

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ



**YAPAY SİNİR AĞLARI İLE RÜZGAR VE GÜNEŞ ENERJİSİ
POTANSİYELİNİN MODELLENMESİ VE DALGACIK DÖNÜŞÜMÜ İLE
ANALİZİ**

YÜKSEK LİSANS TEZİ

Durhan GABRALI

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

TEMMUZ 2019

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ



**YAPAY SINIR AĞLARI İLE RÜZGAR VE GÜNEŞ ENERJİSİ
POTANSİYELİNİN MODELLENMESİ VE DALGACIK DÖNÜŞÜMÜ İLE
ANALİZİ**

YÜKSEK LİSANS TEZİ

**Durhan GABRALI
(Y1613.010012)**

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Zafer ASLAN

TEMMUZ 2019



T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ

Yüksek Lisans Tez Onay Belgesi

Enstitümüz Bilgisayar Mühendisliği Ana Bilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı **Y1613.010012** numaralı öğrencisi **Durhan GABRALI**'nin "YAPAY SİNİR AĞLARI İLE RÜZGAR VE GÜNEŞ ENERJİSİ POTANSİYELİNİN MODELLENMESİ VE DALGACIK DÖNÜŞÜMÜ İLE ANALİZİ" adlı tez çalışması Enstitümüz Yönetim Kurulunun 12.06.2019 tarih ve 2019/12 sayılı kararıyla oluşturulan jüri tarafından **başarılı** şekilde Tezli Yüksek Lisans tezi olarak **kabul** edilmiştir.

Öğretim Üyesi Adı Soyadı

İmzası

Tez Savunma Tarihi : 31/07/2019

1) **Tez Danışmanı:** Prof. Dr. Zafer ASLAN

2) **Jüri Üyesi :** Prof. Dr. Ali GÜNEŞ

3) **Jüri Üyesi :** Doç. Dr. Metin ZONTUL

(Handwritten signatures of Prof. Dr. Zafer ASLAN, Prof. Dr. Ali GÜNEŞ, and Doç. Dr. Metin ZONTUL)

Not: Öğrencinin Tez savunmasında **Başarılı** olması halinde bu form **imzalanacaktır**. Aksi halde geçersizdir.

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Rüzgâr ve Güneş Enerji Potansiyelinin YSA ve Dalgacık Dönüşümü ile Analizi: İstanbul Uygulaması” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (31/07/2019)

Durhan GABRALI

ÖNSÖZ

Son yıllarda enerji üretiminde yenilenebilir enerji kaynaklarının payı önemli ölçüde artış göstermektedir. Rüzgar ve güneş enerjisi en önemli yenilenebilir enerji kaynaklarındandır. Ancak rüzgar şiddeti ve güneş ışınımının değişkenliği ve kontrol edilememesi, bu enerjilerin kullanımında güvenilirlik açısından sorunlara yol açmaktadır. Bu nedenle belirli bir bölge için rüzgar ve güneş enerji potansiyeli ile bunlara etki eden faktörlerin önceden belirlenmesi çok önemlidir. Bu çalışmada Marmara Bölgesi, İstanbul İlinde yer alan Büyükçekmece İlçesinde geçmiş meteorolojik veriler kullanılarak rüzgar ve güneş enerji potansiyeline etki eden faktörler incelenmiştir ve rüzgar şiddeti ile güneş radyasyonunun kısa süreli tahmini için modelleme çalışması yapılmıştır.

Tez konusunun belirlenmesinde, çalışmada kullanılacak verilerin sağlanmasında ve baştan sona kadar büyük bir sabırla bana gösterdikleri ilgi, destek ve yardımlarından dolayı saygıdeğer Hocam ve tez danışmanım olan Prof. Dr. Zafer ASLAN'a teşekkür ederim. Sayın Hocamın bilgi, tecrübe ve yönlendirmeleri çalışmanın yürütülmesinde son derece faydalı olmuştur. Bu zorlu çalışma döneminde uygun çalışma ortamını sağlayan ve bana destek olan değerli aileme de teşekkürlerimi sunarım.

Temmuz 2019

Durhan GABRALI

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR LİSTESİ.....	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
SEMBOL LİSTESİ.....	xix
ÖZET	xxi
ABSTRACT.....	xxiii
1. GİRİŞ.....	1
1.1 Tezin Amacı.....	3
1.2 Tezin Kapsam ve İçeriği	4
1.3 Literatür Özeti.....	5
2. MATERYAL VE YÖNTEM.....	17
2.1 Çalışma Bölgesi ve Veriler	17
2.2 Verilere Uygulanan Önışlemler	18
2.3 Çoklu Lineer Regresyon	19
2.4 Dalgacık (Wavelet) Dönüşümü	20
2.4.1 Sürekli dalgacık dönüşümü	22
2.4.2 Ayrık dalgacık dönüşümü.....	24
2.5 Yapay Sinir Ağları	26
2.5.1 Yapay sinir ağlarının yapısı	26
2.6 Dalgacık YSA (D-YSA) Modeli	31
2.7 Model Performanslarının Değerlendirilmesinde Kullanılan Yöntemler	32
3. ANALİZ VE UYGULAMA.....	35
3.1 İstatiksel Analiz ve Modelleme	35
3.1.1 Mevsimlere göre istatistiksel analiz	36
3.1.2 Çoklu lineer regresyon ile tahmin modelleme.....	43
3.2 Dalgacık Analizi	48
3.2.1 Mart Ayı dalgacık analizi	49
3.2.1.1 Mart Ayı ayrık dalgacık analizi	49
3.2.1.2 Mart Ayı sürekli dalgacık analizi	50
3.2.2 Haziran ayı dalgacık analizi	52
3.2.2.1 Haziran ayı ayrık dalgacık analizi	52
3.2.2.2 Haziran ayı sürekli dalgacık analizi	53
3.2.3 Eylül ayı dalgacık analizi	54
3.2.3.1 Eylül ayı ayrık dalgacık analizi	54
3.2.3.2 Eylül ayı sürekli dalgacık analizi	56
3.2.4 Aralık ayı dalgacık analizi	57
3.2.4.1 Aralık ayı ayrık dalgacık analizi.....	57
3.2.4.2 Aralık ayı sürekli dalgacık analizi	59
3.3 YSA ile Tahmin Modelleme.....	60

3.3.1 Kurulan YSA modellerinin mimarisi.....	60
3.3.2 YSA modellerini uygulama	62
3.3.2.1 Rüzgar şiddeti YSA ile tahmin modelleme	62
3.3.2.2 Güneş radyasyonu YSA ile tahmin modelleme.....	65
3.4 Dalgacık YSA İle Tahmin Modelleme	68
3.4.1 Rüzgar şiddeti D-YSA ile tahmin modelleme	69
3.4.2 Güneş radyasyonu D-YSA ile tahmin modelleme.....	73
4. BULGULAR VE ÖNERİLER	79
4.1 İstatistiksel Analiz Sonuçları	79
4.2 ÇLR Modelleme Sonuçları	80
4.3 YSA Modelleme Sonuçları.....	81
4.4 D-YSA Modelleme Sonuçları.....	81
4.5 Genel Sonuç ve Öneriler	81
KAYNAKLAR	85
EKLER.....	91
ÖZGEÇMİŞ.....	113

KISALTMALAR LİSTESİ

ADD	: Ayrık Dalgacık Dönüşümü
ANFIZ	: Adaptive Neuro-Fuzzy Inference System (Uyarlamalı Ağ Bulanık Çıkarım Sistemi)
ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
AR	: Auto Regressive (Oto Regresif)
ARIMA	: Auto Regressive Integrated Moving Average (Oto Regresif Hareketli Ortalamalar)
BPNN	: Back Propagation Neural Networks (Geri Yayılımlı Sinir Ağları)
DHR	: Dinamik Harmonik Regresyon
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
D-YSA	: Dalgacık - Yapay Sinir Ağı
CFA	: Chaotic Firefly Algorithm (Kaotik Ateşböceği Algoritması)
ÇLR	: Çoklu Lineer Regresyon
CS	: Cuckoo Search (Cuckoo Arama Optimizasyon Algoritması)
CWT	: Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
GA	: Genetik Algoritma
GEP	: Genetik Ekspresyon Programlama
GEPA	: Güneş Enerjisi Potansiyeli Atlası
KF	: Kalman Filtreleme
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MATLAB	: Matrix Laboratory (Matris Laboratuvarı)
MABE	: Mean Absolute Bias Error (Ortalama Mutlak Sapma Hatası)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Hata Yüzdesi)
MLP	: Multilayer Perceptron (Çok Katmanlı Perceptron)
MLR	: Multiple Lineer Regression (Çoklu Lineer Regresyon)
MGM	: Meteoroloji Genel Müdürlüğü
MS	: Microsoft
NAR	: Nonlinear Autoregressive (Doğrusal Olmayan Oto Regresif)
NWP	: Numerical Weather Prediction (Sayısal Hava Tahmini)
UV	: Ultraviyole
REPA	: Türkiye Rüzgar Enerjisi Potansiyel Atlası
RF	: Random Forest (Rastgele Orman)
RMSE	: Root Mean Square Error (Kök Ortalama Kare Hatası)
nRMSE	: Normalized Root Mean Square Error (Normalize Kök Ortalama Kare Hatası)
rRMSE	: Relative Root Mean Square Error (Göreceli Kök Ortalama Kare Hatası)
SDD	: Sürekli Dalgacık Dönüşümü

SPSS	: Statistical Package for the Social Sciences (Sosyal Bilimler İçin İstatistik Programı)
SSE	: Squared Sum of Errors (Tahmin Hata Karelerinin Toplamı)
SVM	: Support Vector Machine (Destek Vektör Makinası)
TARBİL	: Tarım Bilgi Sistemi
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
YSA	: Yapay Sinir Ağları
YEGM	: Yenilenebilir Enerji Genel Müdürlüğü
WD	: Wavelet Decomposition (Dalgacık Ayrıştırması)
WNN	: Wavelet Neural Network (Dalgacık Sinir Ağı)
WOASAR	: Whale Optimization Algorithm with Simulated Annealing and Roulette wheel selection (Benzetilmiş Tavlama ile Balina Optimizasyonu Algoritması ve Rulet tekerleği seçimi)
WT	: Wavelet Transform (Dalgacık Dönüşümü)

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: İnceleme Bölgesi ve Kullanılan Veriler	17
Çizelge 2.2 : Etkinlik Fonksiyonları ve Açıklamaları	29
Çizelge 3.1 : 2016 Yılı, Eskice Mevki Kayıp Veri Analizi	35
Çizelge 3.2 : Aylar Bazında Kayıp Veri Analizi	37
Çizelge 3.3 : Rüzgar Şiddeti (m/s) Verileri İçin Tanımlayıcı İstatistik.....	37
Çizelge 3.4 : Güneş Radyasyonu (W/m^2) Verileri İçin Tanımlayıcı İstatistik	38
Çizelge 3.5 : Rüzgar Şiddeti (m/s), Çoklu Lineer Regresyon Modellerinin (ÇLR _{RS}) Performansları	45
Çizelge 3.6 : Güneş Radyasyonu (W/m^2), Çoklu Lineer Regresyon Modellerinin (ÇLR _{GR}) Performansları	46
Çizelge 3.7 : Rüzgar Şiddeti (m/s), YSA(6,3,1) _{RS} Modellerinin Performansı	63
Çizelge 3.8 : Güneş Radyasyonu (W/m^2), YSA(6,3,1) _{GR} Modellerinin Performansı	66
Çizelge 3.9 : Haziran Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	70
Çizelge 3.10 : Rüzgar Şiddeti D-YSA Modellerinde Giriş İçin Seçilen Alt Zaman Bileşenleri.....	71
Çizelge 3.11 : Rüzgar Şiddeti (m/s), D-YSA Modellerinin Performansı	72
Çizelge 3.12 : Haziran Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	74
Çizelge 3.13 : Güneş Radyasyonu D-YSA Modellerinde Giriş İçin Seçilen Alt Zaman Bileşenleri.....	74
Çizelge 3.14 : Güneş Radyasyonu (W/m^2), D-YSA Modellerinin Performansı	76
Çizelge 4.1 : Rüzgar Şiddeti (m/s), Model Performanslarının Karşılaştırılması.....	82
Çizelge 4.2 : Güneş Radyasyonu (W/m^2), Model Performanslarının Karşılaştırılması	83
Çizelge A.1 : Mart Ayı Pearson Korelasyon Katsayıları.....	93
Çizelge A.2 : Haziran Ayı Pearson Korelasyon Katsayıları	93
Çizelge A.3 : Eylül Ayı Pearson Korelasyon Katsayıları.....	93
Çizelge A.4 : Aralık Ayı Pearson Korelasyon Katsayıları	94
Çizelge A.5 : Mart Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	94
Çizelge A.6 : Eylül Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	95
Çizelge A.7 : Aralık Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	95

Çizelge A.8 : Mart Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	96
Çizelge A.9 : Eylül Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	96
Çizelge A.10 : Aralık Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri	97

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Türkiye Rüzgar Enerjisi Potansiyel Atlası (REPA), Rüzgar Hızı Haritası, 50m Yükseklik (Url-1).....	2
Şekil 1.2 : Türkiye Güneş Enerjisi Potansiyel Atlası (GEPA) (Url-2).....	2
Şekil 2.1 : Eskice Mevki İstasyonu (41.0722 ° N, 28.5782 ° E , Rakım : 50m) (Url-3)	18
Şekil 2.2 : Dalgacık Dönüşümü (Wavelet Transform)	21
Şekil 2.3 : Örnek Dalgacıklar (Fugal, 2009)	22
Şekil 2.4 : Sürekli Dalgacık Dönüşümü Renk Spektogramı (Peleg, 2000).....	23
Şekil 2.5 : (a) Dalgacık Ayırıştırma (b) Dalgacık Yeniden Yapılandırma (Aghajani, Kazemzadeh, & Ebrahimi, 2016).....	25
Şekil 2.6 : Yapay Sinir Ağı Örneği.....	27
Şekil 2.7 : Bir Yapay Sinir Hücresinin Yapısı (Elmas, 2016).....	28
Şekil 2.8 : Değişik Etkinlik İşlevleri (Nabiyeve, 2016)	28
Şekil 2.9 : (a) Danışmanlı Öğrenme (b) Danışmansız Öğrenme (Elmas, 2016)	30
Şekil 2.10 : Dalgacık YSA Modelinin Blok Şeması (Partal, 2007)	32
Şekil 3.1 : 2016 Yılı, Eskice Mevki, Aylık Ortalama Rüzgar Şiddeti (m/s) Grafiği	36
Şekil 3.2 : 2016 Yılı, Eskice Mevki, Aylık Ortalama Güneş Radyasyonu (W/m ²) Grafiği	36
Şekil 3.3 : Rüzgar Şiddeti (a) Mart Ayı (b) Haziran Ayı (c) Eylül Ayı (d) Aralık Ayı, Zamansal Değişim Grafikleri	39
Şekil 3.4 : Güneş Radyasyonu (a) Mart Ayı (b) Haziran Ayı (c) Eylül Ayı (d) Aralık Ayı, Zamansal Değişim Grafikleri	41
Şekil 3.5 : Haziran Ayı, Rüzgar Şiddeti, ÇLR Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri	46
Şekil 3.6 : Haziran Ayı, Güneş Radyasyonu, ÇLR Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri	47
Şekil 3.7 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Mart Ayı)	49
Şekil 3.8 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Mart Ayı)	50
Şekil 3.9 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Mart Ayı).....	51
Şekil 3.10 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Mart Ayı).....	51
Şekil 3.11 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Haziran Ayı).....	52
Şekil 3.12 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Haziran Ayı)	53

Şekil 3.13 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Haziran Ayı).....	53
Şekil 3.14 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Haziran Ayı).....	54
Şekil 3.15 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Eylül Ayı).....	55
Şekil 3.16 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Eylül Ayı)	55
Şekil 3.17 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Eylül Ayı).....	56
Şekil 3.18 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Eylül Ayı).....	57
Şekil 3.19 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Aralık Ayı)	58
Şekil 3.20 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Aralık Ayı).....	58
Şekil 3.21 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Aralık Ayı)	59
Şekil 3.22 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m ²), Eskice Mevki (2016 Yılı Aralık Ayı)	60
Şekil 3.23 : MATLAB YSA Model Şeması (MATLAB 2016, nntraintool)	61
Şekil 3.24 : YSA(6,3,1) _{RS} Modelinin Şematik Gösterimi	62
Şekil 3.25 : Haziran 2016, Rüzgar Şiddeti YSA Modeli Eğitim Aşaması (MATLAB 2016, nntraintool)	63
Şekil 3.26 : Haziran Ayı, Rüzgar Şiddeti, YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin zaman Grafiği, Test verileri	64
Şekil 3.27 : YSA(6,3,1) _{GR} Modelinin Şematik Gösterimi	65
Şekil 3.28 : Haziran 2016, Güneş Radyasyonu YSA Modeli Eğitim Aşaması (MATLAB 2016, nntraintool).....	66
Şekil 3.29 : Haziran Ayı, Güneş Radyasyonu, YSA(6,3,1) Modeli İçin (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri	67
Şekil 3.30 : Wavelet 1D, Db3, 11.Seviye, Rüzgar Şiddeti, Eskice Mevki, Haziran Ayı.....	69
Şekil 3.31 : Haziran Ayı D-YSA(6,3,1) _{RS} Modelinin Şematik Gösterimi	71
Şekil 3.32 : Haziran Ayı, Rüzgar Şiddeti, D-YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri.....	73
Şekil 3.33 : Haziran Ayı D-YSA(6,3,1) _{GR} Modelinin Şematik Gösterimi	75
Şekil 3.34 : Haziran Ayı, Güneş Radyasyonu, D-YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri	77
Şekil B.1 : 2016 Yılı Mart Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri	99
Şekil B.2 : 2016 Yılı Haziran Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri	99
Şekil B.3 : 2016 Yılı Eylül Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri	99
Şekil B.4 : 2016 Yılı Aralık Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri	100

