindeki ortalama tahmin performansları Çizelge 5.7’de listelenmiştir.

Çizelge 5.7. Farklı kombinasyonlara ait iyi performans sonuçları.

Komb.	Girdiler	Eğitim			Test			Süre (sn)
		R	MAPE	RMSE	R	MAPE	RMSE	
1	Rkm	0,2106	45,36	6,62	0,1587	45,58	6,69	5
2	Rkm, nGun	0,9158	14,26	2,72	0,9113	14,63	2,79	19
3	Rkm, nGun, n	0,9842	6,04	1,20	0,9819	6,45	1,29	31
4	Rkm, nGun, T _{max} , nN	0,9856	5,76	1,15	0,9823	6,51	1,28	57
5	Rkm, nGun, T _{min} , T _s , nN	0,9872	5,48	1,08	0,9813	6,82	1,32	99
6	Rkm, nGun, T _{min} , T _{max} , T _s , n	0,9876	5,36	1,06	0,9819	6,73	1,31	116
7	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , nN	0,9881	5,29	1,04	0,9813	6,83	1,32	151
8	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , n	0,9884	5,20	1,03	0,9806	6,94	1,35	165
9	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, nN	0,9884	5,19	1,03	0,9807	6,88	1,34	203
10	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, n, nN	0,9877	5,35	1,06	0,9817	6,75	1,30	177
16	Enl, Byl, Rkm, nGun, Ay, N, H _o , SinD, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, n, nN	0,9893	5,02	0,99	0,9808	6,71	1,33	331

Çizelge 5.7’de ilk iki satır daha önce açıklanmış olan coğrafi parametrelerden iyi olan girdilere ait sonuçları, son satır ise tüm 16 parametrenin eğitim ve test veri setleri için performans değerlerini göstermektedir. Diğer satırlar ise Rkm, nGun parametrelerine ilaveten 8 meteorolojik parametrenin (R_{hum}, T_{min}, T_{avg}, T_{max}, T_s, WS, n, nN) 1-8’li kombinasyonları içinden iyi sonuç verenleri göstermektedir. Aynı çizelgede bu kombinasyonlara ait sonuçların elde edilmesi için harcanan toplam süre de verilmiştir.

Çizelge 5.7’deki verilere ve Şekil 5.13’te gösterilen grafiğe göre üçlü kombinasyon ve sonrasında YSA tahmin performansında önemli bir gelişme görülmektedir. Eğitim veri seti performans göstergelerinde küçük iyileşmeler olsa da test veri setinde Rkm, nGun, n kombinasyonu sonrasında performans göstergelerinde düşüş gözlenmektedir. Test veri setindeki bu düşüş özellikle MAPE performans göstergesinde daha belirgin ortaya çıkmıştır.



Şekil 5.13. Farklı kombinasyonlara ait eğitim ve test performansları.

Rkm, nGun parametrelerine ilaveten 8 meteorolojik parametrenin (R_{hum} , T_{min} , T_{avg} , T_{max} , T_s , WS , n , nN) tüm kombinasyonlarına ait 255 modelin 10’ar defa çalıştırılması sonucunda elde edilen eğitim, doğrulama, test ve tüm veri seti ortalama performans sonuçları Çizelge Ek C.1’de listelenmiştir. Bu çizelgeye göre Rkm, nGun parametrelerine ilaveten n ve/veya nN parametrelerinin bulunduğu 192 modelin tüm veri setleri üzerindeki performansı R, MAPE ve RMSE göstergelerine göre, sırası ile en düşük 0,9830, 6,32 ve 1,24 olarak gerçekleşmiştir. Fakat n ve/veya nN parametrelerinin bulunmadığı 63 modelin performansı R, MAPE ve RMSE göstergelerine göre, sırası ile en yüksek 0,9645, 8,99 ve 1,79 olarak gerçekleşmiştir. Güneşlenme süresi ile ilgili bu iki parametrenin girdi olarak bulunduğu en düşük

tahmin performansının, girdi olarak yer almadığı diğer modellerin en yüksek tahmin performansına göre daha iyi olduğu açık bir şekilde görülmektedir.

Ayrıca nN parametresi, tekli kombinasyon sonuçlarına göre diğer meteorolojik parametreler ile karşılaştırıldığında iyi performans göstermemesine rağmen (Çizelge 5.5), diğer coğrafi-meteorolojik faktörler ile birlikte modele girdi olarak dahil edildiğinde GSR tahmin performansını artırmaktadır.

Bu tez kapsamında literatürden farklı olarak GSR tahmin performansını artırmak üzere çevre istasyonların ortalama GSR verilerinin de girdi olarak eklendiği modellerin 10'ar defa çalıştırılması sonucundaki ortalama performansları Çizelge 5.8'de verilmiştir.


Çizelge 5.8. Çevre istasyonlara ait ortalama GSR verisinin girdi olarak eklendiği modellerin performansları.

Girdi Sayısı	Girdiler	Eğitim			Test			Süre (sn)
		R	MAPE	RMSE	R	MAPE	RMSE	
16	Tüm parametreler	0,9893	5,02	0,99	0,9808	6,71	1,33	331
17	Tüm parametreler ve H_{avg}	0,9904	4,76	0,94	0,9823	6,56	1,28	380
3	Rkm, nGun, n	0,9842	6,04	1,20	0,9819	6,45	1,29	31
4	Rkm, nGun, n ve H_{avg}	0,9869	5,52	1,09	0,9837	6,08	1,23	39

Çevre istasyonların ortalama GSR verilerinin girdi olarak eklenmesi durumunda ortalama performans değerlerinde iyileşme olduğu görülmektedir. Daha öncede bahsedildiği üzere, tüm parametrelerin girdi olması durumunda eğitim performanslarında iyileşme olmaktadır, fakat bu iyileşme test performansına yansımamaktadır. Rkm, nGun ve n parametrelerine ilave olarak çevre istasyonların ortalama GSR verisinin de parametre olarak ilave edilmesi durumunda, özellikle test veri seti performans değerlerinde tüm parametrelerin girdi olarak eklenmesi durumuna göre daha fazla iyileşme olduğu görülmüştür.


Ayrıca, Çizelge 5.7’de her ilave girdinin, hesaplama süresi açısından modelin performansını düşürdüğü görülmektedir. Çevre istasyon yaklaşımında, 3 çevre istasyona ait GSR verisinin modelde ayrı ayrı girdi olarak kullanılması yerine, çevre istasyonların ortalama GSR verisinin hesaplanarak 1 ilave girdi olarak modele eklenmesi YSA modellerinin daha kısa sürede hesaplama performansını artırmaktadır.

Rkm, nGun, n ve H_{avg} parametrelerinin girdi olarak kullanıldığı YSA modelinin çalıştırılması sonucunda elde edilen tahmin değerlerinden birisi ile ölçülmüş değerler arasındaki dağılım grafiği Şekil 5.14’te görülmektedir. Geliştirilen bu YSA modelinde genel olarak elde edilen korelasyonun ve eğitim, doğrulama, test ve tüm veri setlerine ait tahmin tutarlılığının yüksek olduğu sonucuna varılmıştır.



Şekil 5.14. Rkm, nGun, n ve H_{avg} girdi parametrelerine göre ölçüm ve tahmin değerleri dağılım grafiği.

Rkm, nGun, n ve H_{avg} girdi parametrelerini kullanan modelin çalıştırılması sonucunda elde edilen tahmin değerlerinin ölçüm değerleri ile karşılaştırıldığı ve tahmin hatalarının gösterildiği grafik Şekil 5.15'te görülmektedir. Grafik incelendiğinde genel olarak yılın ilk yarısında GSR değişiminin daha fazla olduğu görülmektedir. Bu durum ilgili zamanlarda daha fazla tahmin hatasına sebep olmaktadır.



Şekil 5.15. Rkm, nGun, n ve H_{avg} girdi parametrelerine göre ölçüm ve tahmin değerleri karşılaştırma ve hata grafiği.

Çizelge 5.9'da literatürde yapılmış olan aylık GSR tahmin modellerinin geliştirildiği çalışmalar listelenmiştir. İlgili çalışmalara ait hesaplanmış olan R, MAPE ve/veya RMSE performans göstergeleri de verilmiştir.

Çizelge 5.9'daki çalışmalar, mevcut bu çalışmadaki aylık GSR tahmini için elde edilen performans göstergeleri ile karşılaştırıldığında; R değerine göre Sözen vd. tarafından yapılan çalışmadan sonra en iyi sonucun elde edildiği; MAPE değerine göre en iyi sonuca ulaşıldığı ve RMSE değerine göre ise Koca vd. tarafından yapılan çalışmadan sonra en iyi ikinci sonucun gerçekleştiği görülmektedir.

Çizelge 5.9. Literatürdeki aylık GSR tahmin modellerinin karşılaştırılması.

Kaynak	Girdiler	R	MAPE	RMSE
Mohandes vd. (1998) [29]	Enl, Byl, Rkm, n		6,5-19,1	
Al-Alawi ve Al-Hinai (1998) [33]	Ay, Basınç, T_{avg} , Buhar basıncı, R_{hum} , WS, n		5,43-7,30	
Sözen vd. (2005) [24]	Enl, Byl, Rkm, Ay, n, T_{avg}	0,9972-0,9989	3,63-6,78	
Azadeh vd. (2009) [3]	T_{max} , T_{min} , R_{hum} , Buhar basıncı, Toplam yağış, WS, n	0,9695	6,70	
Şenkal ve Kuleli (2009) [30]	Enl, Byl, Rkm, Ay, difüz ışınım, direkt ışınım			3,94
Şenkal (2010) [20]	Enl, Byl, Rkm, iki tip emisivite, T_s	0,9341		0,32
Koca vd.(2011) [31]	Enl, Byl, Rkm, Ay, Bulutluluk	0,9931-0,9974		0,04-0,07
Ozgoren vd. (2012) [26]	n, Ay, Bulutluluk, T_s , T_{avg} , Rkm, W_s , T_{max} , T_{min} , Enl	0,9936	5,34	
Jiang vd. (2015) [21]	T_{avg} , T_{max} , T_{min} , R_{hum} , vs. 12 girdi		5,44-7,64	1,01-1,42
Mevcut çalışma	H_o, n, SinD, T_{avg}, H_1, H_2, H_3	0,9985	2,83	0,23

Çizelge 5.10’da günlük GSR tahmini ile ilgili literatürde yapılmış olan modellerin geliştirildiği çalışmalar listelenmiştir. Aynı çizelgede, ilgili çalışmalarda hesaplanmış olan R, MAPE ve/veya RMSE performans göstergeleri de verilmiştir.

Çizelge 5.10’daki çalışmalar, mevcut bu tez çalışmasındaki günlük GSR tahmin modeli ile elde edilen performans göstergeleri ile karşılaştırıldığında; R değerine göre Elminir vd., Behrang vd. ile Linares-Rodriguez vd. tarafından yapılan çalışmalardan sonra en iyi sonuca ulaşıldığı; MAPE değerine göre Rehman ve Mohandes ile Behrang vd. tarafından yapılan çalışmalardan sonra en iyi sonucun gerçekleştiği ve RMSE değerine göre ise en iyi sonucun elde edildiği görülmektedir.

Genel olarak bakıldığında, bu çalışmada hem aylık hem de günlük veriler üzerinde geliştirilmiş olan modellerin iyi sonuçlar verdiği söylenebilir.