Şekil B.5 : 2016 Yılı Mart Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları	100
Şekil B.6 : 2016 Yılı Haziran Ayı (a) Rüzgar Şiddeti (b) Güneş Radyasyonu Boxplot Diyagramları.....	100
Şekil B.7 : 2016 Yılı Eylül Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları	101
Şekil B.8 : 2016 Yılı Aralık Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları	101
Şekil B.9 : Rüzgar Şiddeti (m/s), Mart Ayı Test Verileri (a) ÇLR (b) YSA (c) D- YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	102
Şekil B.10 : Rüzgar Şiddeti (m/s), Haziran Ayı Test verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	103
Şekil B.11 : Rüzgar Şiddeti (m/s), Eylül Ayı Test Verileri (a) ÇLR (b) YSA (c) D- YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	104
Şekil B.12 : Rüzgar Şiddeti (m/s), Aralık Ayı Test Verileri (a) ÇLR (b) YSA (c) D- YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	105
Şekil B.13 : Güneş Radyasyonu (W/m^2), Mart Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	106
Şekil B.14 : Güneş Radyasyonu (W/m^2), Haziran Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	107
Şekil B.15 : Güneş Radyasyonu (W/m^2), Eylül Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	108
Şekil B.16 : Güneş Radyasyonu (W/m^2), Aralık Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri	109
Şekil B.17 : Tez Çalışması Akış Diyagramı	110

SEMBOL LİSTESİ

R	: Korelasyon katsayısı
R²	: Determinasyon katsayısı
Y	: Bağımlı değişken
X	: Bağımsız değişken
Ψ	: Ana dalgacık
s	: Ölçekleme parametresi
τ	: Konum (kaydırma) parametresi
A	: Yaklaşım Bileşeni
D	: Detay bileşeni
w	: Ağırlık
θ	: Eşik değeri
α	: Anlamlılık seviyesi
n	: Veri adedi
y_i	: Gözlemlenmiş değer
\bar{y}_i	: Gözlemlenmiş değerlerin ortalaması
\hat{y}_i	: Tahmin edilen değer
$\bar{\hat{y}}_i$: Tahmin edilen değerlerin ortalaması
f	: Fonksiyon
rs	: Rüzgar şiddeti
gr	: Güneş radyasyonu
uv	: UV radyasyon indis
s5cm	: Toprak üstü 5cm sıcaklık
s2m	: Sıcaklık 2m
ry	: Rüzgar yönü
t	: Zaman
e	: Hata terimi
a, b, c	: Katsayılar
k	: Zaman kaydırması

YAPAY SINIR AĞLARI İLE RÜZGAR VE GÜNEŞ ENERJİSİ POTANSİYELİNİN MODELLENMESİ VE DALGACIK DÖNÜŞÜMÜ İLE ANALİZİ

ÖZET

Son yıllarda fosil yakıt kaynaklarının tükenmesi ve çevresel kaygılar nedeniyle yenilenebilir enerji kaynaklarının mevcut enerji üretiminde kullanım payı giderek artmaktadır. Yenilenebilir enerji kaynaklarından olan rüzgar ve güneş enerjileri temiz, sürdürülebilir ve çevre dostu enerji kaynağı olmaları nedeniyle öne çıkmaktadır. Rüzgar ve güneş enerji potansiyeli, meteorolojik koşullara göre önemli ölçüde değişim gösterir. Rüzgar şiddeti ve güneş radyasyonunun değişken ve kontrolünün güç oluşu, güneş ve rüzgar enerjisi sistemlerinde güç kalitesi, üretim tüketim dengesi ve güvenilirlik açısından bazı sorunlara neden olmaktadır. Bu nedenle, rüzgar ve güneş enerjisi sistemlerinin montajı ve işletimi sırasında, sistemlerin kurulduğu bölgelerin rüzgar şiddeti ve güneş radyasyonu özelliklerinin bilinmesi ve tahmin edilmesi çok önemlidir.

Bu çalışmada, İstanbul Büyükçekmece İlçesi Eskice Bölgesine ait 2016 yılı meteorolojik verileri (rüzgar şiddeti ve güneş radyasyonu), istatistiksel yöntemler ve dalgacık dönüşümü yardımıyla mevsimsel olarak incelenmiştir. Böylece çalışma alanındaki rüzgar ve güneş enerjisi potansiyelleri ve bu potansiyelleri etkileyen küçük, orta ve büyük ölçekli olayların rolleri belirlenmiştir. Ek olarak değişik meteorolojik veriler (rüzgar şiddeti, güneş radyasyonu, UV radyasyon indis, toprak üstü 5cm sıcaklık, sıcaklık 2m, rüzgar yönü) kullanılarak rüzgar şiddeti ve güneş radyasyonu için ileriye yönelik kısa ve orta vadeli bir tahmin çalışması yapılmıştır. Modelleme için geleneksel istatistiksel yöntemlerden biri olan Çoklu Lineer Regresyon (ÇLR) ve esnek hesaplama yöntemlerinden biri olan Yapay Sinir Ağları (YSA) kullanılmıştır. YSA modellerinin performansını arttırmak için verilere dalgacık dönüşümü ön işlemi uygulanarak Dalgacık Yapay Sinir Ağı (D-YSA) hibrit modelleri geliştirilmiştir.

Geliştirilen tüm modeller istatistiksel olarak karşılaştırılmıştır. Mevsimsel olarak, rüzgar şiddeti için en başarılı modelin yaz mevsimini temsilen seçilen Haziran ayında ve R^2 , nRMSE ve MAPE(%) için sırasıyla 0.634, 0.327, 26.07 değerlerine sahip D-YSA modelinin olduğu saptanmıştır. Güneş radyasyonu analizlerine dayalı olarak en başarılı tahminin yine Haziran ayında elde edildiği saptanmıştır. Bu aşamada kullanılan D-YSA modeli ile güneş radyasyonu için R^2 , nRMSE ve MAPE(%) değerleri sırasıyla 0.842, 0.471, 27.84 olarak hesaplanmıştır. Sonuç olarak, YSA kullanarak rüzgar şiddeti ve güneş radyasyonu tahmininde, dalgacık dönüşümü ile ön işlem yapmanın başarıyı arttırdığı gözlenmiştir. Bu verilere dayalı olarak seçilen inceleme bölgesinde ve Haziran ayında rüzgar ve güneş enerji potansiyelinin yeter güvenilirlik ile tahmin edilebileceği vurgulanabilir.

Anahtar Kelimeler : *Rüzgar ve Güneş Enerjisi, Çoklu Lineer Regresyon, Dalgacık Dönüşümü, Yapay Sinir Ağları , Dalgacık - YSA*

MODELING OF WIND AND SOLAR ENERGY POTENTIAL WITH ARTIFICIAL NEURAL NETWORK AND ANALYSIS WITH WAVELET TRANSFORMATION

ABSTRACT

In recent years, due to the depletion of fossil fuel resources and environmental concerns, the share of renewable energy resources in the current energy production show an increasing trend. Wind and solar energy as renewable energy sources are sustainable, clean and environmental friendly energy sources. The wind and solar energy potential show significant variations along with the meteorological conditions. Controlling mechanisms of wind and solar energy potential are not easy. These mechanisms cause some problems in terms of power quality, production consumption balance and reliability in solar and wind energy systems. For this reason, it is very important to know and estimate the wind speed and solar radiation characteristics during the installation and operation of wind and solar systems.

In this study, meteorological data (wind speed, solar radiation) at the Eskişehir Region (Büyükdere District, Istanbul) in 2016 was analysed by using statistical methods and wavelet transforms. The roles of small, medium and large-scale factors on wind and solar energy potential variation were seasonally evaluated in the study area. In the second part of the thesis is related with a short and medium term modelling of energy potential based on different meteorological data (wind speed, solar radiation, UV radiation index, above ground 5cm temperature, temperature 2m, wind direction). Multiple Linear Regression (MLR), one of the traditional statistical methods for modeling, and Artificial Neural Networks (ANN), which is one of the soft computing methods, were considered in this part of the thesis. In order to improve the performance of ANN models, Wavelet Artificial Neural Network (W-ANN) hybrid models have been developed by applying wavelet transform.


Observations and model outputs were compared by error analyses. Success ratio and reliability of models for wind speed (and wind energy potential) estimations are higher in summer (June) than other seasons. Based on seasonal success ratio of D-ANN for wind speed model, R^2 , nRMSE and MAPE(%) are 0.634, 0.327, 26.07 respectively in June. Based on solar radiation analysis, the most reliable estimation for solar energy potential was also obtained in June. Based on W-ANN model, R^2 , nRMSE and MAPE(%) values were calculated as 0.842, 0.471, 27.84 respectively in June. As a conclusion, it has been observed that pre-process with a wavelet transformation with ANN increases the success ratio in estimation of wind speed and solar radiation. Based on these results, it can be underlined that the wind and solar energy potential can be estimated with sufficient reliability in the study area in June.

Keywords: *Wind Energy, Solar Energy, Multiple Linear Regression, Wavelet Transform, Artificial Neural Networks, Wavelet – ANN*

1. GİRİŞ


Günümüzde global enerji ihtiyacının büyük bölümü fosil yakıt kaynaklarından karşılanmaktadır. Birincil enerji tüketimi %80 civarında fosil yakıt kaynaklarından sağlanırken geri kalanı yenilenebilir enerji kaynaklarından elde edilmektedir (Yılmaz & Öziç, 2018). Buna göre günümüzde mevcut enerji tüketiminin sadece beşte biri temiz ve çevre dostu olan yenilenebilir enerji kaynaklarından karşılanabildiği söylenebilir. Fosil kaynaklı yakıt rezervleri ise kullanıma bağlı olarak her gün azalmakta ve sınırlı rezervler yüzünden gelecekte yakın bir zamanda biteceği öngörülmektedir. Kanıtlanmış fosil yakıt rezervlerinin mevcut tüketim oranları ile 70 yıl sonra tamamen tükeneceğini ve büyük olasılıkla artan talep eğilimleri dikkate alındığında daha önce de tükenebileceği öngörülmektedir. (Rahman, B. Mostafiz, Paatero, & Lahdelma, 2014). Fosil kaynaklı yakıtlar çevreye de zarar vermektedir. Sınırlı sayıda rezerve sahip olmaları ve çevreye verdikleri zararlı etkilerden dolayı fosil enerji kaynaklarına alternatif olarak yenilenebilir enerji kaynakları önem kazanmaktadır. Gelecek yıllarda yenilenebilir enerji kaynaklarının toplam enerji üretimindeki payının artacağı öngörülmektedir. Yenilenebilir enerji kaynakları içerisinde rüzgar ve güneş enerjisi en önemli kaynaklar olarak gösterilebilir. Rüzgâr enerjisi için rüzgâr şiddeti, güneş enerjisi için de güneş radyasyonu önemli parametrelerdir.

Yenilenebilir Enerji Genel Müdürlüğü (YEGM)'den alınan Türkiye Rüzgar Enerjisi Potansiyel Atlası (REPA) Şekil 1.1'de görülmektedir. Yıllık, mevsimlik ve aylar bazında Türkiye'deki rüzgar şiddeti ortalamaları verilmiştir. Haritaya göre Marmara denizi çevresinde, Ege Bölgesinin batı kıyıları boyunca ve Hatay İlindeki küçük bir bölgede en yüksek yıllık rüzgar şiddeti ortalamaları görülmektedir. Meteoroloji Genel Müdürlüğü (MGM) tarafından yapılan ölçümlere göre Türkiye'nin yıllık ortalama rüzgar şiddeti 2.54 m/s, rüzgar gücü yoğunluğu ise 24 W/m²'dir. Rüzgar enerji potansiyeli en yüksek olan bölge yıllık ortalama 3.3 m/s rüzgar şiddeti ve 51.91 W/m² rüzgar güç yoğunluğu ile Marmara Bölgesidir (Şenel & Koç, 2015).



Şekil 1.1 : Türkiye Rüzgar Enerjisi Potansiyel Atlası (REPA), Rüzgar Hızı Haritası, 50m Yükseklik (Url-1)

Türkiye coğrafi konumu nedeniyle güneş enerji potansiyeli yüksek olan bir ülkedir. Türkiye'deki güneş enerji potansiyeli Şekil 1.2'de Türkiye'nin Güneş Enerjisi Potansiyeli Atlasında (GEPA) görülmektedir. Yıllık ortalama toplam güneş ışınımının en yüksek olduğu bölgeler Güneydoğu Anadolu ve Akdeniz bölgeleri olmakla beraber Türkiye'deki hemen hemen her bölgede güneş enerji sistemleri verimli bir şekilde kullanılabilir. GEPA'ya göre yıllık gelen toplam güneş enerjisi 1527 kWh/m^2 (günlük ortalama 4.2 kWh/m^2), yıllık toplam güneşlenme süresi ise 2737 saat (günlük ortalama 7.5 saattir) olarak belirlenmiştir (Kılıç, 2015).



Şekil 1.2 : Türkiye Güneş Enerjisi Potansiyel Atlası (GEPA) (Url-2)

Bu çalışmanın konusu Marmara Bölgesinde bulunan İstanbul İlindeki belirli bir bölgede rüzgâr ve güneş enerji potansiyelinin ve onlara etki eden olayların incelenmesi, geleneksel istatistiksel yöntemler ve Yapay Sinir Ağları (YSA) kullanarak değişik meteorolojik parametrelere bağlı olarak rüzgâr şiddeti ve güneş radyasyonu için tahmin gerçekleştirilmesidir. Çalışmada İstanbul İli Büyükçekmece İlçesi Eskice Mevkiinde bulunan Tarım ve Orman Bakanlığına bağlı Tarım Bilgi Sistemi (TARBİL) istasyonuna ait 2016 yılında ölçülen ve 10 dakikalık aralıklarla kaydedilen güneş radyasyonu, rüzgâr şiddeti, rüzgar yönü, sıcaklık 2m, ultraviyole radyasyon indis, toprak üstü 5cm sıcaklık verileri kullanılmıştır.

1.1 Tezin Amacı

Yenilenebilir enerji kaynaklarından rüzgâr ve güneş enerji sistemlerinin tasarımında rüzgâr şiddeti ve güneş ışınımı potansiyellerinin belirlenmesi ile bunlara etki eden büyük ve küçük ölçekli olayların ortaya çıkartılması oldukça önemlidir. Bu çalışmanın amacı belirli bir bölgede en önemli yenilenebilir enerji kaynaklarından olan rüzgâr ve güneş enerji potansiyeli karakteristiklerinin incelenmesi ve bunlara etki eden faktörlerin analiz edilmesidir. Çalışmanın bir diğer amacı ise zaman serisi biçimindeki değişik meteorolojik veriler kullanılarak belirli bir bölgede rüzgâr şiddeti ve güneş radyasyonunun tahmin edilmesi için modeller geliştirmek ve kullanılan modellerin başarı açısından karşılaştırılmasıdır.

Çalışma kapsamında İstanbul İli Büyükçekmece İlçesinde bulunan Eskice Mevki bölgesinin rüzgâr ve güneş enerji potansiyeli 2016 yılı verileri kullanılarak mevsimsel bazda incelenmiştir. İnceleme neticesinde bunlara etki eden faktörler ortaya konulmuştur. Geçmişte ölçülmüş değişik meteorolojik veriler kullanılarak rüzgar şiddeti ve güneş radyasyonu için ileriye yönelik 24 saatlik zaman ufkunda 10 dakikalık adımlarla tahmin çalışması yapılmıştır. Tahmin çalışmasında geleneksel istatistiksel yöntemler ile esnek hesaplama yöntemlerinden olan YSA, dalgacık dönüşümü ve YSA'nın birlikte kullanılarak oluşturulan hibrit model D-YSA kullanılmış ve bunların tahmin başarısı karşılaştırılmıştır. Bu bilgiler bölgede kurulacak rüzgâr ve güneş enerji sistemleri veya mevcut kurulu bulunan sistemlerin işletimi için önemli olabilir.

1.2 Tezin Kapsam ve İçeriği

Bu çalışma beş temel aşamadan oluşmaktadır. Bu aşamalar istatistiksel analiz, dalgacık analizi, çoklu lineer regresyon ile tahmin, yapay sinir ağları ile tahmin ve dalgacık yapay sinir ağı ile tahmin çalışması şeklinde ifade edilebilir.

Birinci aşamada verilere istatistiksel analiz uygulanmıştır. Verileri düzenlemek ve istatistiksel analizler uygulamak için MS-Excel ve SPSS programlarından yararlanılmıştır. Değişik istatistiksel analizler yapılmış, sonuçlar tablolar ve grafiklerle ortaya konularak verilerin istatistiksel olarak yorumlanması sağlanmıştır. Çalışmanın ana konusu “rüzgâr ve güneş enerji potansiyeli” olduğundan rüzgâr şiddeti ve güneş radyasyonu verileri incelenmiştir. Mevsimsel etkileri ortaya koymak için her mevsimin ilk ayı seçilerek aylık bazda çalışma gerçekleştirilmiştir. İlkbahar ayını temsilen Mart Ayı, yaz mevsimini temsilen Haziran Ayı, sonbahar mevsimini temsilen Eylül Ayı, kış mevsimini temsilen Aralık Ayı seçilmiştir. Bu ayların her biri için eksik veri analizi, tanımlayıcı istatistik, veriler arasında korelasyon ilişkisi belirleme çalışması yapılmıştır. Frekans dağılımını gösteren histogramlar, çeyrek (*ing. quartile*) dağılımı ve ekstrem değerleri gösteren box-plot grafikleri oluşturulmuştur. Ayrıca seçilen her ay için rüzgâr şiddeti ve güneş radyasyonu zamansal değişim grafikleri oluşturularak bu verilerin zamansal değişimi yorumlanmıştır.

İkinci aşamada dört mevsimi temsil eden Mart, Haziran, Eylül ve Aralık ayları için rüzgâr şiddeti ve güneş radyasyonu verilerine sürekli (*ing. continuous*) ve ayrık (*ing. discrete*) dalgacık analizi uygulanmıştır. Dalgacık analizinin uygulanmasında MATLAB Programının Wavelet Toolbox aracı kullanılmıştır. Dalgacık analizi ile onar dakikalık ortalama rüzgâr şiddeti ve gelen güneş radyasyonu miktarının zamansal değişimine etki eden büyük ve küçük ölçekli olaylar incelenmiştir. Bu gözlem verilerinin periyodik yapısı yorumlanmıştır.

Üçüncü aşamada geleneksel istatistiksel metotlar kullanılarak rüzgar şiddeti ve güneş radyasyonu için ileriye yönelik tahmin çalışması gerçekleştirilmiştir. İstatistiksel olarak Çoklu Lineer Regresyon (*ing. Multiple Linear Regression ; MLR*) modelleri SPSS programı yardımı ile rüzgâr şiddeti ve güneş radyasyonu tahmini için gözlem verilerine uygulanmıştır.

Tezin dördüncü aşamasında doğrusal olmayan ilişkileri modellemedeki başarısı nedeniyle rüzgar şiddeti ve güneş radyasyonunun tahmini için yapay sinir ağları

kullanarak tahmin çalışması yapılmıştır. Bu aşamada YSA modelleri farklı parametrelerle tahmin için denenmiş ve en uygun modeller ortaya çıkartılmıştır.

Beşinci ve son aşamada YSA modellerinin tahmin başarısını artırmak için verilere dalgacık ayrışması ön işlemi uygulanarak dalgacık yapay sinir ağı (D-YSA) şeklinde hibrit modelleme ile tahmin çalışması yapılmıştır.

Tahmin çalışmasında kullanılan modellerin başarısı Korelasyon Katsayısı (R), Determinasyon Katsayısı (R^2), Hata Kareleri Ortalamasının Karekökü (RMSE), Normalize Hata Kareleri Ortalamasının Karekökü (nRMSE) ve Mutlak Hata Oranları Ortalaması (MAPE) gibi istatistiksel yöntemlerle karşılaştırılmıştır. Böylece hangi modelin hangi ayda daha başarılı olduğu ortaya konulmuştur. Tez çalışmasına ait akış şeması Şekil B.17'de verilmiştir.

1.3 Literatür Özeti

Rüzgar ve güneş enerjisinin önceden tahmini, meteorolojik koşulların değişkenliği ve düzensizliği nedeniyle oldukça zordur. Bilim adamları ve araştırmacılar şimdiye kadar güneş radyasyonu ve rüzgar şiddetinin ileriye yönelik tahmini için birçok araştırma yapmışlardır. Yapılan literatür taramasında bu konuda çok sayıda yöntemin kullanıldığını göstermektedir. Sun ve diğ. (2018) güneş radyasyonu tahmin yöntemlerini üç kategoriye ayırmışlardır; matematik ve istatistik tabanlı geleneksel yöntemler (*ing.* traditional mathematical statistics), sayısal hava tahmini (*ing.* numerical weather forecasting) ve makine öğrenmesi (*ing.* machine learning). Matematik ve istatistik tabanlı geleneksel yöntemler şunları içerir; regresyon analizi, zaman serileri analizi, gri veya kara kutu teorisi, bulanık teori, dalgacık analizi ve Kalman filtresi. Sayısal hava tahmini performanslı bilgisayarların meteorolojik verileri kullanarak karmaşık denklemleri çözmesi ile gerçekleştirilir. Büyük veri madenciliğinin gelişmesiyle beraber makine öğrenmesi teknikleri günümüzde büyük ilgi görmektedir. Örneğin yapay sinir ağları, destek vektör makineleri (SVM) ve sezgisel akıllı optimizasyon algoritmaları güneş radyasyonu tahmininde yaygın olarak kullanılmaktadır (Sun, Wang, Zhang, & Zheng, 2018).

Zaman serileri analizi kullanılarak yapılan bir çalışmada Huang ve diğ. (2013) bulutlu günlerde 1 saat sonraki güneş radyasyonunu tahmin etmek için otoregresif (AR) ve dinamik sisteme dayalı kombine bir model kullanmışlar ve çıkan sonuçlarda genel

sinir ađlarına veya rastgele modellere gre dođruluđun %30 oranında arttıđı grlmřtr.

Bir bařka alıřmada Chen ve diđ. (2013) bulanık mantık ve yapay sinir ađına dayalı yeni bir gneř ıřınımı tahmin tekniđi nermiřlerdir. Gkyz kořulları ve sıcaklık bilgileri bulanık mantık kurallara gre farklı bulanık kmeler olarak sınıflandırılır. Bulanık mantık ve yapay sinir ađını birlikte kullanarak farklı gkyz ve sıcaklık kořullarında tahmin iřlemi gerekleřtirilmiřtir. Yaklařımın etkinliđi, drt farklı senaryonun test edildiđi bir vaka alıřması ile dođrulanmıřtır. MAPE %6.03 – %9.65 ile diđer gneř radyasyon yntemine gre ok daha dřktr. nerilen yntem saatlik ve gnlk gneř radyasyonu tahmini iin kullanılabilir.

Erdil ve Araklıođlu (2013) Trkiye’de farklı lm istasyonlarından elde edilmiř boylam, rakım, ay, gnlk minimum ve maksimum nem, ortalama gneřleme sresi, gnlk minimum ve maksimum sıcaklık, gnlk minimum ve maksimum basın verilerini girdi olarak kullanan ve gnlk gneř radyasyonunu tahmin eden yapay sinir ađı modeli kullanmıřlardır. Test sonularında determinasyon katsayısı (R^2) deđerı 0.997 ve ortalama yzde hata 5.775 olarak bulunmuřtur. Elde edilen sonular tahmini ve llen deđerler arasındaki farkın ok dřk olduđunu gstermektedir.

Fidan ve diđ. (2014), İzmir’de gri kutu teorisi olarak adlandırılan Fourier dnřm ve yapay sinir ađlarının btnleřmesiyle saatlik gneř ıřınımını ngrmřlerdir. Bu alıřmada sabahın erken saatlerinde elde edilen gneř ıřınımı verilerini kullanarak gneř ıřınımı verilerinin davranıřını herhangi bir gnde aıklamanın mmkn olduđu grlmřtr.

Akarıslan ve diđ. (2014) gneř ıřınımını tahmin etmek iin ok boyutlu dođrusal ngrmeli filtreleme modelini kullanmıřlardır. Bu teknik, yıllık bazda saatlik gneř ıřınımlarını ve sıcaklıkları zaman iinde ok boyutlu grntler olarak deđerlendirir. Bu grntler nerilen optimal katsayılı dođrusal tahmin filtrelerinin yardımı ile birbirine bađlanmıřtır. Bu filtreler genel deseni tarar ve sonraki saatin gneř ıřınımı verilerine karřılık gelen piksel deđerı tahmin edilir. Bu alıřmada 14 farklı model ve 9 farklı filtre kademe konfigrasyonu tasarlanmıř ve test edilmiřtir. Her modelin performansı birbirleriyle ve daha nce geliřtirilen modellerle karřılařtırılmıřtır. Deneysel sonular, nerilen yaklařımın tahmin dođruluđunda nemli bir iyileřtirme sađladıđını gstermiřtir.

Esnek hesaplama yöntemlerini içeren makine öğrenmesi tekniklerinin tahmin yöntemi olarak birçok araştırmacı tarafından kullanıldığı ve bazı yönlerden diğer yöntemlerden üstün olduğu yapılan literatür taramasında görülmüştür. Amrouche ve Le Pivert (2014) Amerika Birleşik Devletleri'ndeki dört bölgenin günlük toplam güneş ışınımını tahmin etmek için mekânsal modelleme ve yapay sinir ağlarını kullanmışlardır. Deneysel sonuçlar önerilen modelin tahmin başarısında beklenen doğruluk gereksinimlerini karşıladığını göstermektedir.

Long ve diğ. (2014) çiy sıcaklığı, güneşlenme süresi, rüzgar hızı, güneş radyasyonu, üretilen güç gibi parametrelere bağlı olarak günlük güneş enerjisi tahminini ANN dahil dört farklı yöntemle gerçekleştirmişlerdir. Tahminde daha etkili olabilecek parametreleri seçmek için korelasyona dayalı parametre seçim prosedürü uygulanarak önemli parametreler modellerde giriş olarak seçilmiştir. ANN sonuçlarında R^2 değeri 0.909, RMSE değeri 59.57, MAPE %11.87 olarak bulunmuştur.

Regresyon analizi kapsamında Trapero ve diğ. (2015), İspanya'da kısa vadeli (1-24 saat) güneş ışınımını öngörmek için Dinamik Harmonik Regresyon (DHR) modelini uygulamıştır. Sonuçlar 24 saatlik bir tahmin ufku için DHR'nin küresel ve doğrudan radyasyon için sırayla %30 ve %47 olmak üzere en düşük rRMSE değerlerine ulaştığını göstermektedir. İspanya'da bulunan meteoroloji istasyonlarında ölçülen güneş radyasyonu verileri kullanılarak doğrulanmış sonuçlara göre DHR'nin tahmin doğruluğunu önemli ölçüde geliştirdiğini ve dolayısıyla rekabetçi bir tahmin tekniği olarak değerlendirilebileceğini göstermektedir.

Bou-Rabee ve diğ. (2017) Kuveyt'te beş farklı bölgeden elde edilen verileri kullanarak günlük ortalama güneş radyasyonunu tahmin etmek için YSA modelleri kullanmışlardır. 2007-2010 arası verilerle eğitilen model, 2011 verileri ile test edilmiştir. Geliştirilen üç farklı YSA modeli içerinden Levenberg-Marquardt algoritmasını kullanan model 85,6 MAPE değeri ile en başarılı sonucu vermiştir.

Mghouchi ve diğ. (2019) günlük güneş radyasyonunu tahmin etmek için kullanılan parametrelerin en iyi girdi senaryolarını belirlemek için ileri beslemeli geri yayımlı YSA'ya dayalı yeni bir yaklaşım sunmuşlardır. Önerilen yaklaşım mükemmel korelasyonlar verebilecek en iyi senaryoları belirlemek için tüm olası giriş kombinasyonları arasındaki karşılaştırmalara dayanmaktadır. Çalışmada farklı iklim bölgelerine ait 35 istasyondan (Fas'ta 27 ve komşu ülkelerde 27) kaydedilen veriler

kullanılmıştır. Dokuz giriş parametresine bağlı olarak 511 olası giriş kombinizasyonundan sadece 128 tanesi en iyi senaryo olarak bulunmuştur. Sonuçlar güneş radyasyonunu tahmin etmek için en iyi girdi senaryosunun sadece üç iklimsel parametreye dayandığını göstermiştir; açıklık indeksi (*ing.* clearness index dimensionless), ortalama sıcaklık, atmosfer üstü radyasyon (*ing.* top of atmosphere). Çalışmada yapılan istatistiksel analiz sonuçları güneş radyasyonunun ölçülen ve öngörülen değerleri arasındaki mükemmel korelasyon ve yaklaşımları göstermektedir. Fan ve diğ. (2019) küresel güneş radyasyonu tahmininde kullanılan ampirik ve makine öğrenmesi yöntemlerini kapsamlı bir literatür taraması yaparak özetlemişlerdir. Ayrıca Çin'in farklı iklim bölgelerinde küresel güneş ışınımı tahmininde 12 ampirik ve 12 makine öğrenmesi yöntemi kullanarak performanslarını karşılaştırmışlardır. Sonuçlar, makine öğrenmesi modellerinin (RMSE: 2.055-2.751 MJm⁻² d⁻¹; R²: 0,839-0,936) genellikle ampirik modellerden (RMSE: 2.118–3.540 MJm⁻² d⁻¹; R²: 0.834-0.935) daha iyi performans gösterdiğini ortaya koymaktadır. Adaptive Neuro Fuzzy Inference System (ANFIS), Extreme Learning Machine (ELM), Least Square Support Vector Machine (LSSVM) ve Multivariate Adaptive Regression Spline (MARS)'ın makine öğrenimi modelleri arasında diğerlerine göre genellikle daha iyi performans elde ettikleri görülmüştür. Tahmin doğruluğu ve hesaplama maliyetleri dikkate alındığında, çalışmada ANFIS şiddetle tavsiye edilmektedir.

Zang ve diğ. (2019) yaptıkları çalışmada, 1994'ten 2015 yılına kadar Çin'in altı iklim bölgesinde 35 meteoroloji istasyonunda ölçülen verilere dayanan yatay yüzeyde günlük küresel güneş ışınımını tahmin etmek için yılın gününe (*ing.* day of the year based; DYB) dayalı yedi tane ampirik ve yedi tane de makine öğrenmesine dayalı toplam 14 farklı model kullanmışlardır. Çalışmada ampirik modellerin tahmin doğruluğunu arttırmak için yeni bir hibrid 3. dereceden polinom ve sinüs dalga modeli önerilmiştir. Önerilen yeni ampirik modelin RMSE, MAPE, MABE ve R değerleri sırasıyla 1.410 - 2.986 MJ/m², %5.355 - %20.412, 1.090 - 2.300 MJ/m² ve 0.698 - 0.980 aralığındadır. Ayrıca ANFIS-CFA ve ANFIS-WOASAR olmak üzere farklı iklim koşullarına mükemmel adaptasyon sergileyen iki yeni akıllı optimize edilmiş model önerilmiştir. Önerilen bu iki modelin RMSE, MAPE, MABE ve R değerleri sırasıyla 1.203 - 2.491MJ/m², %4.516 - %18.976, 1.090 - 2.300 MJ/m² ve 0.877 - 0.983 aralığındadır ve ampirik modellerden daha başarılıdır.

Benali ve diğ. (2019) Fransa Odeillo bölgesinde akıllı kalıcılık (*ing. smart persistence*), yapay sinir ağı ve rastgele orman (*ing. random forest*) olmak üzere üç yöntem kullanarak ölçülen güneş radyasyonunun üç bileşenini (küresel yatay, normal ışın ve dağınık yatay) tahmin çalışması yapmışlardır. Çalışmadaki amaç bir ile altı saat zaman ufku için saatlik güneş radyasyonunu tahmin etmektir. Rastgele orman (RF) yöntemi en verimli yöntem olarak bulunmuştur. Rastgele orman yöntemi regresyon ağacı ailesine aittir, torbalama regresyon ağacının geliştirilmiş bir modelidir. YSA ve akıllı kalıcılık ile karşılaştırıldığında RF kullanımının getirdiği gelişme, tahmin ufku ile birlikte artmaktadır. Mevsimsel çalışmaya göre ilkbahar ve sonbaharda güneş radyasyonunu öngörmenin kış ve yaz aylarına göre daha az güvenilir olduğunu göstermektedir, çünkü bu dönemlerde meteorolojik değişkenlik daha fazladır.

YSA'ların öğrenme süreci, rüzgar şiddeti veya güneş radyasyonu zaman serisi verilerinin anomalileriyle bozulabilir ve bu tahmin doğruluğunun düşmesine neden olur. Rüzgar veya güneş zaman serisi verilerini makine öğrenmesi, veri kümeleme ve sınıflandırma gibi yöntemler vasıtasıyla işlemek ve analiz etmek, tahmin doğruluğunu önemli ölçüde artırabilir. Ghofrani ve diğ. (2019), örüntü tanıma ve makine öğrenme tekniklerinin güneş ışınımı tahmini için kullanıldığını gösteren kapsamlı bir literatür taraması yapmışlardır. Bu araştırmanın sonuçları, veri kümeleme veya sınıflandırma ile düzensiz olan güneş ışınımı zaman serilerinin düzensiz kalıplarının tanımlanmasının, sinir ağları için daha iyi bir eğitim sağladığını ve tahmin doğruluğunu artırdığını göstermektedir. Bununla birlikte, çoklu örüntü tanıma ve makine öğrenme tekniklerini kullanan hibrit tahmin yöntemlerinin hesaplama karmaşıklıkları, bunları çevrimiçi tahminler veya çok kısa vadeli tahminler için yetersiz kılmaktadır (Ghofrani, Azimi, & Youshi, 2019).

Güneş radyasyonunda olduğu gibi rüzgar şiddetinin ileriye yönelik tahmini konusunda da farklı tekniklerin kullanıldığı yapılan literatür taramasında görülmüştür. Korkmaz ve diğ. (2018) genel olarak tahmin yöntemlerini üç ana yaklaşım altında tanımlamaktadır; fiziksel, istatistiksel ve karma yöntemler.

En yaygın fiziksel yöntem meteoroloji uzmanları tarafından geliştirilen sayısal hava tahmin yöntemidir (NWP). Bu yöntemin temel amacı atmosferik olayları matematiksel modeller kullanarak tanımlamaktır. Mükemmel bir tahmin gerçekleştirebilmek için büyük miktarlarda hava durumu verisinin süper bilgisayarlar vasıtasıyla yoğun hesaplamalar yapılarak işlenmesini gerektirir. Hesaplama süresi uzun olan NWP

sistemleri uzun vadeli tahminlerde daha etkilidir. Rüzgar şiddetinin kısa sürelerdeki yüksek değişkenliği nedeniyle NWP sistemleri kısa süreli tahminlerde etkisizdir (Korkmaz, İzgi, & Tutun, 2018).

Son yayınlar fiziksel yöntemlerin yerine istatistiksel yöntemlerin ön plana çıktığını göstermektedir. Korkmaz ve diğ. (2018) göre istatistiksel tahmin yöntemleri iki ana yaklaşıma ayrılabilir: (1) otoregresif ve hareketli ortalama modelleri gibi zaman serisi modelleri ile (2) YSA ve bulanık mantık gibi esnek hesaplama yöntemlerini kullanan modeller. Ayrıca tahmin hatalarını azaltmak için genetik algoritmalar (GA), SVM ve Kalman filtreleme (KF) yaklaşımlarının kullanıldığı görülmektedir.

Günümüzde çok sayıda araştırmacının kısa vadeli rüzgar şiddetini tahmin etmek için YSA temelli esnek hesaplama yöntemlerini kullandığı yapılan literatür taramasında görülmektedir. YSA'nın diğer modellere göre avantajı, doğrusal olmayan ilişkiler içeren çok değişkenli bir problemi modelleme kabiliyetidir. Rüzgar şiddeti verilerinin doğrusal olmayan ilişkilerini modellemede YSA'lar oldukça etkili olmaktadır. (Ata, 2015).