Çizelge 5.10. Literatürdeki günlük GSR tahmin modellerinin karşılaştırılması.

Kaynak	Girdiler	R	MAPE	RMSE
Elminir vd. (2005) [22]	Rüzgâr yönü, WS, R _{hum} , T _{avg} , bulutluluk	0,931-0,999		2,21-6,75
Mellit vd. (2005) [23]	Enl, Byl, Rkm	0,92		
Tymvios vd. (2005) [19]	n, N, T _{max}	0,9592		
Rehman ve Mohandes (2008) [25]	nGun, R _{hum} , T _{avg}		4,49	
Behrang vd. (2010) [32]	WS, nGun, n, R _{hum} , T _{avg}	0,9993	5,21	
Lu vd. (2011) [70]	Uydu verileri, Rkm, hava kütlesi	R ² : 0,83-0,85		2,86-3,09
Rahimikhoob (2010) [34]	H _o , T _{max} , T _{min}	R ² : 0,845-0,889		2,53-2,55
Landeras vd. (2012) [7]	nGun, H _o , T _{max} , T _{min} , açık hava ışıınımı			2,93
Linares-Rodriguez vd. (2013) [27]	11 adet meteoroloji uydu girdisi, açık hava GSR değeri	0,99		1,25
Amrouche ve Le Pivert (2014) [28]	En yakın 4 ağ kesişim noktası için yapılan sıcaklık ve GSR tahminleri			2,85
Zeynab vd. (2014) [35]	nGun, H _o , n, N, T _{max} , T _{min} , açık hava ışıınımı	0,889		3,3
Mohammadi vd. (2015) [36]	H _o , nN, T _{max} -T _{min} , T _{avg} , R _{hum} , su buhar basıncı		9,31	1,84
Mevcut çalışma	Rkm, nGun, n ve H_{avg}	0,9837	6,08	1,23

BÖLÜM 6

SONUÇ ve ÖNERİLER

Hava kirleticiler, coğrafi ve meteorolojik parametrelerin YSA tahmin performansı üzerine etkilerini incelemek üzere yapılan bu tez çalışmasında aşağıda özetlenen sonuçlara ulaşılmıştır.

- a. Çevre istasyonlara ait aylık GSR verilerinin, merkez istasyon aylık ortalama GSR tahmininde girdi olarak kullanılması performans göstergelerinde iyileşme sağlamıştır.
- b. Bu çalışmada hava kirleticilerden PM_{10} ve SO_2 parametrelerinin günlük GSR tahmini üzerindeki etkileri incelenmiştir. Bir konum için hava kirletici ortalaması yükseldiğinde hava kirletici ile GSR arasındaki korelasyon ters yönde artmaktadır. İlgili hava kirletici ortalamasının ve hava kirletici-GSR korelasyonunun yüksek olduğu bölgelerde GSR tahmin performansı, düşük olan bölgelere göre artmaktadır.
- c. Bir başka şekilde ifade edilirse, PM_{10} ve SO_2 parametreleri için bu kirleticilerin ortalama değerlerinin yüksek olduğu bölgelerde güneş enerjisinden yararlanma performansı düşme eğilimindedir.
- d. Hava kirleticiler için oluşturulan yüksek ve düşük ortalamalı veri grupları üzerinde elde edilen sonuçlara göre, SO_2 ile karşılaştırıldığında, PM_{10} parametresi ile GSR tahmin performansında daha fazla iyileşme sağlandığı görülmüştür.
- e. Kullanılan veriler ve oluşturulan modellerden elde edilen sonuçlara göre, PM_{10} ve SO_2 parametreleri ile coğrafi-meteorolojik faktörler karşılaştırıldığında, PM_{10} ve SO_2 'nin YSA modellerindeki GSR tahmin performansına katkısı coğrafi-meteorolojik parametrelere göre oldukça azdır.
- f. Coğrafi ve meteorolojik parametrelerin günlük GSR tahmini üzerine etkisini incelemek üzere 5 istasyon belirlendiğinden, konum parametrelerinden Enl, Byl

ve Rkm parametrelerinin tahmin performansına etkisi çok farklılık göstermemiştir. Bu nedenle, girdi sayısının artmaması için diğer analizlere Rkm parametresi ile devam edilmiştir.

- g. nGun parametresi daha iyi olmak üzere Ay, N, H₀ ve SinD coğrafi parametrelerinin tekli kombinasyonlarında performans açısından yakın sonuçlar verdiği görülmektedir.
- h. Tekli kombinasyonlarda meteorolojik parametreler ise MAPE performans göstergesine göre n, T_s, T_{avg}, T_{max}, T_{min}, R_{hum}, nN ve WS sıralamasında daha iyi sonuçlar vermiştir.
- i. Rkm parametresine ilave olarak diğer nGun, Ay, N, H₀ ve SinD parametrelerinin tekli kombinasyon sonuçlarına bakıldığında en iyi sonuç Rkm, nGun girdi parametreleri ile elde edilmiştir. Tüm kombinasyon sonuçlarına bakıldığında ise çok küçük farklar ile daha iyi sonuçlar elde edilse de YSA çalışma performansı açısından daha az girdi kullanılması uygun olacağından coğrafi parametreler olarak Rkm ve nGun ikilisi ile meteorolojik faktörlerin analizi yapılmıştır.
- j. Rkm, nGun parametrelerine ilaveten 8 meteorolojik parametrenin (R_{hum}, T_{min}, T_{avg}, T_{max}, T_s, WS, n, nN) tüm kombinasyonlarına ait modellerin performans sonuçlarına göre; n ve/veya nN parametrelerinin girdi olarak bulunduğu en düşük tahmin performansının, girdi olarak yer almadığı modellerin en yüksek tahmin performansına göre daha iyi olduğu sonucuna varılmıştır.
- k. Farklı kombinasyonlarda tüm veri seti üzerinden en iyi performans sonucunu veren modellere bakıldığında, üçlü kombinasyon ve sonrasında YSA tahmin performansında önemli bir gelişme olmamıştır. Eğitim veri seti performans göstergelerinde küçük iyileşmeler olsa da test veri setinde Rkm, nGun, n kombinasyonu sonrasında performans göstergelerinde düşüş gözlenmiştir. Test veri setindeki bu düşüş, özellikle MAPE performans göstergesinde daha belirgin olarak ortaya çıkmıştır.
- l. Bu tez kapsamında literatürden farklı olarak günlük GSR tahmin performansını artırmak üzere çevre istasyonların ortalama GSR verilerinin de girdi olarak eklendiği modellerin, girdi olarak eklenmediği modellere göre daha iyi sonuçlar verdiği görülmüştür.
- m. Rkm, nGun, n ve çevre istasyonların ortalama GSR verilerinin girdi olarak kullanıldığı YSA modelinin, özellikle test veri setinde R, MAPE ve RMSE

performans göstergeleri açısından daha iyi sonuçlar verdiği ve bu YSA modelinin tüm parametrelerin kullanıldığı modele göre yaklaşık 1/10 oranında daha kısa sürede hesaplama ve sonuç üretme işlemini gerçekleştirdiği görülmüştür.

Bu tez çalışması ile elde edilen sonuçlar ışığında aşağıdaki öneriler yapılmıştır:

- a. Hava kirletici verilerinin günlük GSR tahmin performansına etkisine bakıldığında; hava kirliliğinin sürekli artmasının sağlık sorunlarını ortaya çıkardığı bilinmektedir, fakat bu artış temel yaşam kaynaklarından olan güneş enerjisinden yararlanma miktarını da azaltacağı görülmektedir. Tüm ülkelerin hava kirliliği problemini en aza indirecek düzenlemeler ve uygulamalar geliştirmesi gerekmektedir.
- b. Bu çalışmada, PM₁₀ ve SO₂ kirleticilerinin etkisi incelenmiştir. ÇRLM tarafından geçmiş yıllara ait NO, NO₂, NO_x, O₃ ve CO hava kirleticileri için ölçümler yapılamadığından, ilgili parametrelerin etkileri bu çalışmada incelenememiştir. Ancak sonraki yıllarda bu parametreler için yeterli sayıda ölçüme ulaşıldığında bu faktörlerin etkisi ayrıca incelenebilir.
- c. Yine benzer şekilde bu tez çalışması kapsamında aylık veya günlük GSR tahmin performansını artırmak için geliştirilen yöntem, farklı parametreler veya daha yeni veriler ile tekrar kullanılabilir.
- d. Geliştirilen yöntem, güneş enerjisi sistemleri üzerine yapılacak çalışmalarda bölgenin GSR potansiyelini ortaya çıkarmak için kullanılabilir.
- e. Tez çalışmasında geliştirilen yöntemde, çevre istasyonların GSR verileri girdi olarak kullanıldığından, bir bölge için GSR haritalarının çıkarılmasında bir yöntem olarak değerlendirilebilir.

KAYNAKLAR

1. Esen, M. and Yuksel, T., "Isi borulu gunes enerjili termosifon duzlemsel kollektorun performansi", *Firat Universitesi Fen Ve Muhendislik Bilimleri Dergisi*, 12 (2): 201–207 (2000).
2. Coskun, C., Oktay, Z., and Dincer, I., "Estimation of monthly solar radiation distribution for solar energy system analysis", *Energy*, 36 (2): 1319–1323 (2011).
3. Azadeh, A., Maghsoudi, A., and Sohrabkhani, S., "An integrated artificial neural networks approach for predicting global radiation", *Energy Conversion And Management*, 50 (6): 1497–1505 (2009).
4. Öztürk, K., "Küresel İklim Değişikliği ve Türkiye'ye Olası Etkileri", *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 22 (1): (2002).
5. Hassan, M. A., Khalil, A., Kaseb, S., and Kassem, M. A., "Potential of four different machine-learning algorithms in modeling daily global solar radiation", *Renewable Energy*, 111: 52–62 (2017).
6. Sharifi, S. S., Rezaverdinejad, V., and Nourani, V., "Estimation of daily global solar radiation using wavelet regression, ANN, GEP and empirical models: A comparative study of selected temperature-based approaches", *Journal Of Atmospheric And Solar-Terrestrial Physics*, 149: 131–145 (2016).
7. Landeras, G., López, J. J., Kisi, O., and Shiri, J., "Comparison of Gene Expression Programming with neuro-fuzzy and neural network computing techniques in estimating daily incoming solar radiation in the Basque Country (Northern Spain)", *Energy Conversion And Management*, 62: 1–13 (2012).
8. Mehdizadeh, S., Behmanesh, J., and Khalili, K., "Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation", *Journal Of Atmospheric And Solar-Terrestrial Physics*, 146: 215–227 (2016).
9. Kurtgoz, Y. and Deniz, E., "Chapter 1.8 - Comparison of ANN, Regression Analysis, and ANFIS Models in Estimation of Global Solar Radiation for Different Climatological Locations", *Exergetic, Energetic and Environmental Dimensions, Academic Press*, 133–148 (2018).
10. Kurtgoz, Y. and Deniz, E., "Comparison of regression analysis ANN and ANFIS methods in the prediction of monthly mean global solar radiation: A case study", *8th International Exergy, Energy and Environment Symposium*, Antalya, 226–231 (2016).