Ramasama ve diğ. (2015) meteorolojik parametrelerin (sıcaklık, hava basıncı, güneş radyasyonu ve rakım) giriş değişkenleri olarak yer aldığı bir MLP yapay sinir ağı kullanarak Hindistan'ın Batı Himalaya eyaletindeki 11 lokasyonda günlük rüzgar hızını öngörmüşlerdir. Öngörülen ve ölçülen rüzgar hızları arasındaki MAPE ve korelasyon katsayısı sırasıyla % 4.55 ve 0.98 olarak bulunmuştur. Model, ölçülen verilerin mevcut olduğu başka bir yerde doğrulanmış ve MAPE %6.489, korelasyon katsayısı 0.99 olarak yüksek tahmin doğruluğunu gösterir şekilde bulunmuştur.

Zaman serisi modellerinden olan doğrusal ve doğrusal olmayan otoregresif modellerin kısa vadeli rüzgar tahmini için kullanıldığı görülmektedir. Lydia ve diğ. (2016) yaptıkları çalışmada doğrusal ve doğrusal olmayan otoregresif hareketli ortalama yöntemlerini kullanarak, 1 saate kadar 10 dakikalık aralıklarla rüzgar hızını tahmin etmek için modeller oluşturmuşlardır. Çalışmada modellerin doğruluğu, Ortalama Mutlak Hata (MAE), RMSE ve MAPE olmak üzere üç performans ölçümü kullanılarak ölçülmüştür.

Ghorbani ve diğ. (2016) YSA ve Genetik Ekspresyon Programlama (GEP) kullanarak kısa vadeli bir rüzgar tahmin tekniği sunmaktadırlar. Çalışmada Amerika Birleşik Devletleri Colorado eyaletindeki Kersey sahasında 8 yıllık kayıtlı rüzgar verileri

kullanılmıştır. Tahmin sonuçları MLR yöntemiyle ve veriler için geliştirilen kalıcılık yöntemiyle karşılaştırılmıştır. Model performansları korelasyon katsayısı, kök ortalama kare hatası, Nash-Sutcliffe verim katsayısı ve Akaike bilgi kriteri kullanılarak değerlendirilmiştir. Sonuçlar, tahmin edilen rüzgar hızının yalnızca geçmiş rüzgar hızı kayıtları kullanılarak gerçekleştirilebildiğini göstermektedir. Veriler için maksimum sağlama süresinin 14 saat olduğu bulunmuştur. Sonuçlar hem GEP hem de YSA'nın eşit derecede güvenilir seçimler olduğunu ve kullanımları nedeniyle MLR'nın bile reddedilmemesi gerektiğini göstermektedir.

Akcan (2017) Türkiye'de bulunan beş farklı bölgedeki dokuz meteoroloji istasyonundan elde edilen aylık ortalama rüzgar şiddeti verilerini kullanarak rüzgar hızı tahmini yapmıştır. Çalışmada zaman serisi istatistiksel analiz metotları kullanılmıştır. Ele alınan metotların başarımı beş farklı performans ölçüm yöntemi ile karşılaştırılmıştır. Performans ölçüm sonuçlarının kabul edilebilir seviyede olduğu ve ele alınan yöntemlerin rüzgar hızı tahmininde kullanılabilceğini göstermektedir. Çalışmada kullanılan yöntemlerden trend ve mevsimsellik ile üstel yumuşatmanın (*ing.* exponential smoothing with trend and seasonality) tüm istasyonlar için en uygun olduğu söylenebilir.

Korkmaz ve diğ. (2018) Marmara bölgesi Silivri ilçesinde farklı yüksekliklerden (30 m, 50 m, 60 m) elde edilen bir yıllık rüzgar verilerini kullanarak yaptıkları çalışmada ANFİZ ve YSA gibi esnek hesaplama yöntemleri kullanarak geliştirdikleri 4 farklı model ile ileriye yönelik kısa süreli tahminler yapmışlardır. Elde edilen en düşük RMSE 0.5942 ve elde edilen en yüksek R^2 değerleri 0.9753 dir. Çalışmanın deneysel sonuçlarına göre, rüzgar hızının her yükseklik için davranışının aynı görünse de, rüzgar hızını en iyi doğrulukla tahmin edecek tek bir model olmadığını ortaya koymaktadır. Bu nedenle esnek hesaplama yöntemlerine yönelik her model, farklı yükseklikler için değiştirilerek rüzgar hızı tahmin doğruluğu artırılmalıdır.

Alkan ve diğ. (2018) Düzce bölgesinde yaptıkları çalışmada rüzgar ve güneşe dayalı yenilenebilir enerji santrallerinde kullanılmak üzere kısa dönem enerji üretim tahmini yapmak için çoklu regresyon analizi kullanmışlardır. Modelde girdi olarak sıcaklık, güneş radyasyonu, rüzgar şiddeti kullanılmıştır. Çıktı olarak üretilen elektrik enerji miktarı elde edilmiştir. Güneş enerjisi tahmini için geliştirilen modelin R^2 değeri 0.997, RMSE değeri 3.443, MAPE ise 5.43 olarak bulunmuştur. Rüzgar enerjisi için

geliştirilen modelin R^2 değeri 0.9995, RMSE değeri 4.514, MAPE ise 0.6 olarak bulunmuştur. Sonuçlar regresyon modelinin güvenilir olduğunu göstermektedir.

Kırbaş (2018) Antalya Bakırlitepe Yerleşkesinde bulunan TÜBİTAK T60 teleskobundan elde edilen rüzgar şiddeti zaman serisinin geçmiş verilerini kullanarak ileriye yönelik kısa dönem çok adımlı rüzgar hızı tahmini gerçekleştirmiştir. Veriler 20 dakikalık ortalamalar şeklinde düzenlenmiş 1224 adet kayıttan oluşmaktadır. Model olarak ARIMA ve NAR tipi YSA kullanılmıştır. Geliştirilen modeller beş farklı istatistiksel yöntemle karşılaştırılmıştır. Sonuçlar ARIMA modellerinin en iyi RMSE değerleriyle NAR-YSA modellerinden daha başarılı olduğunu göstermektedir. NAR ağlarında geriye dönük parametre sayısı artırıldığında başarımın azaldığı bunun nedeni olarak da rüzgar şiddeti verilerinin oldukça değişken yapıda olması gösterilmektedir.

Literatürde yapılan taramada rüzgar şiddetini tahmin etmek için hibrit modellerin de başarılı bir şekilde kullanıldığı görülmektedir. Guo ve diğ. (2011) geri yayılım yapay sinir ağına (BPNN) ve mevsimsel düzenlemeye sahip hibrit tahmin yöntemini ile 2001'den 2006'ya kadar Çin'deki Minqin bölgesinden toplanan bir rüzgar hızı veri setini kullanarak bir tahmin çalışması yapmışlardır. Sonuçlar yalnızca BPNN kullanmak yerine tahmin performansını iyileştirmek için karma bir tekniğin kullanılması gerektiğini göstermektedir.

Liu ve diğ. (2012) ARIMA-YSA ve ARIMA Kalman filtre modelleri olarak bilinen iki yeni hibrid yaklaşımı rüzgar şiddeti tahmini için kullanmışlardır. Sonuçlar her iki modelin de rüzgar enerjisi sistemlerinde durağan olmayan rüzgar hızı tahminine uygulanabilecek iyi performansa sahip olduğunu göstermektedir.

Singh ve Mohapatra (2019) çok kısa vadeli rüzgar hızı tahminleri için doğruluğu arttırılmış tekrarlanan dalgacık dönüşümü bazlı ARIMA (RWT-ARIMA) modeli önermektedirler. Yaptıkları çalışmada İrlanda Cumhuriyeti'nin Donegal İlçesinde Malin Head'deki Met Eireann istasyonunun 2017 Aralık ayı için 1 ve 10 dakikalık gerçek rüzgar hızı verilerini kullanmışlardır. 3 dak., 5 dak. ve 7 dak. çözünürlükteki veriler mevcut 1 dak. verilerden elde edilmiştir. Önerilen modelin çok kısa vadeli rüzgar hızı tahminlerinde 1 dak., 3 dak., 5 dak., 7 dak. ve 10 dak. gibi çeşitli zaman ölçekleri için ARIMA modeli ve WT-ARIMA modeli ile karşılaştırması yapılmıştır.

Bu karşılaştırma, önerilen RWT-ARIMA modelinin çok kısa vadeli rüzgar hızı tahmininde diğer modellere göre üstünlüğünü kanıtlamaktadır.

Tipik bir rüzgar şiddeti, rüzgar şiddetindeki uzun vadeli trendi temsil eden ve yavaş hareket eden bir değişkenliğe sahiptir. Yavaş hareket eden varyasyonun yanı sıra küçük bir zaman diliminde ortaya çıkan yüksek bir frekans varyasyonuna da sahiptir. Bu varyasyon fırtına, türbülans vs.'ye tekabül eder. Dalgacık dönüşümü (WT) sayesinde düşük frekansın yanı sıra yüksek frekans bileşenlerini farklı zaman serisi sinyalleri olarak elde etmek mümkündür. Bu farklı zaman serileri daha sonra seçilen modeller ile modellenir. Örneğin düşük frekanslı bir zaman serisi sinyali, yüksek frekanslı bir zaman serisi sinyaline kıyasla ARIMA modeli ile daha etkili bir şekilde modellenir. Bu, WT-ARIMA modeli ile rüzgar hızındaki uzun vadeli eğilimin, fırtına ve türbülans modellemesine kıyasla daha kesin bir şekilde modellenebileceği anlamına gelir. Bu nedenle yüksek frekanslı zaman serisi modelinden rüzgar hızı tahminine yapılan hata katkısı, düşük frekanslı zaman serisi modelinden kaynaklanan hata katkılarıyla karşılaştırıldığında daha fazladır (Singh & Mohapatra, 2019).

Dalgacık dönüşümü ve YSA'nın birlikte kullanılarak geliştirilen hibrit modellerle yapılan tahmin çalışmalarında başarımın arttığı yapılan literatür taramasında görülmüştür. Melit ve diğ. (2006) yaptıkları çalışmada 1989'dan 2000 yılına kadar güneş radyasyonu verilerini kullanarak 2001 yılındaki toplam güneş radyasyonunu tahmin etmek için uyarlamalı dalgacık sinir ağı modeli kullanmışlardır. Kullanılan yöntemin hata yüzdesi %6 ile geleneksel sinir ağı modellerinden ve klasik istatistiksel yöntemlerden daha iyi performans göstermiştir.

Partal ve diğ. (2008) dalgacık dönüşümü ve YSA yöntemi ile Türkiye'de üç farklı istasyona ait verileri kullanarak günlük yağış tahmini yapmıştır. Çalışmada 1987-1998 yılları arasındaki 4383 veri eğitim amaçlı, 1999-2001 yılları arasındaki 1096 veri test amaçlı kullanılmıştır. Giriş olarak kullanılan altı farklı veri grubu dalgacık dönüşü ile 11 seviyeye kadar ayrıştırılmış ve elde edilen alt zaman bileşenlerinin tahmin edilmek istenilen orijinal yağış verisi ile korelasyonuna bakılmıştır. Yüksek korelasyona sahip alt zaman bileşenleri seçilerek toplanmak suretiyle giriş için yeni zaman serileri elde edilmiştir. Sonuçlar ÇLR ile kıyaslanmış ve dalgacık YSA modellerinin daha başarılı olduğu görülmüştür. Kullanılan modeller arasında ileri beslemeli geri yayımlı dalgacık YSA modelleri determinasyon katsayı (R^2) değerleri 0.70 – 0.90 arasında en iyi sonucu vermiştir.

Taşcıkaraoğlu ve Uzunoğlu (2011) Yıldız Teknik Üniversitesi Davutpaşa kampüsünden elde edilen ve birer dakika aralıklarla kaydedilen 35 saatlik verileri kullanarak dalgacık dönüşümü ve YSA ile üç ve altı adım ilerisi için tahmin çalışması yapmışlardır. Daubechies 1 (db1) dalgacığı kullanarak 2 seviyeli ayrıştırma ile alt zaman bileşenlerine ayrılan veriler YSA'da giriş olarak kullanılmıştır. Sonuçlar dalgacık dönüşümü ön işlemi uygulamasının YSA modellerinde başarımı her durumda artırdığını ortaya koymuştur.

Terzi ve Barak (2015) Türkiye'de Sivas İlinde 1993-2005 arasında ölçülmüş günlük ortalama yağış değerleri ile Kızılırmak Nehri'nde bulunan Söğütluhan akım istasyonuna ait günlük ortalama akarsu akım değerlerini tahmin etmek için YSA ve dalgacık YSA modelleri kullanmışlardır. Çalışmada orijinal giriş zaman serisi verileri Meyer (dmey) ve Haar dalgacığı kullanılarak 12. seviyeye kadar ayrıştırılmıştır. Daha sonra elde edilen alt bileşenler ile model çıktısı arasındaki korelasyon değerleri hesaplanmış ve uygun olan alt bileşenler seçilmiştir. Seçilen alt bileşenler ayrı ayrı ve toplanmış olarak YSA modellerine giriş olarak uygulanmıştır. Sonuçta dalgacık dönüşümü ön işleminin uygulandığı tüm YSA modellerinin normal YSA modellerine göre daha başarılı olduğu görülmüştür. Ayrıca alt bileşenlerin toplanarak girdi olarak kullanıldığı D-YSA modellerin alt bileşenlerin ayrı olarak kullanıldığı modellere göre genel olarak daha başarılı olduğu görülmüştür.

Monjoly ve diğ. (2017) dalgacık ayrıştırma da dahil olmak üzere çeşitli çoklu ölçekli ayrıştırma yöntemleri kullanan ve 1 saat ilerisi için güneş radyasyonu tahmini yapan yeni bir yaklaşım önermişlerdir. Tahmin sonuçları dalgacık ayrışmasının diğer ayrıştırma yöntemlerinden daha iyi sonuç verdiğini göstermektedir. Çalışmada dalgacık ayrıştırma ve yapay sinir ağı hibrit tahmin modeli için rRMSE değeri % 7.86 ve beceri değeri % 72.08 olarak bulunmuştur.

Dalgacık dönüşümü rüzgar şiddeti verilerini herhangi bir stokastik oynaklıktan filtrelemek için kullanılır. Dhiman ve diğ. (2019) dalgacık dönüşümü ve Support Vector Regression (SVR)'dan oluşan bir tahmin yönteminin performansını analiz etmişlerdir. Hibrit yöntemin değerlendirilmesi dört veri seti üzerinde yapılmıştır. Kullanılan yöntemde orijinal rüzgar şiddeti zaman serilerinde Daubechies 4 (db4) ile 5 seviyeli bir ADD gerçekleştirmiş ve yön zaman serileri ile birlikte yaklaşım ve ayrıntı alt zaman sinyalleri SVR modelinde girdi olarak kullanmıştır. En iyi performansın alındığı modelde RMSE 1.157 m/s, MAE 57.25 olarak bulunmuştur.

Rüzgar şiddeti tahmini, rüzgara dayalı enerji sistemlerinin yönetimi için büyük önem taşımakta ve şebekenin entegrasyonunda önemli bir rol oynamaktadır. Rüzgar şiddeti doğada değişkendir ve bu nedenle tek bir modelle tahmin etmek zordur. Zhang ve diğ. (2019) yaptıkları çalışmada üç tane hibrit çok kademeli rüzgar şiddeti tahmin modeli geliştirmiş, bu modelleri birbirleriyle ve daha önce önerilen rüzgar şiddeti tahmin modelleri ile karşılaştırmışlardır. Bu üç model dalgacık ayrıştırmasına (WD), Cuckoo arama (CS) optimizasyon algoritmasına ve dalgacık sinir ağına (WNN) dayanmaktadır. CS, modellerin parametrelerini ve diğer pratik problemleri optimize etmek için geniş ve başarılı bir şekilde kullanılan yeni bir optimizasyon metaheuristik algoritmasıdır. Bu çalışmada, Çin'in doğusundaki Shandong'da bulunan iki rüzgar çiftliğinden elde edilen rüzgar şiddeti verileri kullanılmıştır. Sonuçlar üç hibrit model arasında ve daha önceden önerilen modeller arasında CS-WD-WNN'nin en düşük MAE, MAPE ve RMSE değerlerine ve her durumda en yüksek R değerlerine sahip olan en iyi performansı gösteren model olduğunu göstermektedir. CS-WNN'de CS algoritması, tahmin parametrelerini belirlemek için dalgacık aktivasyon fonksiyonlarına uygulanır. Son olarak CS-WD-WNN'de orijinal seri dalgacık analizi ile farklı frekanslarda alt sıra dalga formlarına ayrıştırılır. Bu dalga formları WNN'de giriş olarak kullanılır. CS algoritması nihai sonucu elde etmek için her WNN'nin parametrelerini optimize etmek için kullanılır.

2. MATERYAL VE YÖNTEM

Çalışmada kullanılan veriler belirli bir bölgeden alınmıştır. Literatürde rüzgar şiddetine ait zaman serilerinin kısa süreli incelemelerde gece gündüz, uzun süreli incelemelerde ise mevsimler arasında periyodik örüntülere sahip olduğu görülmüştür (Hocaoğlu, Fidan, & Gerek, 2009). Ayrıca birçok tahmin çalışmasında aylık veya mevsimlik olarak analiz yapıldığı görülmektedir (Aghajani, Kazemzadeh, & Ebrahimi, 2016; Cantürk, 2018). Bu çalışmada mevsimsel etkileri ortaya çıkarmak için veriler her mevsimi temsilen birer ay seçilerek dört gruba ayrılmıştır. Veriler gruplar bazında istatistiksel olarak analiz edilmiş ve yorumlanmıştır. Rüzgar şiddeti ve güneş radyasyonu verilerine sürekli ve ayrık dalgacık analizi uygulanarak büyük ve küçük ölçekli olayların etkisi ortaya çıkartılmıştır. ÇLR, YSA ve D-YSA modelleri kullanılarak mevcut meteorolojik veriler ile ileriye yönelik bir günlük zaman periyodunda ve onar dakikalık adımlarla rüzgar şiddeti ve güneş radyasyonu tahmin çalışması yapılmıştır. Sonuçlar Korelasyon Katsayısı (R), Determinasyon Katsayısı (R^2), RMSE, nRMSE ve MAPE kriterlerine göre karşılaştırılarak en başarılı modeller ortaya konulmuştur.

2.1 Çalışma Bölgesi ve Veriler

Bu çalışmada Şekil 2.1'deki haritada konumu gösterilen İstanbul İli Büyükçekmece İçesinde bulunan TARBİL Eskice Mevki istasyonundan alınan 2016 yılına ait veriler kullanılmıştır. Veriler 10 dakikalık periyotlarla kaydedilmiştir. Her veri grubundan toplamda 52576 adet kayıt bulunmaktadır. Çizelge 2.1'de istasyon bilgileri mevcuttur.

Çizelge 2.1: İnceleme Bölgesi ve Kullanılan Veriler

İstasyon adı, kodu, enlem ve boylam	Büyükçekmece, Eskice Mevki, 34.01 (41.0722 ° N, 28.5782 ° E , Rakım : 50m)
Dönemi	01.01.2016 – 31.12.2016
Veri Aralığı	10 dakika
İstasyon Verileri	Güneş Radyasyonu (W/m^2), Rüzgar Şiddeti (Km/saat), Sıcaklık 2m (°C), UV Radyasyon İndis, Toprak Üstü 5cm Sıcaklık (°C)
Kule Yüksekliği	10 m



Şekil 2.1: Eskice Mevki İstasyonu (41.0722 ° N, 28.5782 ° E , Rakım : 50m) (Url-3)

Ham veri setinde km/saat olarak bulunan Rüzgar Şiddeti Eşitlik (2.1) kullanılarak m/s (metre/saniye) birimine dönüştürülmüştür.

$$\text{Rüzgar Şiddeti}(m/s) = [\text{Rüzgar Şiddeti}(km/saat) \times 1000]/3600 \quad (2.1)$$

2.2 Verilere Uygulanan Önışlemler

Çalışmada kullanılacak olan veriler, tahmin modellerinde kullanılmadan önce birtakım ön işlemlerden geçirilmelidir. Veri madenciliği belirli bir süreci kapsamaktadır. Bu sürecin başlangıcında veri temizleme, veri bütünleştirme, veri indirgeme, veri dönüştürme gibi adımlar vardır (Özkan, 2016). İlk uygulanacak ön işlem veri madenciliği süreçlerinden olan ve veri temizleme kapsamında gerçekleştirilen, eksik verilerin yerine yenilerinin konulması işlemidir. Bu kapsamda verilerin tamamına ve çalışmada kullanılmak üzere seçilen aylardaki verilere SPSS programı kullanılarak kayıp veri analizi yapılmıştır. Bu analiz sonucunda kayıp içeren veri gruplarına SPSS programında lineer interpolasyon yöntemi kullanılarak kayıp verilerin yerine yenisi konulmuştur.

Veri madenciliği süreçlerinden olan ve veri dönüştürme kapsamında uygulanan bir diğer işlem normalizasyon işlemidir. YSA modellerinde verilerin kullanılmadan önce uygun olarak düzenlenmesi model başarımını artırmaktadır. Bu nedenle YSA ve D-YSA modellerinde kullanılacak tüm veriler Min-Max yöntemi ile Eşitlik (2.2) kullanılarak dönüştürülmüştür. Bu dönüştürme işlemi sonucunda tüm veriler 0 ile 1 arasındaki sayısal değerlere dönüştürülür (Özkan, 2016).

$$Y^* = \frac{X - X_{\min(ay)}}{X_{\max(ay)} - X_{\min(ay)}} \quad (2.2)$$

- Y^* : Dönüştürülmüş değerler
 X : Gözlem değerleri
 $X_{\min(ay)}$: İlgili ay için en küçük gözlem değeri
 $X_{\max(ay)}$: İlgili ay için en büyük gözlem değeri

2.3 Çoklu Lineer Regresyon

Regresyon analizi, iki yada daha çok değişken arasındaki ilişkiyi modellemede kullanılan metotlar arasında en yaygın olanıdır. Bağımlı değişkeni tahmin etmek için kurulan modelde giriş olarak tek bir bağımsız değişken kullanılıyorsa Tekli Regresyon, birden fazla bağımsız değişken kullanılıyorsa Çoklu Regresyon analizi olarak adlandırılır. Bağımlı ve bağımsız değişken yada değişkenler arasındaki ilişki doğrusal (linear) olabileceği gibi eğrisel de olabilir. Regresyon analizi ile bağımlı ve bağımsız değişkenler arasındaki ilişkinin varlığı, eğer ilişki var ise bunun gücü hakkında bilgi edinilebilir.

Çoklu Lineer Regresyon'da (ÇLR), n adet bağımsız değişken ($X_1, X_2, X_3 \dots X_n$) ile bağımlı değişken (Y) arasındaki doğrusal ilişki Eşitlik (2.3)'teki gibidir (Damodar, 2004).

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n + e \quad (2.3)$$

Burada Y bağımsız değişkeni, X_n bağımlı değişkenlerin doğrusal bir fonksiyonu olarak ele alınır. Eşitlikteki b_n değerleri modeldeki katsayılar olup, b_0 doğrunun Y eksenini kestiği noktayı göstermektedir. Eşitlikteki e ise hata terimi olarak tanımlanmıştır. Buradaki katsayılar en küçük kareler yöntemi ile bulunmaktadır.

En küçük kareler yaklaşımı kullanılarak Eşitlik (2.4)'te verilen tahmin hatası sıfıra indirgenmeye çalışılmaktadır (Aslan, Yavasca, & Yasar, 2011).

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.4)$$

Eşitlik (2.4)'te n veri sayısı, y_i gözlemlenmiş orijinal veri, \hat{y}_i modelin tahmin ettiği değer, SSE (*ing.* Sum of Squares for Error) ise tahmin hatalarının karesel toplamıdır.

Bu yöntemde SSE değişkeni, her katsayı farklılaştırıldıktan sonra sıfıra eşitlenmeye veya minimize edilmeye çalışılır. Bu şekilde Eşitlik (2.3)'de gösterilen regresyon denklemi elde edilir. Eşitlik(2.5)'te üç katsayı (a, b, c) ve iki bağımsız değişkenden (x_1, x_2) oluşan bir lineer regresyon denklemi ($y = a + bx_1 + cx_2$) için katsayıların hesaplanmasını sağlayan ve en küçük kareler yöntemi kullanılarak elde edilen denklem görülmektedir (Aslan, Yavasca, & Yasar, 2011).

$$\begin{bmatrix} n & \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{2i} \\ \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{1i}^2 & \sum_{i=1}^n x_{1i} \cdot x_{2i} \\ \sum_{i=1}^n x_{2i} & \sum_{i=1}^n x_{1i} \cdot x_{2i} & \sum_{i=1}^n x_{2i}^2 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{1i} y_i \\ \sum_{i=1}^n x_{2i} y_i \end{bmatrix} \quad (2.5)$$


2.4 Dalgacık (Wavelet) Dönüşümü

Wavelet (*ing.* Dalgacık) dönüşümü ve analizinin kullanımı yeni olmasına rağmen temelleri uzun süre önce Joseph Baptiste Fourier tarafından 1805 yılında atılmıştır. Fourier dönüşümü ile zaman serisi şeklindeki bir sinyalin frekans analizi yapılabilmektedir. Fourier analizi ile frekans bileşenleri ortaya çıkartılan sinyalin zaman bilgisi kaybolmaktadır. Bu nedenle zaman bilgisini kaybetmeden hem frekans hem de zaman bileşenlerini ortaya çıkartabilecek yeni bir sinyal işleme tekniğine ihtiyaç duyulmuştur.

Günümüzdeki kullanılan biçimiyle “Wavelet” kelimesi ilk defa Alfred Haar (1909) tarafından doktora tezinde ortaya atılmıştır. Daha sonraki yıllarda teorinin gelişmesine Paul Levy (1930), Jean Morlet ve Alex Grossmann (1980), Yves Meyer gibi bilim adamları katkıda bulunmuştur. Günümüzde kullanılan dalgacık dönüşümü algoritması Mallat (1989)'ın çalışmasına dayanmaktadır. Ayrıca Daubechies, Coifman ve Wickherhouser adlı bilim insanları da önemli katkılarda bulunmuşlardır (Graps, 1995).

Dalgacık analizi bir sinyalin içindeki hem zaman hem de frekans (ölçek) bilgisini açığa çıkarması nedeniyle son yıllarda popüler bir araç haline gelmiştir (Nourani, Komasi, & Mano, 2009). Dalgacık analizi orijinal bir sinyali analiz ve işleme için farklı bir alana (özellikle zaman alanında) dönüştüren matematiksel bir prosedürdür. Bu model durağan olmayan veriler için, yani sinyalin ortalama ve oto korelasyonunun zaman

içinde sabit olmadığı durumlarda uygundur. Çoğu finansal zaman serisi ve iklimsel zaman serisi verileri durağan değildir; bu nedenle dalgacık dönüşümleri bu tür veriler için kullanılır (Nury, Hasan, & Alam, 2017). Şekil 2.2’de dalgacık dönüşümü gösterilmiştir (Yarımçam, 2009).



Şekil 2.2 : Dalgacık Dönüşümü (Wavelet Transform)

Dalgacık fonksiyonlarını, “ana dalgacık” olarak adlandırılan tek bir fonksiyonun dönüşüm ve açılımından oluşan bir fonksiyonlar ailesi olarak kabul edilir. Bu dalgacıklar Eşitlik (2.6) ile tanımlanır (Nury, Hasan, & Alam, 2017).

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-\tau}{s}\right); \quad s, \tau \in R; \quad s \neq 0 \quad (2.6)$$

- Ψ : Ana dalgacık
 s : Ölçekleme parametresi
 τ : Konum (kaydırma) parametresi

Ölçekleme parametresi sıkıştırma derecesini ölçer. Kaydırma parametresi ise dalgacığın zaman konumunu belirler. Dalgacık fonksiyonları aşağıdaki özelliklere sahip olmalıdırlar (Duran, 2013).

1. Dalgacık fonksiyonunun meydana getirdiği alan sıfır olmalıdır. Bu durum Eşitlik (2.7)’de gösterildiği gibi $(-\infty, +\infty)$ aralığında integralinin sıfıra eşit olması demektir.

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (2.7)$$

2. Dalgacık fonksiyonun Eşitlik (2.8)’de gösterildiği gibi $(-\infty, +\infty)$ aralığında karesinin integrali bire eşit olmalıdır.

$$\int_{-\infty}^{+\infty} \Psi^2(t) dt = 1 \quad (2.8)$$

3. Dalgacık fonksiyonunun enerjisi sonludur ve Eşitlik (2.9)'da gösterildiği şekilde sınırlı olmalıdır. Sınırlı fonksiyonun mutlak değerinin integrali de sınırlıdır.


$$\int_{-\infty}^{+\infty} |\Psi(t)| dt < \infty \quad (2.9)$$

4. Eşitlik (2.10)'de gösterildiği gibi dalgacık fonksiyonu $\Psi(\omega)$ 'da sifıra yaklaşmalıdır. $\Psi(\omega)$ ise Eşitlik (2.11)'deki gösterildiği şekilde $\Psi(t)$ 'nin Fourier dönüşümüne eşittir.

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (2.10)$$

$$\Psi(\omega) = \int_{-\infty}^{+\infty} \Psi(t) e^{-i\omega t} dt \quad (2.11)$$

Yukarıdaki koşulları sağlayan dalgacıklar ana dalgacık (*ing.* mother wavelet) olarak adlandırılırlar (Duran, 2013). Şekil 2.3'te örnek ana dalgacık şekilleri görülmektedir.



Şekil 2.3 : Örnek Dalgacıklar (Fugal, 2009)

2.4.1 Sürekli dalgacık dönüşümü

Sürekli Dalgacık Dönüşümü (SDD) (*ing.* Continuous Wavelet Transform - CWT) dalgacık fonksiyonunun (Ψ) ölçeklendirilmiş ve kaydırılmış versiyonları ile çarpılan bir sinyalin tüm zamanı boyunca toplamı olarak tanımlanır. SDD'nin sonucu olarak dalgacık katsayıları ortaya çıkar. Her katsayının uygun bir şekilde ölçeklendirilmiş ve

kaydırılmış dalgacık ile çarpılması, orijinal sinyalin oluşturucu dalgasını verir. SDD Eşitlik (2.12) ile ifade edilir (Arı, Özen, & Çolak, 2008).

$$CWT_{(s,\tau)} = \int_{-\infty}^{+\infty} f(t)\Psi_{s,\tau}^*(t)dt \quad (2.12)$$

* : Kompleks eşlenik


$f(t)$: Dönüşüm uygulanacak fonksiyon

$\Psi_{s,\tau}(t)$: Ana dalgacık fonksiyonu

Eşitlik (2.6)'ün Eşitlik (2.12)'da yerine konulmasıyla Eşitlik (2.13) elde edilir (Arı, Özen, & Çolak, 2008).

$$CWT_{(s,\tau)} = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t)\Psi^*\left(\frac{t-\tau}{s}\right)dt \quad (2.13)$$

SDD işleminin sonucunda dönüşümü gerçekleştirilen fonksiyonun farklı bölgeleri için farklı ölçeklerde katsayılar elde edilir. Elde edilen katsayılar Eşitlik (2.13)'da $CWT_{(s,\tau)}$ ile gösterilir. Bu katsayılar dalgacık fonksiyonu ile orijinal sinyalin regresyon sonucunu gösterir. Elde edilen katsayılar daha kolay yorumlanabilmesi için renk spektogramında büyüklüklerine göre farklı renklerde renklendirilerek gösterilir.



Şekil 2.4 : Sürekli Dalgacık Dönüşümü Renk Spektogramı (Peleg, 2000)

Şekil 2.4'de görüldüğü gibi x eksenini zamanı, y eksenini ölçeği, her bir x - y noktasındaki renkler ise dalgacık katsayılarının derecesini ifade eder. Küçük katsayılar koyu, büyük katsayılar ise açık renklerle gösterilmiştir (Arı, Özen, & Çolak, 2008). SDD renk

spektogramında zaman eksenini boyunca farklı renklerin oluşturduğu desenlere bakarak küçük veya büyük ölçekli olaylar görülebilir. Ölçek eksenini ise bu olayların periyodikliği hakkında bilgi vermektedir.

2.4.2 Ayrık dalgacık dönüşümü

SDD’de tüm ölçekler ve konumlar için dalgacık katsayıların hesaplanması büyük veri yığınlarına neden olmaktadır. Tüm ölçek ve konum değerleri için hesaplama yapmak yerine sadece belirli ölçek ve konum değerleri için dalgacık katsayılarının hesaplanması fikri Ayrık Dalgacık Dönüşümünün (ADD) (*ing.* Discrete Wavelet Transform - DWT) ortaya çıkmasını sağlamıştır. ADD’de ölçek ve konum değerleri ikinin kuvveti şeklinde belirlenir (Duran, 2013).

ADD’de dalgacık fonksiyonu Eşitlik (2.14)’deki biçimini alır. Bu eşitlikte m ve n değerleri birer tamsayıdır ve sırayla dalgacığın ölçek ile konumunu kontrol ederler. a_0 ölçek parametresidir ve birden büyük değerler alır. b_0 konum parametresidir ve sıfırdan büyük olmalıdır. (Nourani, Komasi, & Mano, 2009).

$$\Psi_{m,n(t)} = \frac{1}{\sqrt{a_0^m}} \Psi\left(\frac{1 - nb_0 a_0^m}{a_0^m}\right) \quad (2.14)$$

Parametreler için yaygın seçenek olarak $a_0=2$ ve $b_0=1$ değerlerinin alınması ile ölçek $a = 2^m$, konum $b = n2^m$ şeklini alır. Ölçek ve konumun ikili (*ing.* dyadic) logaritmik ölçeklendirilmesinin bu gücü ikili ızgara düzeni olarak bilinir. ADD’de ikili dalgacık fonksiyonu Eşitlik (2.15)’deki halini alır (Nourani, Komasi, & Mano, 2009).

$$\Psi_{m,n(t)} = 2^{-\frac{m}{2}} \Psi(2^{-m}t - n) \quad (2.15)$$


Kesikli bir $x(t)$ zaman serisi için ikili dalgacık dönüşümü Eşitlik (2.16) ile ifade edilir ve katsayıların elde edilmesini sağlar. Bu eşitlikte $DWT_{m,n}$ elde edilen katsayıları gösterir (Duran, 2013).

$$DWT_{m,n} = 2^{-\frac{m}{2}} \int_{-\infty}^{+\infty} x(t) \Psi(2^{-m}t - n) dt \quad (2.16)$$

SDD’de ölçek ve konum parametreleri reel sayı değerleri alırken ADD’de ölçek ve konum parametreleri tam sayı değerleri alır. ADD’yi kullanmak için Stephane Mallat’ın çoklu çözünürlük teorisi kullanılır (Mallat, 1989). Bu teknik ayrıştırma ve

yeniden yapılandırma olmak üzere iki ana adımdan oluşur. Ayırıştırma işlemi sonucunda zaman serisi bir tane yaklaşım bileşeni (A) ve kaçınıcı seviyeden ayırıştırma yapılmış ise o kadar detay (D) bileşenlerine ayrılır. Yaklaşım bileşeni yüksek ölçeğe sahip olmakla beraber verilerdeki alçak frekans değerlerini gösterir. Detay bileşenleri ise düşük ölçekli olup verilerdeki yüksek frekans değerlerini temsil eder.

Detay bileşenleri verilerdeki küçük detayları ve yorumlanabilen değerleri yakalar. Yaklaşım bileşeni ise verinin arka plan bilgisini gösterir (Nourani, Komasi, & Mano, 2009).