11. Piri, J. and Kisi, O., "Modelling solar radiation reached to the Earth using ANFIS, NN-ARX, and empirical models (Case studies: Zahedan and Bojnurd stations)", *Journal Of Atmospheric And Solar-Terrestrial Physics*, 123: 39–47 (2015).
12. Quej, V. H., Almorox, J., Arnaldo, J. A., and Saito, L., "ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment", *Journal Of Atmospheric And Solar-Terrestrial Physics*, 155: 62–70 (2017).
13. Kurtgoz, Y. and Deniz, E., "Global solar radiation estimation using artificial neural network by the addition of nearby meteorological stations' solar radiation data and exergy of solar radiation: a case study", *International Journal Of Exergy*, 21 (3): 315–330 (2016).
14. Rensheng, C., Shihua, L., Ersi, K., Jianping, Y., and Xibin, J., "Estimating daily global radiation using two types of revised models in China", *Energy Conversion And Management*, 47 (7–8): 865–878 (2006).
15. Paoli, C., Voyant, C., Muselli, M., and Nivet, M.-L., "Forecasting of preprocessed daily solar radiation time series using neural networks", *Solar Energy*, 84 (12): 2146–2160 (2010).
16. Pusat, Ş., Akkoyunlu, M. T., and Ekmekci, İ., "Estimation of Global Solar Radiation and Sunshine Duration from GEPA for Selected Cities of Turkey", *International Conference on Advances in Science (ICAS 2016)*, Istanbul, 224–227 (2016).
17. Pusat, Ş. and Ekmekci, İ., "Evaluation of Monthly Global Solar Radiation Models for Denizli", *International Conference on Advances in Mechanical Engineering (ICAME'15)*, Istanbul, (2015).
18. Khatib, T., Mohamed, A., and Sopian, K., "A review of solar energy modeling techniques", *Renewable And Sustainable Energy Reviews*, 16 (5): 2864–2869 (2012).
19. Tymvios, F. S., Jacovides, C. P., Michaelides, S. C., and Scouteli, C., "Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation", *Solar Energy*, 78 (6): 752–762 (2005).
20. Şenkal, O., "Modeling of solar radiation using remote sensing and artificial neural network in Turkey", *Energy*, 35 (12): 4795–4801 (2010).
21. Jiang, H., Dong, Y., Wang, J., and Li, Y., "Intelligent optimization models based on hard-ridge penalty and RBF for forecasting global solar radiation", *Energy Conversion And Management*, 95 (Supplement C): 42–58 (2015).
22. Elminir, H. K., Areed, F. F., and Elsayed, T. S., "Estimation of solar radiation components incident on Helwan site using neural networks", *Solar Energy*, 79 (3): 270–279 (2005).

23. Mellit, A., Benghanem, M., Arab, A. H., and Guessoum, A., "A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach", *Solar Energy*, 79 (5): 469–482 (2005).
24. Sozen, A., Arcaklioglu, E., Ozalp, M., and Caglar, N., "Forecasting based on neural network approach of solar potential in Turkey", *Renewable Energy*, 30 (7): 1075–1090 (2005).
25. Rehman, S. and Mohandes, M., "Artificial neural network estimation of global solar radiation using air temperature and relative humidity", *Energy Policy*, 36 (2): 571–576 (2008).
26. Ozgoren, M., Bilgili, M., and Sahin, B., "Estimation of global solar radiation using ANN over Turkey", *Expert Systems With Applications*, 39 (5): 5043–5051 (2012).
27. Linares-Rodriguez, A., Ruiz-Arias, J. A., Pozo-Vazquez, D., and Tovar-Pescador, J., "An artificial neural network ensemble model for estimating global solar radiation from Meteosat satellite images", *Energy*, 61: 636–645 (2013).
28. Amrouche, B. and Le Pivert, X., "Artificial neural network based daily local forecasting for global solar radiation", *Applied Energy*, 130: 333–341 (2014).
29. Mohandes, M., Rehman, S., and Halawani, T. O., "Estimation of global solar radiation using artificial neural networks", *Renewable Energy*, 14 (1–4): 179–184 (1998).
30. Şenkal, O. and Kuleli, T., "Estimation of solar radiation over Turkey using artificial neural network and satellite data", *Applied Energy*, 86 (7–8): 1222–1228 (2009).
31. Koca, A., Oztop, H. F., Varol, Y., and Koca, G. O., "Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey", *Expert Systems With Applications*, 38 (7): 8756–8762 (2011).
32. Behrang, M. A., Assareh, E., Ghanbarzadeh, A., and Noghrehabadi, A. R., "The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data", *Solar Energy*, 84 (8): 1468–1480 (2010).
33. Al-Alawi, S. M. and Al-Hinai, H. A., "An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation", *Renewable Energy*, 14 (1–4): 199–204 (1998).
34. Rahimikhoob, A., "Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment", *Renewable Energy*, 35 (9): 2131–2135 (2010).

35. Ramedani, Z., Omid, M., Keyhani, A., Khoshnevisan, B., and Saboohi, H., "A comparative study between fuzzy linear regression and support vector regression for global solar radiation prediction in Iran", *Solar Energy*, 109 (Supplement C): 135–143 (2014).
36. Mohammadi, K., Shamsirband, S., Tong, C. W., Arif, M., Petković, D., and Ch, S., "A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation", *Energy Conversion And Management*, 92 (Supplement C): 162–171 (2015).
37. Yadav, A. K. and Chandel, S. S., "Solar radiation prediction using Artificial Neural Network techniques: A review", *Renewable And Sustainable Energy Reviews*, 33: 772–781 (2014).
38. Öztemel, E., "Yapay Sinir Ağları", *Papatya Yayıncılık*, İstanbul, (2003).
39. Elmas, Ç., "Yapay Zekâ Uygulamaları", *Seçkin Yayıncılık*, Ankara, (2011).
40. Haykin, S., "Neural Networks", *Prentice Hall, New Jersey*, (1999).
41. Anderson, D. and McNeill, G., "Artificial neural networks technology", *Kaman Sciences Corporation*, 258 (6): 1–83 (1992).
42. Negnevitsky, M., "Artificial Intelligence: A Guide to Intelligent Systems", *Pearson Education*, (2005).
43. Kamruzzaman, J., "Artificial Neural Networks in Finance and Manufacturing", *IGI Global*, (2006).
44. Duffie, J. A. and Beckman, W. A., "Solar Engineering of Thermal Processes", *John Wiley & Sons*, (2013).
45. Turk Togrul, I. and Onat, E., "A study for estimating solar radiation in Elazig using geographical and meteorological data", *Energy Conversion And Management*, 40 (14): 1577–1584 (1999).
46. Djafer, D., Irbah, A., and Zaiani, M., "Identification of clear days from solar irradiance observations using a new method based on the wavelet transform", *Renewable Energy*, 101 (Supplement C): 347–355 (2017).
47. Bendt, P., Collares-Pereira, M., and Rabl, A., "The frequency distribution of daily insolation values", *Solar Energy*, 27 (1): 1–5 (1981).
48. Ahmed, M. A., Ahmad, F., and Akhtar, M. W., "Estimation of global and diffuse solar radiation for Hyderabad, Sindh, Pakistan.", *Journal Of Basic & Applied Sciences*, 5 (2): 73–77 (2009).
49. de Carvalho Alves, M., Sanches, L., de Souza Nogueira, J., and Silva, V. A. M., "Effects of sky conditions measured by the clearness index on the estimation of solar radiation using a digital elevation model", *Atmospheric And Climate Sciences*, 3 (04): 618 (2013).

50. Montgomery, D. C. and Runger, G. C., "Applied Statistics and Probability for Engineers", *John Wiley & Sons*, (2010).
51. Field, A., "Discovering Statistics Using SPSS", *Sage Publications*, (2009).
52. Mendenhall, W. and Sincich, T., "Statistics for Engineering and the Sciences", *Prentice-Hall, Inc.*, (1995).
53. Zhang, J., Zhao, L., Deng, S., Xu, W., and Zhang, Y., "A critical review of the models used to estimate solar radiation", *Renewable And Sustainable Energy Reviews*, 70: 314–329 (2017).
54. Ibrahim, S., Daut, I., Irwan, Y. M., Irwanto, M., Gomesh, N., and Farhana, Z., "Linear Regression Model in Estimating Solar Radiation in Perlis", *Energy Procedia*, 18: 1402–1412 (2012).
55. Besharat, F., Dehghan, A. A., and Faghieh, A. R., "Empirical models for estimating global solar radiation: A review and case study", *Renewable And Sustainable Energy Reviews*, 21: 798–821 (2013).
56. Mohammadi, K., Shamshirband, S., Anisi, M. H., Alam, K. A., and Petković, D., "Support vector regression based prediction of global solar radiation on a horizontal surface", *Energy Conversion And Management*, 91: 433–441 (2015).
57. Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H., "The WEKA Data Mining Software", *SIGKDD Explorations*, 11 (1): 10–18 (2009).
58. Heaton, J., "Encog: Library of Interchangeable Machine Learning Models for Java and C#", *Journal Of Machine Learning Research*, 16: 1243–1247 (2015).
59. Chow, S. K. H., Lee, E. W. M., and Li, D. H. W., "Short-term prediction of photovoltaic energy generation by intelligent approach", *Energy And Buildings*, 55: 660–667 (2012).
60. Yadav, A. K., Malik, H., and Chandel, S. S., "Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models", *Renewable And Sustainable Energy Reviews*, 31: 509–519 (2014).
61. Yadav, A. K. and Chandel, S. S., "Solar energy potential assessment of western Himalayan Indian state of Himachal Pradesh using J48 algorithm of WEKA in ANN based prediction model", *Renewable Energy*, 75: 675–693 (2015).
62. Lazzaroni, M., Ferrari, S., Piuri, V., Salman, A., Cristaldi, L., and Faifer, M., "Models for solar radiation prediction based on different measurement sites", *Measurement*, 63: 346–363 (2015).
63. Qazi, A., Fayaz, H., Wadi, A., Raj, R. G., Rahim, N. A., and Khan, W. A., "The artificial neural network for solar radiation prediction and designing solar systems:

- a systematic literature review", *Journal Of Cleaner Production*, 104: 1–12 (2015).
64. Sfetsos, A. and Coonick, A. H., "Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques", *Solar Energy*, 68 (2): 169–178 (2000).
 65. Hasni, A., Sehli, A., Draoui, B., Bassou, A., and Amieur, B., "Estimating Global Solar Radiation Using Artificial Neural Network and Climate Data in the South-western Region of Algeria", *Energy Procedia*, 18 (Supplement C): 531–537 (2012).
 66. Çelik, Ö., Teke, A., and Yıldırım, H. B., "The optimized artificial neural network model with Levenberg–Marquardt algorithm for global solar radiation estimation in Eastern Mediterranean Region of Turkey", *Journal Of Cleaner Production*, 116 (Supplement C): 1–12 (2016).
 67. Voyant, C., Muselli, M., Paoli, C., and Nivet, M.-L., "Optimization of an artificial neural network dedicated to the multivariate forecasting of daily global radiation", *Energy*, 36 (1): 348–359 (2011).
 68. Sahin, M., Kaya, Y., and Uyar, M., "Comparison of ANN and MLR models for estimating solar radiation in Turkey using NOAA/AVHRR data", *Advances In Space Research*, 51 (5): 891–904 (2013).
 69. Yadav, A. K., Malik, H., and Chandel, S. S., "Application of rapid miner in ANN based prediction of solar radiation for assessment of solar energy resource potential of 76 sites in Northwestern India", *Renewable And Sustainable Energy Reviews*, 52: 1093–1106 (2015).
 70. Lu, N., Qin, J., Yang, K., and Sun, J., "A simple and efficient algorithm to estimate daily global solar radiation from geostationary satellite data", *Energy*, 36 (5): 3179–3188 (2011).