Şekil 2.5: (a) Dalgacık Ayırıştırma (b) Dalgacık Yeniden Yapılandırma (Aghajani, Kazemzadeh, & Ebrahimi, 2016)

Şekil 2.5'te görüldüğü gibi orijinal sinyali (S) ayırıştırmak için yüksek geçiş filtresi (H) ve düşük geçiş filtresi (L) olmak üzere iki tür filtre kullanılır. Dalgacık yeniden yapılandırma ile sinyalin parçalanmış bileşenleri herhangi bir bilgi kaybı olmadan tekrar orijinal sinyale birleştirilebilir. Yeniden oluşturulan orijinal sinyal Eşitlik (2.17) ile bulunabilir (Aghajani, Kazemzadeh, & Ebrahimi, 2016).

$$S = A_1 + D_1 = A_2 + D_1 + D_2 = A_3 + D_1 + D_2 + D_3 \quad (2.17)$$

Yaklaşım (A_1, A_2, A_3) ve detay (D_1, D_2, D_3) sinyalleri alt örnekleme ile elde edilir ve orijinal sinyalin sadece yarısı kadardır. Bu nedenle orijinal sinyali yeniden üretmeden önce yaklaşım ve detay katsayılarını yeniden oluşturmak gerekir. Ayırıştırma adımında sinyal yüksek ve düşük frekans bileşenine bölünür. Ardından, yüksek frekanslar korunur; düşük frekanslar tekrar yüksek ve düşük frekans bileşenine bölünür. Yüksek

frekanslara sinyal detayları, düşük frekanslara sinyalin yaklaşımı denir. Yeniden yapılanma işleminde eylemler tersine çevrilir. Morlet, Haar, Mexican Hat ve Meyer gibi dalgacık dönüşümünde ana dalgacık olarak kullanılacak birçok dalgacık temel fonksiyonu vardır. Bunların gruplarına dalgacık ailesi de denir. Bu aileler arasında Daubechies genellikle daha iyi sonuçlara sahiptir (Aghajani, Kazemzadeh, & Ebrahimi, 2016). Bu çalışmada ADD işleminde ana dalgacık olarak Daubechies dalgacığı kullanılmıştır.

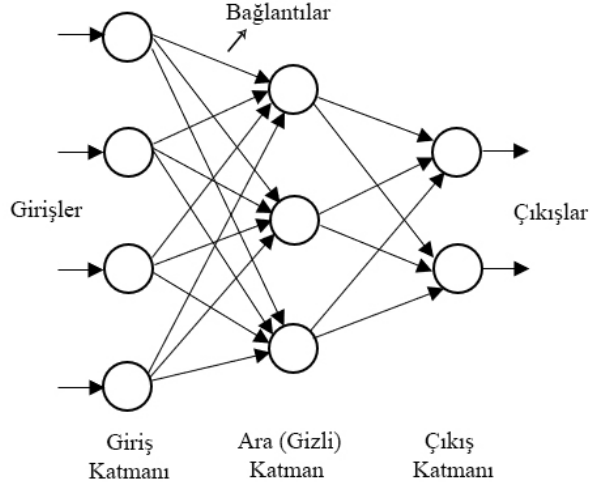
2.5 Yapay Sinir Ağları

Yapay sinir ağları insan beyninin yapısı ve çalışmasından esinlenerek geliştirilmiş, ağırlığı olan bağlantılarla birbirine bağlanmış, her birinin kendi belleği olan düğüm noktalarından oluşan paralel ve dağıtılmış bilgi saklama ve işleme yapılarıdır. YSA'lar için kısaca biyolojik sinir hücrelerinin yapısını ve çalışmasını taklit eden bilgisayar programlarıdır denilebilir. YSA'lar kendi kendine öğrenme yeteneğine sahiptirler. Öğrenmenin yanı sıra ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptirler. YSA'ların başlıca uygulama alanları sınıflandırma, tahmin ve modelleme olarak belirtilebilir (Elmas, 2016).

Öztemel (2016) ise YSA'ların kullanım alanlarını şu şekilde belirtmektedir. Sınıflandırma, örüntü tanıma, probabilistik fonksiyon kestirimleri, ilişkilendirme veya örüntü eşleştirme, sinyal filtreleme, zeki ve doğrusal olmayan kontrol, zaman serisi analizleri, veri sıkıştırma, doğrusal olmayan sinyal işleme, doğrusal olmayan sistem modelleme ve optimizasyon.

2.5.1 Yapay sinir ağlarının yapısı

Yapay sinir ağlarında bilgiler, ağı içindeki bağlantıların ağırlıklarında depolanır. Bir yapay ağda öğrenme işlemi, istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. YSA'da öğrenme işlemi düğümler arasındaki bağlantı ağırlıkların değiştirilmesi ile gerçekleştirilir. Öğrenme işlemi belirli kurallara göre yapılır ve bu konuda değişik yöntemler geliştirilmiştir. Şekil 2.6'de örnek bir yapay sinir ağı görülmektedir.




Şekil 2.6 : Yapay Sinir Ağı Örneği

YSA bir sürü yapay sinir hücresinin bir araya gelip bağlanması ile oluşur. Genel olarak sinir hücreleri üç katman halinde sıralanırlar (Öztemel, 2016).

- Giriş Katmanı : Dış çevreden verileri alan hücrelerin bulunduğu katmandır. Giriş katmanında genelde giriş parametresi kadar hücre bulunur.
- Ara (Gizli) Katman : Giriş katmanındaki hücrelerden gelen verilerin işlenerek çıkış katmanına yönlendirildiği katmandır. Ara katman yada gizli katman olarak adlandırılır. Ara katman bir tane olabileceği gibi birden fazla sayıda da olabilir. Ara katmandaki hücre sayısı değişik kriterlere göre yada istenilen sonuca ulaşana kadar deneme yanılma yöntemiyle bulunur.
- Çıkış Katmanı : Ağın çıkışının alındığı katmandır. Tek çıkışlı ağlarda tek hücreli, çok çıkışlı ağlarda birden fazla hücreli olabilir.

Şekil 2.7’de YSA’ları oluşturan yapay sinir hücrelerinden bir tanesinin yapısı görülmektedir. Girişler x_i ile gösterilmiştir. Girişler çevreden aldıkları bilgileri sinir hücresine getirir. Girişler dış dünyadan veya kendinden önceki sinirden gelebilir. Girişlerin her biri belirli bir ağırlık (w) değeri ile çarpılır. Ağırlıklar girişlerin sinir hücresi üzerindeki etkisini belirleyen uygun katsayılarıdır. Bir ağırlığın büyüklüğü ilgili girişin sinir ağına güçlü bağlanması ve önemli olması anlamına gelir. Ağırlıklarla çarpılan giriş değerleri ve eşik değeri (θ) toplanır. Bazı durumlarda toplama işlevi yerine enaz, ençok, çoğunluk veya normalleştirme algoritması gibi işlevler kullanılabilir. Elde edilen bu toplam (v_i) sonucu oluşturmak için bir etkinlik işlevinden


geçirildikten sonra y_i çıkışı elde edilir. Eşitlik (2.18)'te yapay sinir hücresinin çıkış sinyali verilmiştir (Elmas, 2016).



Şekil 2.7: Bir Yapay Sinir Hücresinin Yapısı (Elmas, 2016)

$$y_i = f \left(\sum_{j=1}^n w_{ij} x_i + \theta_j \right) \quad (2.18)$$

Yapay sinir hücresindeki etkinlik işlevi kendisine gelen girdiyi işleyerek hücrenin üreteceği çıktıyı belirler. Birçok etkinlik işlevi kullanılmaktadır. Etkinlik işlevleri doğrusal veya doğrusal olmayan biçimlerde olabilir. Değişik etkinlik işlevleri Şekil 2.8'de görülmektedir. Step ve sign fonksiyonları genellikle örüntü tanıma ve sınıflandırmada, sigmoid fonksiyonu geri yayımlı (*ing.* back propagation) ağlarda kullanılmaktadır. Doğrusal aktivasyon fonksiyonu ise genellikle lineer yakınlılaşmada kullanılmakta ve çıkışı ağırlandırılmış nöron girişleriyle denk tutmaktadır (Nabiyev, 2016).



Şekil 2.8 : Değişik Etkinlik İşlevleri (Nabiyev, 2016)

Çizelge 2.2’de etkinlik işlevlerinin adı, matematiksel formülleri ve açıklamalarına yer verilmiştir (Öztemel, 2016).

Çizelge 2.2 : Etkinlik Fonksiyonları ve Açıklamaları

İsim	Fonksiyon	Açıklama
Linear	$f(net) = net$	Doğrusal fonksiyon. Girdi olduğu gibi çıktıya aktarılır.
Sign	$f(net) = \begin{cases} +1, net > t \\ -1, net < t \end{cases}$	İşaret Fonksiyonu. Gelen girdi bir eşik değerinden büyük ise çıkış +1, küçük ise çıkış -1 olur.
Step	$f(net) = \begin{cases} 1, net \geq t \\ 0, net < t \end{cases}$	Adım fonksiyonu.
Sigmoid	$f(net) = \frac{1}{1 + e^{-net}}$	Tek kutuplu eğrisel fonksiyon.
Tansig	$f(net) = \frac{e^{net} + e^{-net}}{e^{net} - e^{-net}}$	Hiperbolik tanjant fonksiyonu.

YSA’ları hücreler arasındaki bağlantı yönlerine veya öğrenme kurallarına göre sınıflandırmak mümkündür. Hücreler arasındaki bağlantı yönlerine göre;


- İleri Beslemeli (*ing.* Feedforward)
- Geri Beslemeli (*ing.* Feedback veya Recurrent)

Olmak üzere iki temel ağ mimarisi vardır. İleri beslemeli ağlarda ilk katmandaki girişlere verilen bilgi ağ içerisinde ileriye doğru yayılır. Her katmandaki düğümlere sadece ön katmandaki düğümlerden girişlere izin verilir. Bir düğüm kendisinden sonraki herhangi bir katmana bağlanabilirken kendisine asla bağlanamaz. Son katmandaki işaretler ağın çıkışıdır. Geri beslemeli veya tekrarlanan ağlarda ise en azından bir düğümün geriye doğru bir dönüş bağlantısı vardır. Tekrarlanan ağlar ise tamamen veya parçalı olarak geri besleme yollarına sahiptirler (Elmas, 2016).


Öğrenme yöntemlerine göre yapılan sınıflandırmada;

- Danışmanlı (*ing.* Supervised)
- Danışmansız (*ing.* Unsupervised)

Olmak üzere temelde iki tür ağ mimarisi vardır. Danışmanlı öğrenmede bir öğretmene ihtiyaç vardır ve sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi sinir ağına giriş ve istenilen çıkış değerlerini vererek gerçekleştirilir. Bu bilgiler eğitim kümesi olarak adlandırılır (Elmas, 2016). Sistemin görevi kendisine verilen girdiler ile çıktı arasında belirli istatistiksel kriterlere göre minimum hata olacak şekilde bir haritalama yapmaktır. Böylece girdiler ile çıktı arasındaki ilişki modellenmiş olur. Eğitim işlemi neticesinde öğrenme tamamlanmış olur, ağırlıklar sabitlenir ve bir daha değiştirilmez. Eğitimden sonra sinir ağına daha önce hiç görmediği test verileri verilir ve çıktılar elde edilir. Şekil 2.9 (a)'da danışmanlı öğrenme modeli şematik olarak gösterilmiştir.



(a)



(b)

Şekil 2.9 : (a) Danışmanlı Öğrenme (b) Danışmansız Öğrenme (Elmas, 2016)

Danışmansız öğrenme modelini kullanan sinir ağı modellerinde sisteme yardımcı olan herhangi bir öğretmen yoktur. Sinir ağına sadece girdi değerleri verilir ve sistemin bu girdi değerlerinin özelliklerine göre kendi kendine öğrenerek ağırlıkları ayarlaması beklenir. Bu strateji daha çok sınıflandırma gibi problemlerde kullanılır. Çıktılar elde edildikten sonra ne anlama geldiklerini belirten etiketlemenin kullanıcı tarafından

yapılması gerekir (Öztemel, 2016). Şekil 2.9 (b)'de danışmansız öğrenme modeli şematik olarak gösterilmiştir.

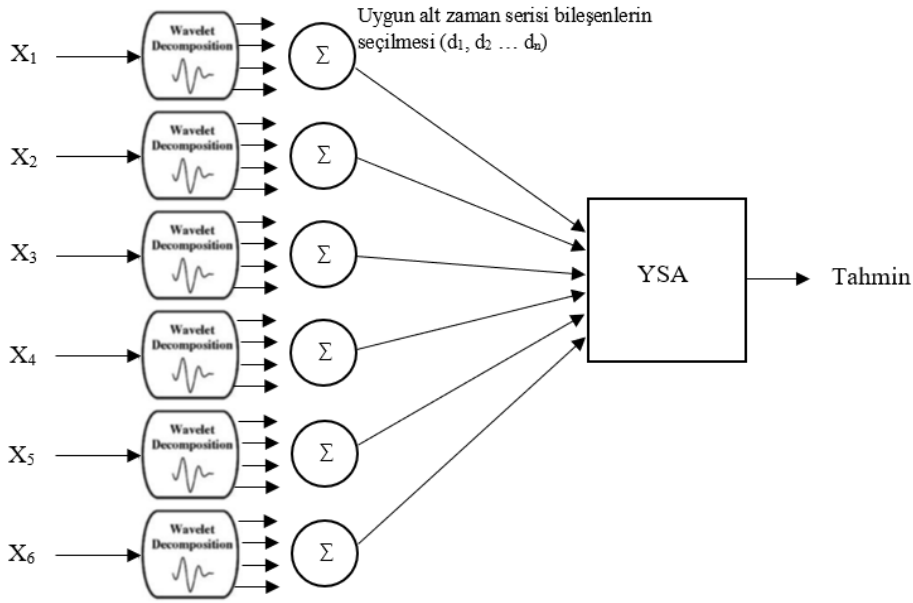
2.6 Dalgacık YSA (D-YSA) Modeli

Tahmin çalışmasında kullanılan YSA modellerinde giriş verilerine ön işlem uygulanmasının başarımı arttırdığı literatürde bir çok çalışmada görülmektedir (Partal, 2016; Hussain & AlAlili, 2017; Monjoly, André, Calif, & Soubdhan, 2017). Bu bağlamda çalışmanın son bölümünde dalgacık dönüşümü ve YSA'nın birlikte kullanıldığı D-YSA modelleri ile rüzgar şiddeti ve güneş radyasyonu için kısa süreli tahmin çalışması yapılmıştır. D-YSA modelinde YSA'da giriş olarak kullanılan meteorolojik verilere ADD ile ayrıştırma işlemi uygulanarak veriler alt zaman bileşenlerine ayrılmıştır.

D-YSA modellerinde ayrıştırma işleminin kaçınıcı seviyeye kadar yapılacağı konusunda literatürde farklı çalışmalara rastlanılmıştır. Nourani ve diğ. (2009) ile Nury ve diğ. (2017) N zaman serisinin uzunluğu olmak üzere $int [\log(N)]$ ayrışma seviyesini belirlemişlerdir. Partal ve diğ. (2008) yaptıkları çalışmada herhangi bir formüle bağlı kalmaksızın 11 adet detay bileşeni, Terzi ve Barak (2015) da yine herhangi bir formüle bağlı kalmadan 12 adet detay bileşeni kullanmıştır.

Ayrıştırma işleminde kullanılacak ana dalgacık konusunda Nourani ve diğ. (2009) Haar, Daubechies-2 (Db2), Sym3, Coif1 dalgacıklarını kullanmışlardır. Nury ve diğ. (2017) ise Daubechies-5 (Db5) ana dalgacığını kullanmışlardır. Ramesh ve Arulmozhivarman (2013) yaptıkları çalışmada rüzgar şiddeti tahmini için geliştirdikleri hibrit D-YSA modelinde Daubechies-3 (Db3) dalgacığı kullanmıştır.

Ayrıştırma işleminden sonra önemli bir konu da hangi alt bileşenlerinin YSA'nın girişi için seçileceğine karar verilmesidir. Literatürde bu konuda farklı uygulamalara rastlanılmaktadır. Bazı çalışmalarda alt bileşenlerin tamamı YSA'da giriş olarak kullanılırken bazı çalışmalarda ise alt bileşenlerin bir kısmı seçilerek kullanılmaktadır (Kahya, & Cıgızoğlu, 2008; Terzi & Barak, 2015). Genel olarak seçim işlemi için daha etkili olabilecek bileşenlerin seçilmesine dikkat edilmektedir. Şekil 2.10'da bu çalışmada kullanılan ve hibrit model olan D-YSA'nın blok şeması görülmektedir.



Şekil 2.10 : Dalgacık YSA Modelinin Blok Şeması (Partal, 2007)

YSA girişinde kullanılan veriler ADD ile önce alt zaman bileşenlerine ayrılmaktadırlar. Her giriş verisi için elde edilen alt zaman bileşenleri ile tahmin edilmesi istenen çıkış verisi arasındaki korelasyon değerlerine bakılmaktadır. Yüksek ve pozitif korelasyona sahip alt bileşenler seçilerek, düşük veya negatif korelasyona sahip alt bileşenler ayrılmaktadır. Yüksek korelasyona sahip pozitif alt zaman bileşenleri toplanarak giriş için yeni zaman serisi elde edilmektedir. Alt bileşenlerin YSA girişlerinde ayrı olarak kullanılması yerine toplanarak kullanılmasının amacı modellerin karmaşıklaşmasını önlemektir. Yüksek ve negatif korelasyona sahip alt bileşenler varsa onlar da ayrı olarak veya kendi aralarında toplanarak giriş kısmında kullanılmaktadır. Alt zaman bileşenlerinin toplanması ile elde edilen yeni zaman serileri ile tahmin edilmesi istenilen hedef veri arasındaki korelasyonun orijinal giriş verisi ile olan korelasyona göre genelde daha yüksek çıktığı görülmektedir (Partal, 2007).