EK AÇIKLAMALAR A.

**COĞRAFİ ve METEOROLOJİK PARAMETRELERİN TEKLİ
KOMBİNASYONLARINA AİT TAHMİN PERFORMANSLARI**

Çizelge Ek A.1. Coğrafi ve meteorolojik parametrelerin tekli kombinasyonlarına ait tahmin performansları.

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
1	Enl	0,2100	45,42	6,63	0,2057	45,33	6,60	0,1578	45,60	6,70	0,1999	45,44	6,64
1	Byl	0,2081	45,60	6,64	0,2111	44,75	6,58	0,1576	45,59	6,70	0,1998	45,43	6,64
1	Rkm	0,2106	45,36	6,62	0,2035	45,55	6,63	0,1587	45,58	6,69	0,2000	45,44	6,64
1	nGun	0,8870	16,70	3,13	0,8833	17,07	3,17	0,8853	16,89	3,15	0,8860	16,81	3,14
1	Ay	0,8716	17,95	3,32	0,8692	18,03	3,35	0,8729	18,03	3,30	0,8714	17,98	3,32
1	N	0,8833	17,16	3,17	0,8787	17,62	3,24	0,8790	17,42	3,23	0,8816	17,30	3,20
1	H _o	0,8743	17,74	3,29	0,8687	18,21	3,35	0,8687	18,06	3,35	0,8722	17,90	3,31
1	SinD	0,8792	17,35	3,23	0,8724	17,73	3,30	0,8747	17,68	3,28	0,8770	17,49	3,25
1	R _{hum}	0,6439	32,23	5,18	0,6264	32,43	5,27	0,6468	30,37	5,26	0,6385	31,91	5,22
1	T _{min}	0,6779	29,08	4,98	0,6708	29,24	5,01	0,6116	31,90	5,37	0,6638	29,66	5,07
1	T _{avg}	0,7569	24,85	4,42	0,7558	25,61	4,46	0,7079	28,18	4,79	0,7474	25,65	4,50
1	T _{max}	0,7475	25,19	4,50	0,7446	25,70	4,53	0,6913	28,61	4,91	0,7362	25,96	4,59
1	T _s	0,7866	23,05	4,18	0,7788	23,68	4,25	0,7620	25,53	4,39	0,7804	23,66	4,24
1	WS	0,3836	41,58	6,25	0,3534	42,22	6,34	0,3165	42,18	6,46	0,3637	41,83	6,31
1	n	0,8435	21,30	3,64	0,8374	21,71	3,70	0,8546	20,21	3,54	0,8443	21,17	3,63
1	nN	0,5848	33,37	5,49	0,5674	34,04	5,58	0,6261	31,31	5,34	0,5880	33,10	5,48
1	H _{avg}	0,9407	11,77	2,30	0,9407	11,92	2,30	0,9346	11,88	2,41	0,9396	11,82	2,32



EK AÇIKLAMALAR B.

**BEŞ COĞRAFİ PARAMETRENİN TÜM KOMBİNASYONLARINA AİT
TAHMİN PERFORMANSLARI**

Çizelge Ek B.1. Rakım parametresine ilave olarak diğer beş coğrafi parametrenin tüm kombinasyonlarına ait tahmin performansları.

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
1	Rkm, nGun	0,9158	14,26	2,72	0,9139	14,35	2,75	0,9113	14,63	2,79	0,9146	14,35	2,74
1	Rkm, Ay	0,9041	15,42	2,90	0,8970	15,71	2,97	0,8994	15,69	2,96	0,9018	15,53	2,93
1	Rkm, N	0,9081	14,83	2,84	0,9034	15,34	2,90	0,8997	15,65	2,97	0,9055	15,09	2,88
1	Rkm, H ₀	0,9065	15,00	2,86	0,9029	15,26	2,91	0,8983	15,77	2,98	0,9041	15,20	2,89
1	Rkm, SinD	0,9082	14,85	2,83	0,9035	15,28	2,91	0,9000	15,60	2,96	0,9056	15,08	2,87
2	Rkm, H ₀ , SinD	0,9159	14,14	2,72	0,9146	14,52	2,74	0,9109	14,66	2,80	0,9147	14,32	2,74
2	Rkm, N, SinD	0,9072	14,97	2,85	0,9061	15,05	2,86	0,8997	15,66	2,96	0,9054	15,12	2,88
2	Rkm, N, H ₀	0,9151	14,25	2,73	0,9167	14,30	2,72	0,9108	14,69	2,80	0,9146	14,35	2,74
2	Rkm, Ay, SinD	0,9176	14,07	2,69	0,9108	14,54	2,79	0,9095	14,74	2,82	0,9147	14,30	2,74
2	Rkm, Ay, H ₀	0,9183	14,02	2,69	0,9096	14,66	2,80	0,9095	14,74	2,82	0,9148	14,29	2,74
2	Rkm, Ay, N	0,9172	14,08	2,70	0,9125	14,58	2,78	0,9103	14,69	2,81	0,9149	14,30	2,73
2	Rkm, nGun, SinD	0,9162	14,16	2,71	0,9148	14,30	2,74	0,9104	14,67	2,81	0,9148	14,29	2,74
2	Rkm, nGun, H ₀	0,9163	14,17	2,71	0,9136	14,44	2,76	0,9111	14,63	2,79	0,9148	14,31	2,74
2	Rkm, nGun, N	0,9168	14,13	2,71	0,9128	14,46	2,76	0,9111	14,65	2,80	0,9149	14,30	2,74
2	Rkm, nGun, Ay	0,9167	14,10	2,70	0,9137	14,61	2,77	0,9105	14,69	2,80	0,9149	14,32	2,73
3	Rkm, N, H ₀ , SinD	0,9165	14,12	2,70	0,9126	14,68	2,79	0,9108	14,70	2,80	0,9146	14,34	2,74
3	Rkm, Ay, H ₀ , SinD	0,9169	14,12	2,70	0,9141	14,29	2,74	0,9100	14,69	2,81	0,9150	14,27	2,73
3	Rkm, Ay, N, SinD	0,9174	14,03	2,70	0,9112	14,70	2,79	0,9094	14,74	2,82	0,9146	14,31	2,74
3	Rkm, Ay, N, H ₀	0,9177	14,00	2,69	0,9115	14,76	2,80	0,9103	14,67	2,81	0,9150	14,29	2,73

Çizelge Ek B.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
3	Rkm, nGun, H _o , SinD	0,9166	14,16	2,71	0,9126	14,51	2,77	0,9111	14,62	2,80	0,9147	14,32	2,74
3	Rkm, nGun, N, SinD	0,9168	14,16	2,71	0,9121	14,52	2,77	0,9113	14,62	2,79	0,9148	14,32	2,74
3	Rkm, nGun, N, H _o	0,9167	14,10	2,70	0,9130	14,58	2,77	0,9111	14,65	2,80	0,9148	14,30	2,74
3	Rkm, nGun, Ay, SinD	0,9178	14,05	2,69	0,9119	14,58	2,79	0,9106	14,66	2,80	0,9152	14,27	2,73
3	Rkm, nGun, Ay, H _o	0,9171	14,10	2,70	0,9133	14,41	2,76	0,9100	14,69	2,81	0,9150	14,27	2,73
3	Rkm, nGun, Ay, N	0,9179	14,12	2,69	0,9116	14,39	2,78	0,9104	14,68	2,81	0,9151	14,28	2,73
4	Rkm, nGun, Ay, N, H _o	0,9180	13,97	2,68	0,9116	14,79	2,80	0,9108	14,65	2,80	0,9153	14,27	2,73
4	Rkm, nGun, Ay, N, SinD	0,9182	14,02	2,68	0,9100	14,75	2,82	0,9106	14,64	2,80	0,9150	14,29	2,73
4	Rkm, nGun, Ay, H _o , SinD	0,9166	14,16	2,71	0,9154	14,17	2,72	0,9106	14,67	2,80	0,9152	14,26	2,73
4	Rkm, nGun, N, H _o , SinD	0,9166	14,15	2,71	0,9131	14,47	2,77	0,9109	14,65	2,80	0,9148	14,31	2,74
4	Rkm, Ay, N, H _o , SinD	0,9176	14,07	2,70	0,9110	14,60	2,78	0,9102	14,68	2,81	0,9148	14,29	2,74
5	Rkm, nGun, Ay, N, H _o , SinD	0,9171	14,06	2,70	0,9125	14,66	2,77	0,9112	14,60	2,79	0,9150	14,29	2,73



EK AÇIKLAMALAR C.

**SEKİZ METEOROLOJİK PARAMETRENİN TÜM
KOMBİNASYONLARINA AİT TAHMİN PERFORMANSLARI**

Çizelge Ek C.1. Sekiz meteorolojik parametrenin tüm kombinasyonlarına ait tahmin performansları.

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
1	Rkm, nGun, R _{hum}	0,9440	11,60	2,23	0,9399	12,15	2,32	0,9353	12,46	2,41	0,9413	11,88	2,29
1	Rkm, nGun, T _{min}	0,9245	13,02	2,58	0,9197	13,62	2,66	0,9179	13,88	2,69	0,9222	13,31	2,62
1	Rkm, nGun, T _{avg}	0,9245	13,36	2,58	0,9221	13,71	2,61	0,9172	14,31	2,70	0,9227	13,62	2,61
1	Rkm, nGun, T _{max}	0,9242	13,42	2,58	0,9206	14,12	2,66	0,9143	14,59	2,74	0,9215	13,79	2,63
1	Rkm, nGun, T _s	0,9290	13,09	2,51	0,9217	13,67	2,62	0,9185	14,38	2,69	0,9254	13,46	2,57
1	Rkm, nGun, WS	0,9193	13,84	2,67	0,9113	14,59	2,79	0,9101	14,76	2,81	0,9159	14,17	2,72
1	Rkm, nGun, n	0,9842	6,04	1,20	0,9827	6,47	1,26	0,9819	6,45	1,29	0,9834	6,21	1,23
1	Rkm, nGun, nN	0,9843	6,03	1,19	0,9826	6,44	1,26	0,9814	6,55	1,31	0,9834	6,21	1,23
2	Rkm, nGun, R _{hum} , T _{min}	0,9525	10,59	2,06	0,9495	11,01	2,12	0,9398	12,09	2,36	0,9491	10,97	2,14
2	Rkm, nGun, R _{hum} , T _{avg}	0,9495	10,91	2,13	0,9431	11,59	2,25	0,9364	12,46	2,40	0,9454	11,35	2,21
2	Rkm, nGun, R _{hum} , T _{max}	0,9479	11,18	2,16	0,9420	11,82	2,27	0,9355	12,66	2,41	0,9441	11,60	2,23
2	Rkm, nGun, R _{hum} , T _s	0,9471	11,14	2,17	0,9411	12,01	2,30	0,9355	12,61	2,41	0,9435	11,60	2,25
2	Rkm, nGun, R _{hum} , WS	0,9453	11,54	2,21	0,9388	12,13	2,33	0,9328	12,75	2,47	0,9414	11,90	2,29
2	Rkm, nGun, R _{hum} , n	0,9847	5,99	1,18	0,9820	6,50	1,28	0,9812	6,69	1,32	0,9834	6,23	1,23
2	Rkm, nGun, R _{hum} , nN	0,9844	6,03	1,19	0,9826	6,50	1,26	0,9808	6,76	1,33	0,9832	6,27	1,24
2	Rkm, nGun, T _{min} , T _{avg}	0,9503	10,82	2,11	0,9463	11,29	2,19	0,9441	11,66	2,23	0,9483	11,08	2,15
2	Rkm, nGun, T _{min} , T _{max}	0,9500	10,43	2,12	0,9439	11,01	2,23	0,9408	11,56	2,30	0,9470	10,77	2,18
2	Rkm, nGun, T _{min} , T _s	0,9564	10,34	1,98	0,9519	10,99	2,07	0,9430	12,12	2,30	0,9525	10,82	2,06
2	Rkm, nGun, T _{min} , WS	0,9278	12,80	2,53	0,9148	13,67	2,72	0,9169	13,90	2,71	0,9230	13,19	2,61

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
2	Rkm, nGun, T_{min} , n	0,9851	5,85	1,17	0,9830	6,26	1,23	0,9823	6,42	1,28	0,9841	6,04	1,20
2	Rkm, nGun, T_{min} , nN	0,9854	5,78	1,15	0,9833	6,30	1,24	0,9822	6,39	1,28	0,9843	6,00	1,20
2	Rkm, nGun, T_{avg} , T_{max}	0,9402	11,05	2,31	0,9332	11,68	2,43	0,9308	12,11	2,48	0,9370	11,39	2,37
2	Rkm, nGun, T_{avg} , T_s	0,9322	12,68	2,45	0,9239	13,55	2,58	0,9220	14,13	2,63	0,9285	13,14	2,52
2	Rkm, nGun, T_{avg} , WS	0,9278	13,09	2,53	0,9162	14,11	2,71	0,9156	14,35	2,73	0,9231	13,54	2,61
2	Rkm, nGun, T_{avg} , n	0,9855	5,75	1,15	0,9831	6,28	1,24	0,9820	6,52	1,29	0,9843	6,01	1,20
2	Rkm, nGun, T_{avg} , nN	0,9854	5,76	1,16	0,9833	6,31	1,23	0,9823	6,47	1,28	0,9843	6,01	1,20
2	Rkm, nGun, T_{max} , T_s	0,9322	12,48	2,45	0,9263	12,91	2,55	0,9209	13,84	2,65	0,9288	12,83	2,51
2	Rkm, nGun, T_{max} , WS	0,9277	13,13	2,53	0,9195	13,88	2,67	0,9123	14,68	2,78	0,9231	13,58	2,61
2	Rkm, nGun, T_{max} , n	0,9851	5,82	1,16	0,9835	6,25	1,22	0,9822	6,56	1,28	0,9842	6,05	1,20
2	Rkm, nGun, T_{max} , nN	0,9856	5,76	1,15	0,9828	6,32	1,25	0,9823	6,51	1,28	0,9843	6,02	1,19
2	Rkm, nGun, T_s , WS	0,9296	12,94	2,50	0,9224	13,75	2,62	0,9196	14,22	2,67	0,9262	13,35	2,56
2	Rkm, nGun, T_s , n	0,9856	5,79	1,14	0,9832	6,31	1,23	0,9807	6,68	1,33	0,9842	6,07	1,20
2	Rkm, nGun, T_s , nN	0,9855	5,83	1,15	0,9832	6,32	1,23	0,9811	6,66	1,32	0,9841	6,09	1,20
2	Rkm, nGun, WS, n	0,9842	6,09	1,20	0,9814	6,62	1,30	0,9817	6,51	1,30	0,9831	6,28	1,24
2	Rkm, nGun, WS, nN	0,9838	6,15	1,22	0,9817	6,67	1,29	0,9820	6,49	1,29	0,9830	6,32	1,24
2	Rkm, nGun, n, nN	0,9841	6,05	1,20	0,9827	6,43	1,25	0,9817	6,49	1,30	0,9833	6,22	1,23
3	Rkm, nGun, R_{hum} , T_{min} , T_{avg}	0,9587	9,80	1,93	0,9534	10,56	2,05	0,9478	11,26	2,17	0,9554	10,24	2,00
3	Rkm, nGun, R_{hum} , T_{min} , T_{max}	0,9599	9,45	1,90	0,9539	10,23	2,03	0,9483	10,94	2,16	0,9564	9,90	1,98

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
3	Rkm, nGun, R _{hum} , T _{min} , T _s	0,9635	9,32	1,81	0,9596	9,92	1,90	0,9490	11,16	2,14	0,9599	9,80	1,90
3	Rkm, nGun, R _{hum} , T _{min} , WS	0,9547	10,42	2,02	0,9459	11,24	2,19	0,9395	12,15	2,37	0,9496	10,92	2,13
3	Rkm, nGun, R _{hum} , T _{min} , n	0,9860	5,69	1,13	0,9833	6,30	1,23	0,9814	6,61	1,31	0,9845	5,99	1,19
3	Rkm, nGun, R _{hum} , T _{min} , nN	0,9862	5,65	1,12	0,9830	6,37	1,25	0,9811	6,72	1,32	0,9845	6,00	1,19
3	Rkm, nGun, R _{hum} , T _{avg} , T _{max}	0,9559	9,66	1,99	0,9509	10,50	2,10	0,9435	11,35	2,26	0,9524	10,16	2,07
3	Rkm, nGun, R _{hum} , T _{avg} , T _s	0,9533	10,51	2,04	0,9468	11,31	2,19	0,9396	12,15	2,33	0,9492	10,99	2,13
3	Rkm, nGun, R _{hum} , T _{avg} , WS	0,9501	10,90	2,11	0,9426	11,77	2,27	0,9362	12,50	2,41	0,9456	11,39	2,20
3	Rkm, nGun, R _{hum} , T _{avg} , n	0,9861	5,63	1,12	0,9835	6,24	1,23	0,9815	6,61	1,30	0,9847	5,94	1,18
3	Rkm, nGun, R _{hum} , T _{avg} , nN	0,9862	5,60	1,12	0,9834	6,23	1,23	0,9816	6,62	1,30	0,9847	5,93	1,18
3	Rkm, nGun, R _{hum} , T _{max} , T _s	0,9522	10,52	2,07	0,9452	11,46	2,21	0,9357	12,63	2,40	0,9475	11,12	2,17
3	Rkm, nGun, R _{hum} , T _{max} , WS	0,9492	11,06	2,14	0,9421	11,87	2,27	0,9349	12,83	2,42	0,9449	11,57	2,22
3	Rkm, nGun, R _{hum} , T _{max} , n	0,9863	5,60	1,12	0,9834	6,29	1,23	0,9814	6,64	1,31	0,9847	5,94	1,18
3	Rkm, nGun, R _{hum} , T _{max} , nN	0,9861	5,67	1,13	0,9831	6,31	1,24	0,9820	6,57	1,29	0,9847	5,98	1,18
3	Rkm, nGun, R _{hum} , T _s , WS	0,9482	11,13	2,15	0,9396	11,98	2,32	0,9349	12,68	2,43	0,9437	11,60	2,24
3	Rkm, nGun, R _{hum} , T _s , n	0,9857	5,75	1,14	0,9836	6,25	1,22	0,9812	6,65	1,32	0,9844	6,03	1,19
3	Rkm, nGun, R _{hum} , T _s , nN	0,9858	5,76	1,14	0,9830	6,28	1,24	0,9812	6,67	1,32	0,9843	6,05	1,20
3	Rkm, nGun, R _{hum} , WS, n	0,9847	5,96	1,18	0,9820	6,60	1,28	0,9815	6,68	1,31	0,9835	6,23	1,23
3	Rkm, nGun, R _{hum} , WS, nN	0,9843	6,06	1,20	0,9821	6,54	1,28	0,9813	6,71	1,31	0,9832	6,28	1,24
3	Rkm, nGun, R _{hum} , n, nN	0,9844	6,02	1,19	0,9826	6,44	1,26	0,9811	6,68	1,33	0,9834	6,23	1,23

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
3	Rkm, nGun, T_{min} , T_{avg} , T_{max}	0,9550	9,80	2,01	0,9508	10,50	2,10	0,9488	10,83	2,14	0,9529	10,14	2,05
3	Rkm, nGun, T_{min} , T_{avg} , T_s	0,9602	9,85	1,89	0,9551	10,54	2,01	0,9477	11,55	2,19	0,9565	10,32	1,98
3	Rkm, nGun, T_{min} , T_{avg} , WS	0,9534	10,49	2,04	0,9451	11,41	2,22	0,9428	11,66	2,26	0,9496	10,90	2,12
3	Rkm, nGun, T_{min} , T_{avg} , n	0,9861	5,65	1,13	0,9839	6,05	1,21	0,9831	6,34	1,25	0,9850	5,87	1,17
3	Rkm, nGun, T_{min} , T_{avg} , nN	0,9858	5,67	1,13	0,9841	6,08	1,20	0,9833	6,31	1,25	0,9849	5,88	1,17
3	Rkm, nGun, T_{min} , T_{max} , T_s	0,9613	9,43	1,87	0,9554	10,35	2,00	0,9463	11,46	2,23	0,9569	10,01	1,97
3	Rkm, nGun, T_{min} , T_{max} , WS	0,9523	10,18	2,07	0,9450	10,89	2,21	0,9420	11,37	2,28	0,9488	10,56	2,14
3	Rkm, nGun, T_{min} , T_{max} , n	0,9858	5,69	1,14	0,9838	6,13	1,21	0,9831	6,46	1,26	0,9848	5,93	1,18
3	Rkm, nGun, T_{min} , T_{max} , nN	0,9860	5,62	1,13	0,9838	6,18	1,22	0,9831	6,39	1,25	0,9849	5,88	1,17
3	Rkm, nGun, T_{min} , T_s , WS	0,9577	10,19	1,95	0,9504	10,98	2,10	0,9427	12,06	2,30	0,9530	10,72	2,05
3	Rkm, nGun, T_{min} , T_s , n	0,9870	5,55	1,09	0,9842	6,12	1,20	0,9813	6,76	1,32	0,9853	5,90	1,16
3	Rkm, nGun, T_{min} , T_s , nN	0,9872	5,48	1,08	0,9841	6,20	1,20	0,9813	6,82	1,32	0,9854	5,89	1,16
3	Rkm, nGun, T_{min} , WS, n	0,9853	5,85	1,16	0,9828	6,36	1,25	0,9822	6,50	1,28	0,9841	6,08	1,20
3	Rkm, nGun, T_{min} , WS, nN	0,9855	5,78	1,15	0,9820	6,45	1,28	0,9820	6,53	1,29	0,9841	6,06	1,21
3	Rkm, nGun, T_{min} , n, nN	0,9854	5,75	1,15	0,9833	6,27	1,24	0,9822	6,40	1,28	0,9843	5,98	1,20
3	Rkm, nGun, T_{avg} , n, nN	0,9856	5,72	1,15	0,9828	6,29	1,25	0,9821	6,53	1,28	0,9843	5,99	1,20
3	Rkm, nGun, T_{avg} , WS, nN	0,9856	5,75	1,15	0,9823	6,32	1,26	0,9820	6,53	1,28	0,9842	6,02	1,20
3	Rkm, nGun, T_{avg} , WS, n	0,9854	5,79	1,15	0,9823	6,42	1,27	0,9819	6,65	1,29	0,9841	6,08	1,21
3	Rkm, nGun, T_{avg} , T_s , nN	0,9861	5,65	1,12	0,9843	6,18	1,20	0,9813	6,64	1,31	0,9847	5,95	1,18