2.7 Model Performanslarının Değerlendirilmesinde Kullanılan Yöntemler

Çalışma kapsamında geliştirilen modellerin başarımını değerlendirmek üzere istatistiksel değerlendirme yöntemlerinden Korelasyon Katsayısı (R), Determinasyon Katsayısı (R^2), Kök Ortalama Karesel Hata (*ing.* Root Mean Square Error - RMSE), Normalize Kök Ortalama Karesel Hata (*ing.* Normalized Root Mean Square Error -

nRMSE), Ortalama Mutlak Yüzde Hata (*ing.* Mean Absolute Percentage Error - MAPE) metotları kullanılmıştır. Eşitlik (2.19)'da R'in hesaplanmasında kullanılan denklem görülmektedir (Zang, ve diğerleri, 2019). Eşitlik (2.20)'de R²'nin hesaplanmasında kullanılan denklem görülmektedir (Nourani, Komasi, & Mano, 2009). Eşitlik (2.21)'da RMSE değerlerinin hesaplanmasında kullanılan denklem görülmektedir (Çelik, Teke, & Yıldırım, 2016). Eşitlik (2.22)'de nRMSE değerinin hesaplanmasında kullanılan denklem görülmektedir (Monjoly, André, Calif, & Soubdhan, 2017; Sun, Wang, Zhang, & Zheng, 2018). Eşitlik (2.23)'de MAPE değerlerinin hesaplanmasında kullanılan denklem görülmektedir (Catalão, Pousinho, & Mendes, 2011; Aghajani, Kazemzadeh, & Ebrahimi, 2016).

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)(y_i - \bar{y}_i)}{\sqrt{[\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2] \cdot [\sum_{i=1}^n (y_i - \bar{y}_i)^2]}} \quad (2.19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2} \quad (2.20)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2.21)$$

$$nRMSE = \frac{RMSE}{\bar{y}_i} \quad (2.22)$$

$$MAPE(\%) = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\bar{y}_i} \right|}{n} \times 100 \quad (2.23)$$

- n : Veri adedi
 y_i : Gözlemlenmiş değer
 \bar{y}_i : Gözlemlenmiş değerlerin ortalaması
 \hat{y}_i : Tahmin edilen değer
 $\bar{\hat{y}}_i$: Tahmin edilen değerlerin ortalaması

R'in -1 ile +1 arasında, R²'nin ise 0 ile 1 arasında bir değerde olması beklenir. R'in -1 veya +1'e yakın olduğu, R²'nin ise 1'e yakın olduğu modeller daha başarılıdır. R ve R²'nin sıfıra yakın olduğu modeller başarısızdır. Başarım ölçümünde RMSE, nRMSE ve MAPE değerlendirmesinde ise değerler ne kadar düşük çıkarsa modeller o kadar

daha başarılı sayılır (Nourani, Komasi, & Mano, 2009). En iyi RMSE veya nRMSE değeri sıfır veya buna yakın değerler olacaktır (Ghorbani, Khatibi, FazeliFard, Naghipour, & Makarynsky, 2016).

RMSE, hatanın ortalama büyüklüğünü ölçen karesel bir skorlamadır. Hataların ortalamaları alınmadan önce kareleri alındığından, RMSE büyük hatalara nispeten daha yüksek ağırlık verir (Li & Shi, 2010). RMSE, önemli tahmin hatalarına karşı daha hassastır ve dolayısıyla küçük hataların büyük hatalardan daha fazla tolere edilebildiği uygulamalar için uygundur (Benali, Notton, Fouilloy, Voyant, & Dizene, 2019). Bu çalışmada mevsimleri temsilen seçilen dört farklı aya ait veri setleri ile çalışıldığından değerlendirmenin daha sağlıklı yapılabilmesi için RMSE her ay için gözlemlenmiş değerlerin ortalamasına bölünerek nRMSE elde edilmiştir. nRMSE değeri ne kadar düşük çıkarsa değerlendirilen model o kadar daha başarılı sayılır (Sun, Wang, Zhang, & Zheng, 2018).

MAPE tahmin değerlerine ait mutlak hata yüzdelerinin ortalamasını göstermektedir. MAPE değerlendirmesinde %10'nun altındaki değerler modellerin çok iyi olduğunu , %10 ile %20 arasındaki değerler iyi, %20 ile %50 arasındaki değerlerin kabul edilebilir ve %50'nin üstündeki değerler ise modellerin yanlış ve hatalı olabileceğini işaret etmektedir (Alkan, Öztürk, & Tosun, 2018).

3. ANALİZ VE UYGULAMA

3.1 İstatiksel Analiz ve Modelleme

Bu aşamada tez çalışmasında kullanılacak olan veriler üzerinde SPSS programı kullanılarak birtakım istatistiksel analizler yapılmıştır. Çizelge 3.1’de tüm verilere ait veri adedi (N), ortalamalar, standart sapmalar ve kayıp veri sayısını ile oranları görülmektedir. Rüzgar yönü verilerinde %21,7 oranında kayıp bulunduğu, diğer verilerdeki kayıp oranının çok düşük olduğu görülmektedir. Rüzgar şiddeti verilerinde hiç kayıp olmadığı görülmüştür.

Çizelge 3.1 : 2016 Yılı, Eskice Mevki Kayıp Veri Analizi

	N	Ortalama	Std. Sapma	Kayıp Veri	
				Sayısı	Oran (%)
Rüzgar Şiddeti (m/s)	52536	3,30	3,091	0	0,0
Güneş Radyasyonu (W/m ²)	52534	152,00	237,040	2	0,0
Sıcaklık 2m (°C)	52375	15,03	8,138	161	0,3
Toprak Üstü 5cm Sıcaklık (°C)	52535	14,76	8,657	1	0,0
UV Radyasyon İndis	52530	0,63	1,224	6	0,0
Rüzgar Yönü	41158	4,90	5,186	11378	21,7

Eskice Mevki istasyonuna ait 2016 yılı rüzgar şiddetinin zamansal değişimi aylık ortalamalar şeklinde Şekil 3.1’de gösterilmiştir. Yıllık bazda değerlendirildiğinde ortalama rüzgar şiddetinin mevsimlere göre farklılık gösterdiği, Ağustos ayında en yüksek şiddette estiği vurgulanabilir. Rüzgar şiddeti verileri incelendiğinde 24 Mart ile 1 Haziran arasındaki kayıtlar 0 m/s olarak görülmektedir. Bu kayıtlar Mart ayının son haftası, Nisan ve Mayıs aylarında bir sorun oluştuğunu ve rüzgar şiddeti ölçümünün yapılamadığını göstermektedir.



Şekil 3.1 : 2016 Yılı, Eskice Mevki, Aylık Ortalama Rüzgar Şiddeti (m/s) Grafıği

Eskice Mevki istasyonuna ait 2016 yılı güneş radyasyonunun zamansal deęişimi aylık ortalamalar şeklinde Şekil 3.2’de gösterilmiştir. Yıllık bazda deęerlendirildiğinde güneş radyasyonunun kış aylarında düşük seviyede olduđu, ilkbahar ile birlikte yükseldiđi, yaz aylarında maksimum seviyeye ulaştıđı, sonbahar ve kışa dođru düştüđü vurgulanabilir.



Şekil 3.2 : 2016 Yılı, Eskice Mevki, Aylık Ortalama Güneş Radyasyonu (W/m²) Grafıği

Bu çalışmanın analiz ve uygulama aşamasında Eskice Mevki istasyonuna ait veriler mevsimleri temsilen dört gruba ayrılmıştır. Her mevsim için başlangıç ayı seçilmiştir. İlkbahar mevsimini temsilen Mart ayı, yaz mevsimini temsilen Haziran ayı, sonbahar mevsimini temsilen Eylül ayı, kış mevsimini temsilen Aralık ayı verileri kullanılarak mevsimsel analiz gerçekleştirilmiştir.

3.1.1 Mevsimlere göre istatistiksel analiz

Çalışmada kullanılan ve mevsimleri temsilen seçilen aylar bazında birtakım istatistiksel analizler yapılmıştır. Çizelge 3.2’de aylar bazında kayıp veri analizi görülmektedir. Buna göre ilkbahar mevsimini temsilen seçilen 2016 yılı Mart ayında sadece Rüzgar Yönü verisinde %28.2 oranında kayıp veri söz konudur. Bu oran

oldukça yüksektir. Diğerlerinde kayıp veri söz konusu değildir. Yaz mevsimini temsilen seçilen 2016 yılı Haziran ayında Rüzgar Yönü verisinde %2.5, Sıcaklık 2m verisinde %3.7 oranında kayıp veri söz konudur. Sonbahar mevsimini temsilen seçilen 2016 yılı Eylül ayında sadece Rüzgar Yönü verisinde %2.6 kayıp veri bulunmaktadır. Kış mevsimini temsilen seçilen 2016 yılı Aralık ayında toplam Rüzgar Yönü verisinde %3.2, UV Radyasyon İndis verisinde %0.1 oranında kayıp veri söz konudur.

Çizelge 3.2 : Aylar Bazında Kayıp Veri Analizi

	Mart Ayı			Haziran Ayı			Eylül Ayı			Aralık Ayı		
	Top. Veri	Kayıp Veri		Top. Veri	Kayıp Veri		Top. Veri	Kayıp Veri		Top. Veri	Kayıp Veri	
		Sayı	Oran (%)		Sayı	Oran (%)		Sayı	Oran (%)		Sayı	Oran (%)
Rüzgar Şiddeti	4457	0	0	4320	0	0	4320	0	0	4309	0	0
Güneş Radyasyonu	4457	0	0	4320	0	0	4320	0	0	4307	2	0
Sıcaklık 2m	4457	0	0	4162	158	3,7	4320	0	0	4309	0	0
UV Radyasyon İndis	4457	0	0	4320	0	0	4320	0	0	4303	6	0,1
Rüzgar Yönü	3201	1256	28,2	4213	107	2,5	4206	114	2,6	4172	137	3,2
Toprak Üstü 5cm Sıcaklık	4457	0	0	4320	0	0	4320	0	0	4309	0	0

Çizelge 3.3 ve Çizelge 3.4’te sırayla rüzgar şiddeti ve güneş radyasyonu verilerine ait mevsimleri temsilen seçilen aylar bazında tanımlayıcı istatistiksel bilgiler verilmiştir. Seçilen tüm aylarda güneş radyasyonu ve rüzgar şiddetinde pozitif çarpıklık olduğu görülmektedir. Dört ayın içerisinde aylık ortalamalara göre rüzgar şiddeti 4.621 m/s ile en yüksek Aralık ayında görülürken, en düşük olarak 2.196 m/s ortalama ile Mart ayında görülmüştür.

Çizelge 3.3 : Rüzgar Şiddeti (m/s) Verileri İçin Tanımlayıcı İstatistik


Aylar	Veri	Aralık	Min.	Mak.	Ort.	Std.Sapma	Varyans	Çarpıklık	Basıklık
Mart	4457	14,31	0	14,31	2,196	2,959	8,756	1,355	1,149
Haziran	4320	11,61	0	11,61	3,994	2,31	5,338	0,314	-0,589
Eylül	4320	10,28	0	10,28	3,890	2,187	4,790	0,281	-0,693
Aralık	4309	17,89	0	17,89	4,621	3,784	14,32	1,02	0,556

Güneş radyasyonu aylık ortalamalara göre dört ayın içerisinde en yüksek değer Haziran ayında (267.95 W/m^2) görülürken, en düşük değer Aralık ayında (45.47 W/m^2) görülmüştür.


Çizelge 3.4 : Güneş Radyasyonu (W/m^2) Verileri İçin Tanımlayıcı İstatistik

Aylar	Veri	Aralık	Min.	Mak.	Ort.	Std.Sapma	Varians	Çarpıklık	Basıklık
Mart	4457	903	0	903	123,4	195,293	38139,376	1,669	1,797
Haziran	4320	1065	0	1065	267,95	309,436	95750,339	0,738	-0,985
Eylül	4320	861	0	861	171,38	540,382	57783,614	1,176	-0,44
Aralık	4307	470	0	470	45,47	87,796	7708,159	2,215	4,124


Rüzgar şiddeti verisine ait aylar bazında zamansal değişim grafikleri Şekil 3.3'te görülmektedir. Mart Ayında rüzgar şiddetinin ay boyunca dalgalı bir seyir izlediği, inceleme ilk yarısında 12 m/s'ye kadar çıktığı, ay ortasında 14,31 m/s ile maksimum değerine ulaştığı, inceleme son çeyreğinde ölçüm alınmadığı ve bu nedenle değerlerin 0 m/s çıktığı vurgulanabilir. Haziran Ayı boyunca 4-10 m/s aralığında dalgalanarak dalgalı ve yüksek hızlı bir seyir izlediği, inceleme ortasında genel olarak 6 m/s hız civarında seyrettiği ancak kısa bir süreliğine 12 m/s'ye kadar çıkarak maksimum değerine ulaştığı, inceleme son çeyreğinde önce yükseldiği, sonrasında ise kademeli olarak azalarak 6 m/s seviyesine çekildiği vurgulanabilir. Eylül Ayı boyunca dalgalı bir seyir izlediği, incelenen ay boyunca 4 kez tekrar eden bir yükselme ve devamında alçalmanın takip ettiği bir periyodiklik izlendiği vurgulanabilir. Aralık Ayı boyunca dalgalı bir seyir izlediği, haftalık periyotlarla önce yükselip sonra azaldığı, inceleme ayının son 2 gününde ay ortalamasının oldukça üstünde 16 m/s'ye çıkarak zirve yaptığı söylenebilir.



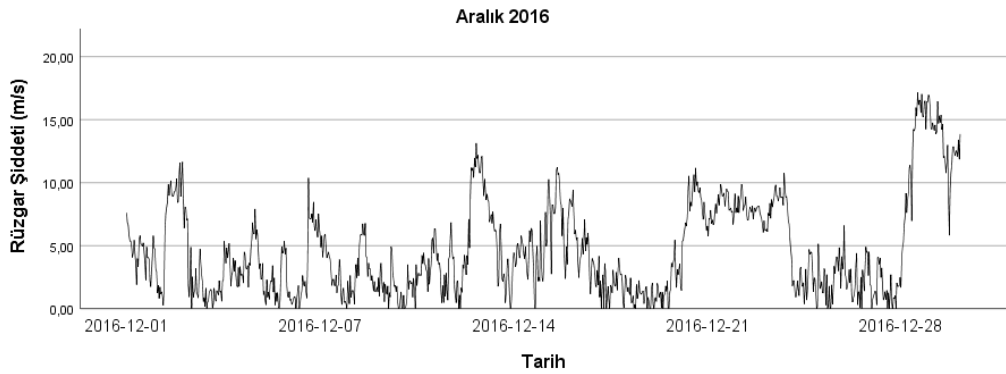
(a)



(b)



(c)




(d)


Şekil 3.3 : Rüzgar Şiddeti (a) Mart Ayı (b) Haziran Ayı (c) Eylül Ayı (d) Aralık Ayı, Zamansal Değişim Grafikleri

Güneş Radyasyonu verisine ait aylar bazında zamansal değişim grafikleri Şekil 3.4'te görülmektedir. Mart ayında radyasyon verilerinin inceleme ilk yarısında 700 W/m^2 kadar çıktığı, söz konusu ayın ortasında ise 200 W/m^2 'nin altına düştüğü, son yarısında ise 800 W/m^2 'ye kadar çıkarak daha yüksek değerler görüldüğü vurgulanabilir. Haziran ayında güneş radyasyonunun inceleme ilk yarısında 1000 W/m^2 'nin üzerine çıksa da genel olarak ay boyunca $800\text{-}900 \text{ W/m}^2$ civarında seyrettiği

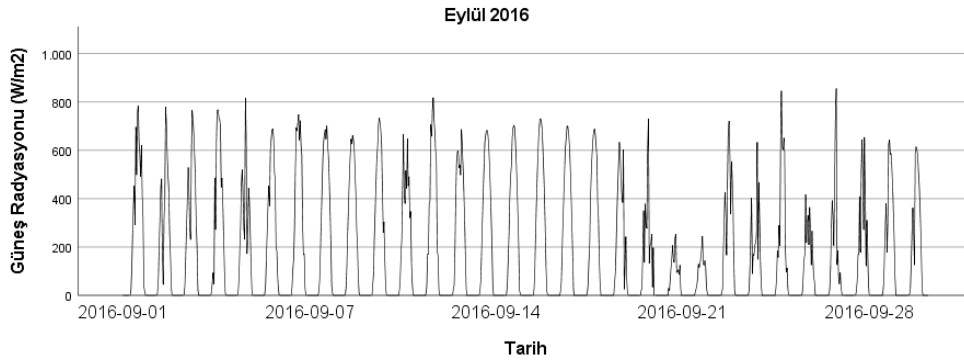
görülmüştür. Eylül Ayı boyunca 600 – 800 W/m² arasında değişen bir seyir izleyen radyasyon verilerinin inceleme son yarısında 250 W/m² ye kadar düşerek devamında tekrar yükseldiği gözlenmektedir. Aralık ayında ise radyasyon verilerinin yaz ve son bahar aylarına göre azalarak 200-400 W/m² bandında seyrettiği, bazı günlerde 50-120 W/m² bandına kadar indiği vurgulanabilir.



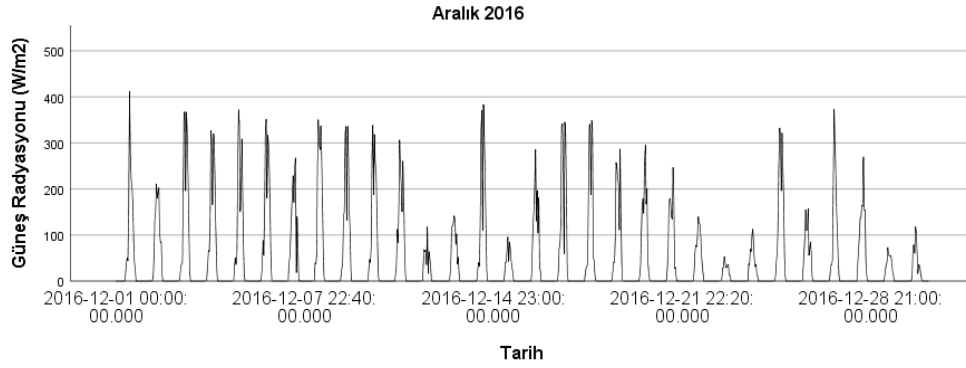
(a)



(b)



(c)



(d)

Şekil 3.4 : Güneş Radyasyonu (a) Mart Ayı (b) Haziran Ayı (c) Eylül Ayı (d) Aralık Ayı, Zamansal Değişim Grafikleri

Rüzgar şiddeti ve güneş radyasyonu ile diğer veriler arasındaki ilişkiyi anlayabilmek için Pearson korelasyon katsayıları Çizelge A.1 - Çizelge A.4'te aylar bazında görülmektedir. Korelasyon katsayısı (R) +1 ile -1 arasında değişmektedir. Artı değerler veriler arasında pozitif bir ilişkiye, eksi değerler ise veriler arasında negatif ilişkiye işaret etmektedir. R değeri +1 veya -1'e yaklaştıkça veriler arasındaki ilişkinin derecesi pozitif yada negatif yönde artmaktadır. Sıfıra yakın R değerleri veriler arasında ilişkinin zayıf veya hiç olmadığı anlamına gelir.