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
3	Rkm, nGun, T_{avg} , T_s , n	0,9861	5,67	1,13	0,9838	6,17	1,21	0,9811	6,73	1,33	0,9846	5,98	1,18
3	Rkm, nGun, T_{avg} , T_s , WS	0,9339	12,49	2,42	0,9236	13,53	2,60	0,9193	14,29	2,68	0,9289	13,05	2,51
3	Rkm, nGun, T_{avg} , T_{max} , nN	0,9858	5,67	1,14	0,9840	6,13	1,21	0,9825	6,50	1,28	0,9847	5,93	1,18
3	Rkm, nGun, T_{avg} , T_{max} , n	0,9858	5,68	1,14	0,9835	6,18	1,23	0,9824	6,49	1,28	0,9846	5,94	1,18
3	Rkm, nGun, T_{avg} , T_{max} , WS	0,9411	11,03	2,29	0,9323	11,68	2,44	0,9281	12,37	2,53	0,9368	11,43	2,37
3	Rkm, nGun, T_{avg} , T_{max} , T_s	0,9441	10,80	2,23	0,9371	11,48	2,37	0,9348	11,99	2,41	0,9408	11,17	2,30
3	Rkm, nGun, T_{max} , n, nN	0,9853	5,78	1,16	0,9837	6,21	1,22	0,9823	6,49	1,28	0,9843	6,01	1,19
3	Rkm, nGun, T_{max} , WS, nN	0,9855	5,85	1,15	0,9809	6,52	1,31	0,9819	6,63	1,29	0,9839	6,14	1,21
3	Rkm, nGun, T_{max} , WS, n	0,9849	5,89	1,17	0,9828	6,28	1,25	0,9822	6,57	1,28	0,9840	6,10	1,21
3	Rkm, nGun, T_{max} , T_s , nN	0,9865	5,61	1,11	0,9841	6,19	1,21	0,9811	6,80	1,33	0,9849	5,96	1,17
3	Rkm, nGun, T_{max} , T_s , n	0,9867	5,56	1,10	0,9843	6,13	1,20	0,9813	6,66	1,32	0,9851	5,89	1,17
3	Rkm, nGun, T_{max} , T_s , WS	0,9341	12,26	2,42	0,9250	13,13	2,58	0,9184	14,06	2,69	0,9291	12,79	2,51
3	Rkm, nGun, T_s , WS, n	0,9855	5,84	1,15	0,9827	6,31	1,25	0,9813	6,63	1,31	0,9841	6,09	1,21
3	Rkm, nGun, T_s , WS, nN	0,9855	5,77	1,15	0,9828	6,44	1,25	0,9812	6,70	1,31	0,9841	6,09	1,20
3	Rkm, nGun, T_s , n, nN	0,9854	5,81	1,15	0,9834	6,29	1,23	0,9815	6,57	1,30	0,9842	6,06	1,20
3	Rkm, nGun, WS, n, nN	0,9838	6,15	1,21	0,9822	6,54	1,28	0,9823	6,41	1,28	0,9832	6,28	1,24
4	Rkm, nGun, T_s , WS, n, nN	0,9855	5,81	1,15	0,9828	6,42	1,25	0,9815	6,65	1,30	0,9842	6,10	1,20
4	Rkm, nGun, T_{max} , WS, n, nN	0,9853	5,82	1,16	0,9828	6,26	1,25	0,9822	6,56	1,28	0,9842	6,05	1,20
4	Rkm, nGun, T_{max} , T_s , n, nN	0,9865	5,59	1,11	0,9841	6,20	1,21	0,9813	6,76	1,32	0,9849	5,94	1,17

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
4	Rkm, nGun, T _{max} , T _s , WS, nN	0,9864	5,63	1,11	0,9841	6,21	1,21	0,9811	6,79	1,33	0,9848	5,97	1,18
4	Rkm, nGun, T _{max} , T _s , WS, n	0,9859	5,72	1,13	0,9837	6,26	1,23	0,9811	6,77	1,33	0,9845	6,04	1,19
4	Rkm, nGun, T _{avg} , WS, n, nN	0,9855	5,72	1,15	0,9827	6,36	1,25	0,9819	6,60	1,29	0,9842	6,02	1,20
4	Rkm, nGun, T _{avg} , T _s , n, nN	0,9864	5,61	1,11	0,9838	6,19	1,21	0,9810	6,69	1,33	0,9848	5,94	1,18
4	Rkm, nGun, T _{avg} , T _s , WS, nN	0,9862	5,68	1,12	0,9830	6,38	1,25	0,9809	6,77	1,33	0,9844	6,04	1,19
4	Rkm, nGun, T _{avg} , T _s , WS, n	0,9866	5,57	1,11	0,9832	6,28	1,23	0,9808	6,77	1,34	0,9847	5,95	1,18
4	Rkm, nGun, T _{avg} , T _{max} , n, nN	0,9860	5,61	1,13	0,9836	6,24	1,22	0,9824	6,50	1,28	0,9848	5,91	1,18
4	Rkm, nGun, T _{avg} , T _{max} , WS, nN	0,9857	5,69	1,14	0,9834	6,28	1,24	0,9821	6,57	1,28	0,9845	5,98	1,19
4	Rkm, nGun, T _{avg} , T _{max} , WS, n	0,9862	5,58	1,12	0,9824	6,33	1,27	0,9821	6,56	1,29	0,9846	5,92	1,19
4	Rkm, nGun, T _{avg} , T _{max} , T _s , nN	0,9867	5,57	1,10	0,9841	6,08	1,20	0,9817	6,67	1,31	0,9851	5,89	1,16
4	Rkm, nGun, T _{avg} , T _{max} , T _s , n	0,9867	5,55	1,10	0,9846	6,10	1,19	0,9814	6,72	1,32	0,9852	5,89	1,16
4	Rkm, nGun, T _{avg} , T _{max} , T _s , WS	0,9455	10,65	2,21	0,9363	11,48	2,38	0,9316	12,27	2,47	0,9409	11,13	2,30
4	Rkm, nGun, T _{min} , WS, n, nN	0,9856	5,78	1,15	0,9822	6,43	1,27	0,9820	6,50	1,29	0,9842	6,05	1,20
4	Rkm, nGun, T _{min} , T _s , n, nN	0,9871	5,50	1,08	0,9841	6,18	1,21	0,9814	6,75	1,32	0,9853	5,88	1,16
4	Rkm, nGun, T _{min} , T _s , WS, nN	0,9868	5,58	1,10	0,9840	6,24	1,21	0,9816	6,80	1,31	0,9852	5,95	1,16
4	Rkm, nGun, T _{min} , T _s , WS, n	0,9871	5,51	1,08	0,9838	6,27	1,21	0,9810	6,87	1,33	0,9852	5,93	1,16
4	Rkm, nGun, T _{min} , T _{max} , n, nN	0,9861	5,61	1,12	0,9838	6,07	1,22	0,9833	6,35	1,24	0,9850	5,85	1,17
4	Rkm, nGun, T _{min} , T _{max} , WS, nN	0,9863	5,58	1,12	0,9832	6,25	1,23	0,9827	6,49	1,27	0,9849	5,89	1,17
4	Rkm, nGun, T _{min} , T _{max} , WS, n	0,9860	5,63	1,13	0,9833	6,27	1,24	0,9829	6,46	1,26	0,9848	5,92	1,18

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
4	Rkm, nGun, T _{min} , T _{max} , T _s , nN	0,9872	5,46	1,08	0,9847	6,08	1,18	0,9821	6,65	1,29	0,9856	5,82	1,14
4	Rkm, nGun, T _{min} , T _{max} , T _s , n	0,9876	5,36	1,06	0,9850	6,03	1,17	0,9819	6,73	1,31	0,9859	5,76	1,14
4	Rkm, nGun, T _{min} , T _{max} , T _s , WS	0,9620	9,36	1,85	0,9553	10,14	2,00	0,9475	11,20	2,19	0,9576	9,88	1,95
4	Rkm, nGun, T _{min} , T _{avg} , n, nN	0,9863	5,59	1,12	0,9836	6,14	1,22	0,9829	6,37	1,26	0,9850	5,85	1,17
4	Rkm, nGun, T _{min} , T _{avg} , WS, nN	0,9862	5,62	1,12	0,9829	6,34	1,24	0,9828	6,47	1,26	0,9848	5,93	1,18
4	Rkm, nGun, T _{min} , T _{avg} , WS, n	0,9859	5,69	1,13	0,9833	6,22	1,23	0,9830	6,44	1,25	0,9848	5,95	1,18
4	Rkm, nGun, T _{min} , T _{avg} , T _s , nN	0,9870	5,49	1,09	0,9847	6,13	1,19	0,9818	6,75	1,30	0,9854	5,86	1,15
4	Rkm, nGun, T _{min} , T _{avg} , T _s , n	0,9868	5,55	1,09	0,9852	5,98	1,16	0,9818	6,70	1,31	0,9854	5,86	1,15
4	Rkm, nGun, T _{min} , T _{avg} , T _s , WS	0,9621	9,66	1,85	0,9540	10,62	2,04	0,9467	11,65	2,21	0,9573	10,25	1,96
4	Rkm, nGun, T _{min} , T _{avg} , T _{max} , nN	0,9864	5,57	1,11	0,9839	6,16	1,21	0,9828	6,44	1,26	0,9851	5,86	1,16
4	Rkm, nGun, T _{min} , T _{avg} , T _{max} , n	0,9864	5,56	1,11	0,9840	6,10	1,21	0,9829	6,48	1,26	0,9852	5,85	1,16
4	Rkm, nGun, T _{min} , T _{avg} , T _{max} , WS	0,9579	9,56	1,94	0,9526	10,30	2,06	0,9483	10,82	2,16	0,9550	9,95	2,01
4	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s	0,9637	9,05	1,81	0,9572	9,86	1,96	0,9517	10,90	2,11	0,9598	9,57	1,90
4	Rkm, nGun, R _{hum} , WS, n, nN	0,9847	5,97	1,18	0,9820	6,54	1,28	0,9814	6,67	1,31	0,9835	6,22	1,23
4	Rkm, nGun, R _{hum} , T _s , n, nN	0,9859	5,72	1,14	0,9832	6,30	1,24	0,9811	6,65	1,32	0,9843	6,02	1,19
4	Rkm, nGun, R _{hum} , T _s , WS, nN	0,9860	5,67	1,13	0,9834	6,34	1,23	0,9808	6,74	1,33	0,9844	6,01	1,19
4	Rkm, nGun, R _{hum} , T _s , WS, n	0,9862	5,67	1,12	0,9829	6,31	1,25	0,9806	6,68	1,33	0,9844	5,99	1,19
4	Rkm, nGun, R _{hum} , T _{max} , n, nN	0,9861	5,64	1,12	0,9837	6,19	1,22	0,9818	6,60	1,29	0,9848	5,94	1,18
4	Rkm, nGun, R _{hum} , T _{max} , WS, nN	0,9866	5,55	1,11	0,9827	6,45	1,26	0,9815	6,71	1,30	0,9848	5,96	1,18

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
4	Rkm, nGun, R _{hum} , T _{max} , WS, n	0,9863	5,66	1,12	0,9826	6,29	1,26	0,9816	6,70	1,30	0,9846	5,99	1,19
4	Rkm, nGun, R _{hum} , T _{max} , T _s , nN	0,9870	5,51	1,09	0,9845	6,11	1,19	0,9812	6,69	1,32	0,9853	5,86	1,16
4	Rkm, nGun, R _{hum} , T _{max} , T _s , n	0,9871	5,47	1,08	0,9844	6,15	1,19	0,9813	6,71	1,32	0,9854	5,85	1,15
4	Rkm, nGun, R _{hum} , T _{max} , T _s , WS	0,9522	10,60	2,07	0,9443	11,45	2,23	0,9385	12,31	2,35	0,9478	11,11	2,16
4	Rkm, nGun, R _{hum} , T _{avg} , n, nN	0,9860	5,67	1,13	0,9838	6,20	1,22	0,9816	6,63	1,30	0,9847	5,96	1,18
4	Rkm, nGun, R _{hum} , T _{avg} , WS, nN	0,9861	5,63	1,12	0,9831	6,28	1,24	0,9815	6,68	1,30	0,9846	5,96	1,18
4	Rkm, nGun, R _{hum} , T _{avg} , WS, n	0,9861	5,63	1,12	0,9831	6,32	1,25	0,9814	6,67	1,30	0,9846	5,97	1,19
4	Rkm, nGun, R _{hum} , T _{avg} , T _s , nN	0,9866	5,55	1,10	0,9844	6,14	1,20	0,9807	6,70	1,34	0,9850	5,89	1,17
4	Rkm, nGun, R _{hum} , T _{avg} , T _s , n	0,9867	5,55	1,10	0,9839	6,17	1,21	0,9810	6,69	1,33	0,9850	5,90	1,17
4	Rkm, nGun, R _{hum} , T _{avg} , T _s , WS	0,9548	10,39	2,02	0,9445	11,50	2,22	0,9392	12,31	2,34	0,9496	10,99	2,13
4	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , nN	0,9865	5,53	1,11	0,9838	6,23	1,22	0,9817	6,64	1,30	0,9850	5,89	1,17
4	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , n	0,9863	5,60	1,12	0,9835	6,21	1,22	0,9817	6,59	1,30	0,9848	5,92	1,18
4	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , WS	0,9570	9,58	1,96	0,9513	10,43	2,09	0,9417	11,38	2,30	0,9527	10,10	2,06
4	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , T _s	0,9595	9,34	1,91	0,9523	10,28	2,08	0,9440	11,28	2,25	0,9550	9,90	2,01
4	Rkm, nGun, R _{hum} , T _{min} , n, nN	0,9860	5,65	1,13	0,9834	6,31	1,23	0,9817	6,60	1,30	0,9846	5,97	1,18
4	Rkm, nGun, R _{hum} , T _{min} , WS, nN	0,9860	5,66	1,13	0,9831	6,39	1,25	0,9814	6,64	1,31	0,9845	6,00	1,19
4	Rkm, nGun, R _{hum} , T _{min} , WS, n	0,9861	5,68	1,13	0,9833	6,33	1,23	0,9816	6,64	1,30	0,9846	6,00	1,18
4	Rkm, nGun, R _{hum} , T _{min} , T _s , nN	0,9871	5,50	1,09	0,9846	6,12	1,18	0,9813	6,72	1,32	0,9854	5,86	1,15
4	Rkm, nGun, R _{hum} , T _{min} , T _s , n	0,9872	5,48	1,08	0,9844	6,19	1,19	0,9808	6,80	1,33	0,9853	5,88	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
4	Rkm, nGun, R _{hum} , T _{min} , T _s , WS	0,9646	9,23	1,79	0,9576	10,15	1,95	0,9476	11,26	2,17	0,9599	9,81	1,90
4	Rkm, nGun, R _{hum} , T _{min} , T _{max} , nN	0,9865	5,55	1,11	0,9841	6,11	1,20	0,9824	6,57	1,27	0,9852	5,86	1,16
4	Rkm, nGun, R _{hum} , T _{min} , T _{max} , n	0,9869	5,50	1,09	0,9836	6,21	1,22	0,9818	6,66	1,30	0,9852	5,87	1,16
4	Rkm, nGun, R _{hum} , T _{min} , T _{max} , WS	0,9612	9,38	1,87	0,9520	10,32	2,06	0,9470	11,08	2,19	0,9565	9,90	1,98
4	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s	0,9658	8,90	1,76	0,9610	9,67	1,88	0,9513	10,81	2,10	0,9619	9,43	1,85
4	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , nN	0,9864	5,57	1,11	0,9837	6,19	1,22	0,9821	6,54	1,28	0,9850	5,89	1,17
4	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , n	0,9864	5,56	1,11	0,9841	6,15	1,21	0,9821	6,52	1,28	0,9850	5,87	1,17
4	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , WS	0,9592	9,78	1,91	0,9531	10,56	2,05	0,9475	11,19	2,18	0,9556	10,21	2,00
4	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s	0,9657	9,07	1,76	0,9604	9,84	1,89	0,9513	11,02	2,10	0,9618	9,60	1,86
4	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max}	0,9629	9,04	1,83	0,9555	9,90	1,99	0,9513	10,54	2,10	0,9591	9,51	1,92
5	Rkm, nGun, T _{max} , T _s , WS, n, nN	0,9867	5,58	1,10	0,9837	6,18	1,22	0,9808	6,83	1,34	0,9849	5,94	1,17
5	Rkm, nGun, T _{avg} , T _s , WS, n, nN	0,9862	5,65	1,12	0,9837	6,27	1,22	0,9810	6,76	1,33	0,9846	5,99	1,19
5	Rkm, nGun, T _{avg} , T _{max} , WS, n, nN	0,9860	5,65	1,13	0,9828	6,28	1,25	0,9821	6,59	1,28	0,9846	5,96	1,19
5	Rkm, nGun, T _{avg} , T _{max} , T _s , n, nN	0,9868	5,49	1,09	0,9845	6,11	1,19	0,9818	6,67	1,30	0,9853	5,85	1,16
5	Rkm, nGun, T _{avg} , T _{max} , T _s , WS, nN	0,9867	5,56	1,10	0,9831	6,31	1,24	0,9813	6,73	1,32	0,9849	5,94	1,18
5	Rkm, nGun, T _{avg} , T _{max} , T _s , WS, n	0,9867	5,53	1,10	0,9840	6,19	1,21	0,9810	6,79	1,33	0,9850	5,91	1,17
5	Rkm, nGun, T _{min} , T _s , WS, n, nN	0,9867	5,59	1,10	0,9844	6,13	1,19	0,9819	6,67	1,30	0,9852	5,91	1,16
5	Rkm, nGun, T _{min} , T _{max} , WS, n, nN	0,9862	5,62	1,12	0,9834	6,16	1,23	0,9829	6,42	1,26	0,9850	5,89	1,17
5	Rkm, nGun, T _{min} , T _{max} , T _s , n, nN	0,9873	5,43	1,08	0,9853	6,03	1,16	0,9822	6,65	1,29	0,9858	5,79	1,14

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
5	Rkm, nGun, T _{min} , T _{max} , T _s , WS, nN	0,9871	5,50	1,08	0,9846	6,10	1,18	0,9818	6,72	1,31	0,9855	5,86	1,15
5	Rkm, nGun, T _{min} , T _{max} , T _s , WS, n	0,9877	5,35	1,06	0,9845	6,12	1,19	0,9814	6,77	1,33	0,9857	5,79	1,14
5	Rkm, nGun, T _{min} , T _{avg} , WS, n, nN	0,9863	5,58	1,12	0,9834	6,29	1,23	0,9828	6,46	1,26	0,9850	5,90	1,17
5	Rkm, nGun, T _{min} , T _{avg} , T _s , n, nN	0,9872	5,45	1,08	0,9846	6,06	1,18	0,9823	6,56	1,29	0,9857	5,79	1,14
5	Rkm, nGun, T _{min} , T _{avg} , T _s , WS, nN	0,9876	5,39	1,06	0,9836	6,21	1,22	0,9814	6,72	1,32	0,9855	5,81	1,15
5	Rkm, nGun, T _{min} , T _{avg} , T _s , WS, n	0,9872	5,49	1,08	0,9844	6,03	1,19	0,9817	6,72	1,31	0,9855	5,84	1,15
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , n, nN	0,9865	5,55	1,11	0,9839	6,13	1,20	0,9831	6,40	1,25	0,9853	5,83	1,16
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , WS, nN	0,9867	5,51	1,10	0,9831	6,28	1,24	0,9827	6,52	1,27	0,9851	5,86	1,16
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , WS, n	0,9865	5,51	1,11	0,9841	6,18	1,21	0,9829	6,50	1,26	0,9853	5,84	1,16
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , nN	0,9877	5,38	1,06	0,9841	6,16	1,20	0,9823	6,63	1,29	0,9858	5,78	1,14
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , n	0,9874	5,47	1,07	0,9843	6,05	1,20	0,9822	6,64	1,29	0,9857	5,81	1,14
5	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , WS	0,9651	8,88	1,77	0,9580	9,85	1,94	0,9504	10,87	2,14	0,9606	9,46	1,88
5	Rkm, nGun, R _{hum} , T _s , WS, n, nN	0,9859	5,69	1,13	0,9835	6,29	1,23	0,9814	6,62	1,31	0,9845	5,99	1,19
5	Rkm, nGun, R _{hum} , T _{max} , WS, n, nN	0,9860	5,68	1,13	0,9834	6,23	1,23	0,9823	6,56	1,28	0,9847	5,96	1,18
5	Rkm, nGun, R _{hum} , T _{max} , T _s , n, nN	0,9867	5,56	1,10	0,9845	6,18	1,19	0,9817	6,62	1,30	0,9853	5,89	1,16
5	Rkm, nGun, R _{hum} , T _{max} , T _s , WS, nN	0,9872	5,47	1,08	0,9834	6,29	1,23	0,9810	6,78	1,32	0,9852	5,89	1,16
5	Rkm, nGun, R _{hum} , T _{max} , T _s , WS, n	0,9871	5,48	1,09	0,9839	6,20	1,21	0,9810	6,75	1,33	0,9852	5,87	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
5	Rkm, nGun, R _{hum} , T _{avg} , WS, n, nN	0,9862	5,61	1,12	0,9832	6,24	1,23	0,9822	6,54	1,28	0,9848	5,92	1,18
5	Rkm, nGun, R _{hum} , T _{avg} , T _s , n, nN	0,9868	5,54	1,10	0,9839	6,16	1,21	0,9809	6,71	1,33	0,9850	5,89	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _s , WS, nN	0,9870	5,48	1,09	0,9839	6,25	1,21	0,9805	6,80	1,34	0,9851	5,89	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _s , WS, n	0,9867	5,54	1,10	0,9834	6,23	1,23	0,9810	6,74	1,32	0,9849	5,91	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , n, nN	0,9867	5,52	1,10	0,9834	6,23	1,23	0,9821	6,55	1,29	0,9851	5,86	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , WS, nN	0,9866	5,49	1,10	0,9837	6,28	1,22	0,9814	6,66	1,31	0,9850	5,88	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , WS, n	0,9864	5,57	1,11	0,9838	6,23	1,22	0,9815	6,72	1,30	0,9849	5,93	1,17
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , T _s , nN	0,9875	5,38	1,07	0,9843	6,24	1,20	0,9814	6,67	1,31	0,9856	5,80	1,15
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , T _s , n	0,9872	5,46	1,08	0,9846	6,12	1,18	0,9811	6,72	1,32	0,9854	5,84	1,15
5	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , T _s , WS	0,9605	9,20	1,88	0,9528	10,38	2,06	0,9439	11,27	2,25	0,9557	9,84	2,00
5	Rkm, nGun, R _{hum} , T _{min} , WS, n, nN	0,9865	5,55	1,11	0,9829	6,33	1,25	0,9814	6,66	1,31	0,9848	5,92	1,18
5	Rkm, nGun, R _{hum} , T _{min} , T _s , n, nN	0,9871	5,49	1,08	0,9847	6,13	1,19	0,9813	6,77	1,32	0,9854	5,87	1,15
5	Rkm, nGun, R _{hum} , T _{min} , T _s , WS, nN	0,9872	5,47	1,08	0,9842	6,18	1,20	0,9815	6,74	1,31	0,9855	5,86	1,15
5	Rkm, nGun, R _{hum} , T _{min} , T _s , WS, n	0,9872	5,45	1,08	0,9842	6,20	1,20	0,9814	6,70	1,31	0,9854	5,85	1,15
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , n, nN	0,9864	5,55	1,11	0,9843	6,13	1,20	0,9828	6,45	1,26	0,9853	5,84	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , WS, nN	0,9872	5,41	1,08	0,9833	6,21	1,23	0,9818	6,67	1,30	0,9853	5,82	1,16
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , WS, n	0,9871	5,42	1,08	0,9835	6,22	1,22	0,9813	6,70	1,31	0,9852	5,83	1,16
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , nN	0,9881	5,29	1,04	0,9850	6,09	1,17	0,9813	6,83	1,32	0,9860	5,75	1,13
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , n	0,9879	5,34	1,05	0,9851	5,99	1,17	0,9813	6,76	1,32	0,9859	5,75	1,13
5	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , WS	0,9664	8,87	1,74	0,9592	9,75	1,91	0,9507	10,88	2,11	0,9619	9,44	1,85
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , n, nN	0,9869	5,48	1,09	0,9835	6,19	1,23	0,9818	6,54	1,30	0,9852	5,83	1,16
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , WS, nN	0,9864	5,57	1,11	0,9833	6,24	1,23	0,9821	6,57	1,28	0,9849	5,90	1,17
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , WS, n	0,9867	5,54	1,10	0,9831	6,26	1,23	0,9818	6,69	1,29	0,9850	5,91	1,17
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , nN	0,9877	5,35	1,06	0,9847	6,07	1,18	0,9810	6,81	1,33	0,9857	5,78	1,14
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , n	0,9877	5,39	1,06	0,9848	6,03	1,18	0,9808	6,77	1,33	0,9857	5,79	1,14
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , WS	0,9665	8,97	1,74	0,9601	9,86	1,90	0,9493	11,29	2,14	0,9618	9,60	1,85
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , nN	0,9869	5,48	1,09	0,9838	6,14	1,21	0,9817	6,60	1,30	0,9853	5,83	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , n	0,9867	5,52	1,10	0,9841	6,15	1,20	0,9818	6,61	1,29	0,9852	5,86	1,16
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , WS	0,9640	8,95	1,80	0,9557	9,97	1,99	0,9507	10,68	2,11	0,9597	9,50	1,91
5	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s	0,9686	8,42	1,68	0,9634	9,22	1,82	0,9534	10,51	2,05	0,9645	8,99	1,79
6	Rkm, nGun, T _{avg} , T _{max} , T _s , WS, n, nN	0,9865	5,56	1,11	0,9843	6,19	1,20	0,9813	6,75	1,31	0,9850	5,92	1,17
6	Rkm, nGun, T _{min} , T _{max} , T _s , WS, n, nN	0,9872	5,52	1,08	0,9842	6,19	1,20	0,9822	6,71	1,29	0,9855	5,89	1,15
6	Rkm, nGun, T _{min} , T _{avg} , T _s , WS, n, nN	0,9872	5,47	1,08	0,9842	6,14	1,20	0,9821	6,63	1,29	0,9855	5,83	1,15
6	Rkm, nGun, T _{min} , T _{avg} , T _{max} , WS, n, nN	0,9863	5,54	1,12	0,9843	6,13	1,20	0,9831	6,45	1,25	0,9852	5,84	1,16
6	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , n, nN	0,9875	5,42	1,07	0,9849	5,97	1,18	0,9826	6,55	1,27	0,9859	5,75	1,13
6	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , WS, nN	0,9875	5,39	1,07	0,9841	6,18	1,20	0,9816	6,82	1,31	0,9856	5,83	1,15

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
6	Rkm, nGun, T_{min} , T_{avg} , T_{max} , T_s , WS, n	0,9875	5,44	1,07	0,9843	6,04	1,19	0,9820	6,71	1,30	0,9857	5,81	1,14
6	Rkm, nGun, R_{hum} , T_{max} , T_s , WS, n, nN	0,9872	5,48	1,08	0,9837	6,25	1,22	0,9807	6,79	1,33	0,9852	5,89	1,16
6	Rkm, nGun, R_{hum} , T_{avg} , T_s , WS, n, nN	0,9867	5,54	1,10	0,9842	6,17	1,20	0,9812	6,66	1,32	0,9851	5,88	1,17
6	Rkm, nGun, R_{hum} , T_{avg} , T_{max} , WS, n, nN	0,9865	5,56	1,11	0,9838	6,12	1,22	0,9816	6,64	1,30	0,9850	5,88	1,17
6	Rkm, nGun, R_{hum} , T_{avg} , T_{max} , T_s , n, nN	0,9872	5,46	1,08	0,9843	6,06	1,19	0,9817	6,62	1,30	0,9855	5,81	1,15
6	Rkm, nGun, R_{hum} , T_{avg} , T_{max} , T_s , WS, nN	0,9879	5,31	1,05	0,9838	6,22	1,22	0,9806	6,87	1,34	0,9856	5,80	1,15
6	Rkm, nGun, R_{hum} , T_{avg} , T_{max} , T_s , WS, n	0,9876	5,34	1,07	0,9841	6,19	1,20	0,9805	6,86	1,34	0,9854	5,81	1,15
6	Rkm, nGun, R_{hum} , T_{min} , T_s , WS, n, nN	0,9873	5,46	1,08	0,9842	6,08	1,19	0,9815	6,74	1,30	0,9855	5,84	1,15
6	Rkm, nGun, R_{hum} , T_{min} , T_{max} , WS, n, nN	0,9867	5,48	1,10	0,9838	6,25	1,21	0,9822	6,56	1,28	0,9852	5,85	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
6	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , n, nN	0,9878	5,36	1,05	0,9848	6,03	1,18	0,9816	6,70	1,31	0,9859	5,76	1,13
6	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , WS, nN	0,9879	5,34	1,05	0,9846	6,10	1,19	0,9814	6,77	1,31	0,9859	5,77	1,14
6	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , WS, n	0,9879	5,34	1,05	0,9845	6,04	1,19	0,9812	6,77	1,32	0,9858	5,76	1,14
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , WS, n, nN	0,9867	5,49	1,10	0,9834	6,28	1,23	0,9822	6,56	1,28	0,9852	5,86	1,16
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , n, nN	0,9877	5,39	1,06	0,9844	6,05	1,19	0,9814	6,70	1,31	0,9857	5,78	1,14
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , WS, nN	0,9876	5,37	1,06	0,9843	6,06	1,19	0,9811	6,77	1,32	0,9856	5,78	1,15
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , WS, n	0,9875	5,39	1,07	0,9843	6,12	1,20	0,9810	6,83	1,33	0,9856	5,82	1,15
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , n, nN	0,9870	5,44	1,09	0,9837	6,21	1,22	0,9818	6,62	1,29	0,9853	5,83	1,16
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , WS, nN	0,9869	5,50	1,09	0,9834	6,29	1,23	0,9819	6,65	1,29	0,9852	5,88	1,16

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , WS, n	0,9871	5,44	1,08	0,9832	6,26	1,24	0,9815	6,70	1,30	0,9852	5,85	1,16
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , nN	0,9883	5,24	1,03	0,9844	6,18	1,19	0,9809	6,78	1,33	0,9860	5,73	1,13
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , n	0,9884	5,20	1,03	0,9847	6,07	1,18	0,9806	6,94	1,35	0,9861	5,72	1,13
6	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS	0,9688	8,40	1,68	0,9618	9,40	1,85	0,9525	10,59	2,07	0,9642	9,03	1,80
7	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, n	0,9879	5,32	1,05	0,9840	6,11	1,20	0,9806	6,92	1,34	0,9856	5,79	1,14
7	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, nN	0,9884	5,19	1,03	0,9845	6,10	1,19	0,9807	6,88	1,34	0,9861	5,71	1,13
7	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , n, nN	0,9881	5,28	1,04	0,9846	6,08	1,19	0,9815	6,74	1,31	0,9860	5,72	1,13
7	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , WS, n, nN	0,9868	5,50	1,10	0,9839	6,11	1,21	0,9822	6,54	1,28	0,9853	5,82	1,16
7	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _s , WS, n, nN	0,9875	5,41	1,07	0,9845	6,08	1,19	0,9815	6,68	1,31	0,9857	5,79	1,14

Çizelge Ek C.1. (devam ediyor).

Komb.	Girdiler	Eğitim			Doğrulama			Test			Tümü		
		R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE	R	MAPE	RMSE
7	Rkm, nGun, R _{hum} , T _{min} , T _{max} , T _s , WS, n, nN	0,9877	5,35	1,06	0,9846	6,08	1,18	0,9820	6,63	1,29	0,9859	5,75	1,13
7	Rkm, nGun, R _{hum} , T _{avg} , T _{max} , T _s , WS, n, nN	0,9872	5,43	1,08	0,9846	6,11	1,19	0,9812	6,68	1,31	0,9855	5,81	1,15
7	Rkm, nGun, T _{min} , T _{avg} , T _{max} , T _s , WS, n, nN	0,9874	5,43	1,07	0,9847	6,01	1,18	0,9821	6,64	1,29	0,9858	5,78	1,14
8	Rkm, nGun, R _{hum} , T _{min} , T _{avg} , T _{max} , T _s , WS, n, nN	0,9877	5,35	1,06	0,9844	6,13	1,19	0,9817	6,75	1,30	0,9858	5,78	1,14

ÖZGEÇMİŞ

Yusuf KURTGÖZ, 1977 yılında Adana’da doğdu, ilk ve orta eğitimini aynı şehirde tamamladı. 1995 yılında Akçadağ Anadolu Öğretmen Lisesinden mezun oldu. 1995-1999 yılları arasında Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Endüstri Mühendisliği Bölümü’nde lisans eğitimi tamamladı. 2002 yılında Zonguldak Karaelmas Üniversitesi Karabük Meslek Yüksekokulunda öğretim görevlisi olarak çalışmaya başladı. 2003-2006 yılları arasında ZKÜ Fen Bilimleri Enstitüsü Makine Eğitimi Anabilim Dalı’nda yüksek lisans eğitimi bitirdi. 2013 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı’nda doktora eğitimine başladı. Halen, Karabük Üniversitesi TOBB Teknik Bilimler Meslek Yüksekokulunda öğretim görevlisi olarak çalışmaya devam etmektedir.

ADRES BİLGİLERİ

Adres : Karabük Üniversitesi
TOBB Teknik Bilimler Meslek Yüksekokulu
Demir Çelik Kampüsü
78050 KARABÜK
Tel : (370) 418 72 02
E-posta : ykurtgoz@karabuk.edu.tr