Mart ayına ait rüzgar şiddeti ve güneş radyasyonu verilerinin diğer verilerle arasındaki korelasyon katsayılarına bakıldığında rüzgar şiddetinin rüzgar yönü verisi ile negatif en yüksek korelasyona sahip olduğu görülmektedir. Pozitif olarak sırayla toprak üstü 5cm sıcaklık ve sıcaklık 2m verileriyle anlamlı ($\alpha < 0.01$) korelasyon görülmekte birlikte bu değerler düşüktür. Rüzgar şiddeti ile güneş radyasyonu ve UV radyasyon indisi arasındaki korelasyon anlamlı değildir ($\alpha > 0.05$). Mart ayında güneş radyasyonunun ise sırayla UV radyasyon indisi, toprak üstü 5cm sıcaklık ve sıcaklık 2m verileriyle anlamlı ($\alpha < 0.01$) pozitif en yüksek korelasyona sahip olduğu görülmektedir.

Haziran ayı için rüzgar şiddetinin toprak üstü 5cm sıcaklık verisi ile anlamlı ($\alpha < 0.01$) pozitif en yüksek korelasyona sahip olduğu görülmektedir. Bunun dışında pozitif yönde büyüklük sırasıyla güneş radyasyonu, sıcaklık 2m ve UV radyasyon indisi ile rüzgar şiddeti arasında anlamlı ($\alpha < 0.01$) korelasyon görülmüştür. Rüzgar şiddeti ve rüzgar yönü arasında ise negatif yönlü anlamlı ($\alpha < 0.01$) korelasyon mevcuttur. Haziran ayında güneş radyasyonunun ise büyüklük sırasıyla UV radyasyon indisi, toprak üstü 5cm sıcaklık, sıcaklık 2m ve rüzgar şiddeti verileriyle anlamlı ($\alpha < 0.01$)

olarak pozitif korelasyona sahip olduğu görülmektedir. Haziran ayı için güneş radyasyonu ile rüzgar yönü arasındaki korelasyon ilişkisi anlamlı değildir ($\alpha > 0.05$).

Eylül ayı için rüzgar şiddetinin güneş radyasyonu verisi ile anlamlı ($\alpha < 0.01$) pozitif en yüksek korelasyona sahip olduğu görülmektedir. Bunun dışında pozitif yönde büyüklük sırasıyla UV radyasyon indis, sıcaklık 2m, toprak üstü 5cm sıcaklık değerleri ile arasında anlamlı ($\alpha < 0.01$) korelasyon görülmüştür. Rüzgar şiddeti ve rüzgar yönü arasında ise negatif yönlü anlamlı ($\alpha < 0.01$) korelasyon mevcuttur. Eylül ayında güneş radyasyonunun ise büyüklük sırayla UV radyasyon indis, sıcaklık 2m, rüzgar şiddeti, toprak üstü 5cm sıcaklık verileriyle anlamlı ($\alpha < 0.01$) olarak pozitif korelasyona sahip olduğu görülmektedir. Eylül ayı için güneş radyasyonu ile rüzgar yönü arasındaki korelasyon ilişkisi anlamlı değildir ($\alpha > 0.05$).

Aralık ayı için rüzgar şiddetinin rüzgar yönü verisi ve sonrasında UV radyasyon indis verisiyle anlamlı ($\alpha < 0.01$) olarak negatif en yüksek korelasyona sahip olduğu görülmektedir. Bunun dışında pozitif yönde büyüklük sırasıyla toprak üstü 5cm sıcaklık ve sıcaklık 2m ile rüzgar şiddeti arasında anlamlı ($\alpha < 0.01$) korelasyon görülmüştür. Rüzgar şiddeti ve güneş radyasyonu arasında ise Aralık ayında anlamlı korelasyon ilişkisi bulunmamaktadır ($\alpha > 0.05$). Güneş radyasyonunun ise büyüklük sırayla UV radyasyon indis, toprak üstü 5cm sıcaklık, sıcaklık 2m ve rüzgar yönü verileriyle anlamlı ($\alpha < 0.01$) olarak pozitif korelasyona sahip olduğu görülmektedir.

Rüzgar şiddeti ve güneş radyasyonu verilerine ait frekans dağılımını gösteren histogram grafiklerine bakıldığında dört mevsimi temsilen seçilen Mart, Haziran, Eylül ve Aralık aylarında her iki veri grubunda da pozitif çarpıklık görülmektedir (Şekil B.1 - Şekil B.4)

Çeyrek dağılımlarını ve aykırı verileri gösteren boxplot grafikleri Şekil B.5 - Şekil B.8'de görülmektedir. Mart ayı için rüzgar şiddetinde Q1 (birinci çeyrek) 0 m/s , Q2 (ikinci çeyrek) 0.5 m/s ve Q3'ün (üçüncü çeyrek) 4 m/s gibi olduğu vurgulanabilir. Ayrıca aykırı değerlerin varlığı da görülmektedir. Mart ayı için 9.8 m/s'nin üstündeki rüzgar şiddeti ölçüm değerleri aykırı değer olarak hesaplanmıştır. Aykırı değerlerin kayıt sıra numaraları grafikte görülmektedir. Mart ayı güneş radyasyonuna ait boxplot grafiği incelendiğinde Q1 ve Q2 0 W/m², Q3'ün ise 190 W/m² civarında olduğu, Mart ayı için tahmini olarak 450 W/m²'nin üstündeki güneş radyasyonu değerlerinin aykırı veri olarak hesaplandığı görülmektedir.

Haziran ayı rüzgar şiddeti Q1 2.1 m/s, Q2 4 m/s ve Q3 5.5 m/s civarında olduğu görülmektedir. Rüzgar şiddeti verilerinde az da olsa aykırı değerlerin varlığı görülmektedir. Haziran ayı için 9,9 m/s'nin üstündeki rüzgar şiddeti ölçüm değerleri aykırı değer olarak hesaplanmıştır. Haziran ayı için güneş radyasyonu verilerinde Q1 0 W/m² , Q2 110 W/m² , Q3'ün ise 540 W/m² civarında olduğu söylenebilir. Haziran ayında güneş radyasyonunda aykırı değerler görülmemiştir.

Eylül ayı rüzgar şiddeti Q1 2.2 m/s , Q2 3.5 m/s ve Q3 5.3 m/s civarında olduğu görülmektedir. Rüzgar şiddeti verilerinde az da olsa aykırı değerlerin varlığı görülmektedir. Eylül ayı için 9,8 m/s'nin üstündeki rüzgar şiddeti ölçüm değerleri aykırı değer olarak hesaplanmıştır. Eylül ayı için güneş radyasyonu verilerinde Q1 0 W/m² , Q2 0 W/m² , Q3'ün ise 300 W/m² civarında olduğu görülmektedir. Eylül ayında 780 W/m²'nin üstündeki güneş radyasyonu değerlerinin aykırı değerler olarak hesaplandığı görülmektedir.

Aralık ayı rüzgar şiddeti Q1 2.0 m/s , Q2 4 m/s ve Q3 7 m/s civarında olduğu görülmektedir. Rüzgar şiddeti verilerinde aykırı değerlerin varlığı görülmektedir. Aralık ayı için 14.5 m/s'nin üstündeki rüzgar şiddeti ölçüm değerleri aykırı değer olarak hesaplanmıştır. Aralık ayı için güneş radyasyonu verilerinde Q1 0 W/m² , Q2 0 W/m² , Q3 ise 40 W/m² civarında olduğu görülmektedir. Aralık ayında güneş radyasyonunda fazla sayıda aykırı değerler görülmüştür. 110 W/m²'nin üstündeki güneş radyasyonu değerleri aykırı değer olarak hesaplanmıştır.

3.1.2 Çoklu lineer regresyon ile tahmin modelleme

Çalışmanın bu aşamasında istatistiksel yöntemlerden çoklu lineer regresyon yöntemi kullanılarak mevsimleri temsilen seçilen aylar bazında rüzgar şiddeti ve güneş radyasyonu için tahmin çalışması yapılmıştır. Tahmin çalışmasında meteorolojik veriler kullanılarak ileriye yönelik 24 saat sonrası için 10 dakikalık adımlarla rüzgar şiddeti ve güneş radyasyonu tahmin edilmeye çalışılmıştır. SPSS programı kullanılarak adimsal (*ing. stepwise*) yöntem ile çoklu lineer regresyon modeli uygulanmıştır.

Kademeli veya adimsal olarak adlandırılan regresyon yöntemi, en iyi alt küme modellerinin seçimi için sağlam bir yöntem olarak uygulanır ve kalan karelerin toplamı üzerinde en büyük etkiye sahip olan değişkenlerin eklenmesine veya silinmesine dayanır (Ghorbani, Khatibi, FazeliFard, Naghipour, & Makarynsky, 2016).

Adımsal yöntemde bağımsız değişkenler bağımlı değişkenle aralarındaki ilişkiye göre en güçlü ilişkiye sahip olandan başlanarak sırayla modele dahil edilir. Bağımlı değişkenle olan anlamlı ilişkisine göre ve modele olan anlamlı katkılarına göre bağımsız değişkenler her adımda modelde tutulur yada modelden atılır. Yöntem modele girecek veya modelden çıkarılacak değişken kalmayınca kadar devam eder. Verilerin %70'i modeli kurmak ve eğitmek için kullanılmış, geri kalan %30'luk kısım ise test için saklı veri olarak ayrılmıştır. Bu seçimler rastgele değil belirli aralıklar verilerek yapılmıştır.

Rüzgar şiddeti regresyon denklemleri aşağıdaki şekilde bulunmuştur.

$$\text{Mart Ayı} : Y_{rs+k} = 1,549 + 0,196X_{rs} + 0,593X_{s5cm} - 0,83X_{ry} - 0,354X_{s2m} - 0,785X_{uv}$$

$$\text{Haziran Ayı} : Y_{rs+k} = -0,874 + 0,085X_{s5cm} + 0,378X_{rs} + 0,69X_{s2m}$$

$$\text{Eylül Ayı} : Y_{rs+k} = -14,788 + 0,123X_{s2m} + 0,292X_{rs} + 0,002X_{gr} + 0,659X_{s5cm} + 0,038X_{ry}$$

$$\text{Aralık Ayı} : Y_{rs+k} = 3,911 + 0,436X_{s5cm} - 0,405X_{s2m} - 2,156X_{uv} + 0,040X_{ry} + 0,041X_{rs}$$

Güneş Radyasyonu regresyon denklemleri aşağıdaki şekilde bulunmuştur.

$$\text{Mart Ayı} : Y_{gr+k} = 6,442 + 0,533X_{gr} + 4,1X_{rs} + 39,28X_{uv} + 2,036X_{ry} - 12,771X_{s2m} \\ + 14,117 X_{s5cm}$$

$$\text{Haziran Ayı} : Y_{gr+k} = 8,793 + 0,295X_{gr} + 70,857X_{uv} + 12,101X_{rs} + 13,563X_{s5cm} - 11,895X_{s2m}$$

$$\text{Eylül Ayı} : Y_{gr+k} = 592,34 + 0,51X_{gr} + 67,82X_{uv} + 3,887X_{rs} - 32,726X_{s5cm} + 5,934X_{s2m} \\ - 1,843X_{ry}$$

$$\text{Aralık Ayı} : Y_{gr+k} = -2,93 + 0,766X_{gr} + 3,385X_{rs} + 20,065X_{uv}$$

$$Y_{rs+k} : 24 \text{ saat sonraki Rüzgar Şiddeti çıkış } (t+k)$$

$$Y_{gr+k} : 24 \text{ saat sonraki Güneş Radyasyonu çıkış } (t+k)$$

$$X_{rs} : \text{Rüzgar Şiddeti giriş } (t)$$

$$X_{gr} : \text{Güneş Radyasyonu giriş } (t)$$

$$X_{uv} : \text{UV Radyasyon İndis giriş } (t)$$

$$X_{s5cm} : \text{Toprak Üstü 5cm Sıcaklık giriş } (t)$$


$$X_{s2m} : \text{Sıcaklık 2m giriş } (t)$$

$$X_{ry} : \text{Rüzgar Yönü giriş } (t)$$


Çizelge 3.5 : Rüzgar Şiddeti (m/s), Çoklu Linear Regresyon Modellerinin (ÇLR_{RS}) Performansları

Aylar	Eğitim					Test				
	R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	0,328	0,107	3,05	0,861	71,96	0,169	0,029	2,49	1,660	140,83
Haziran	0,658	0,433	1,67	0,428	34,45	0,716	0,513	1,60	0,342	26,45
Eylül	0,698	0,488	1,56	0,383	30,37	0,569	0,324	3,66	1,086	95,90
Aralık	0,217	0,047	3,00	0,752	62,50	0,116	0,013	5,36	0,852	68,32

Çizelge 3.5’de Rüzgar şiddeti için aylar bazında ÇLR ile tahmin modellerinin başarımlarını istatistikleri görülmektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. Buna göre rüzgar şiddeti için ÇLR modeli en başarılı tahminleri Haziran ayında yapmıştır. Test verilerinde en yüksek R² değeri 0.513 ile Haziran ayında kaydedilmiştir. nRMSE ve MAPE değerleri de ilgili ayda sırayla 0.342 ve %26.45 ile en düşük değerler olarak bulunmuştur.



(a)



(b)

Şekil 3.5 : Haziran Ayı, Rüzgar Şiddeti, ÇLR Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri


Şekil 3.5'te Haziran ayı rüzgar şiddeti test verilerine ait ÇLR modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişimini gösteren grafik görülmektedir.

Çizelge 3.6 : Güneş Radyasyonu (W/m^2), Çoklu Lineer Regresyon Modellerinin (ÇLR_{GR}) Performansları


Aylar	Eğitim					Test				
	R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	0,771	0,594	103,82	1,048	65,62	0,640	0,410	158,58	1,195	68,74
Haziran	0,876	0,767	149,26	0,554	34,16	0,902	0,813	140,93	0,539	36,74
Eylül	0,929	0,864	92,08	0,507	28,10	0,726	0,527	163,93	1,184	94,56
Aralık	0,824	0,679	53,73	1,054	55,02	0,596	0,355	53,55	1,751	102,58

Çizelge 3.6'da güneş radyasyonu için aylar bazında ÇLR ile tahmin modellerinin başarımlarını göstermektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. Buna göre güneş radyasyonu için ÇLR modeli en başarılı tahminleri Haziran ayında yapmıştır. Test verilerinde en yüksek R² değeri 0.813 ile Haziran ayında kaydedilmiştir. MAPE değeri de ilgili ayda %36.74 ile en

düşük değer olarak bulunmuştur. nRMSE değeri de 0.539 ile en düşük Haziran ayında bulunmuştur.



(a)



(b)

Şekil 3.6 : Haziran Ayı, Güneş Radyasyonu, ÇLR Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri

Şekil 3.6'da Haziran ayı güneş radyasyonu test verilerine ait ÇLR modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişimini gösteren grafik görülmektedir.

3.2 Dalgacık Analizi

Çalışmanın bu bölümünde rüzgar şiddeti ve güneş radyasyonu verilerine dalgacık analizi uygulanmıştır. Dört mevsimi temsilen her mevsimin başlangıç ayı seçilmiştir. İlkbahar için Mart ayı, yaz için Haziran ayı, sonbahar için Eylül ayı ve kış mevsimi için Aralık ayı verileri kullanılmıştır. Veriler 10 dakikalık periyotlarla kayıtladığı için 30 yada 31 çeken aylara göre bir ayda 4320 ile 4464 arası veri kaydı bulunmalıdır. Bazı aylarda değişik nedenlere bağlı olarak az da olsa kayıp veriler mevcuttur. Aylar bazında kayıp veri analizi istatistik çalışması bölümünde gerçekleştirilmiştir.

Ayrık dalgacık dönüşümü ve sürekli dalgacık dönüşümü MATLAB programının Wavelet Analyzer aracı kullanılarak gerçekleştirilmiştir. Wavelet Analyzer aracında ayrık dalgacık analizi Wavelet 1D olarak, sürekli dalgacık analizi ise Continuous Wavelet 1D olarak geçmektedir.

ADD ile zaman serileri alçak ve yüksek frekans bileşenlerine ayrıştırılır. Bu bileşenler yaklaşım (*ing.* approximations) ve detay (*ing.* details) bileşenleri olarak adlandırılır. Orijinal veri s harfi, yaklaşım bileşeni a harfi, detay bileşenleri ise d harfi ile gösterilmektedir. Çalışmada veriler üç seviyede ayrıştırıldığından detay bileşenleri d_1 , d_2 ve d_3 olarak yer alır ve sırayla görece daha küçük, orta ve büyük ölçekleri olayları temsil ederler. Büyük ölçekli olaylar düşük frekans ve uzun periyotla sahipken, küçük ölçekli olaylar yüksek frekans ve kısa periyotlarda gerçekleşir. Yaklaşım bileşeni (a_3) yüksek ölçek değerlerine sahip olmakla beraber zaman serisindeki uzun periyot ve düşük frekans değerlerini temsil eder. Detay bileşenleri ise görece daha düşük (d_3), orta (d_2) ve yüksek (d_1) frekanslı değişimleri temsil eder.

SDD'de rüzgar şiddeti ve güneş radyasyonuna etki eden olaylar küçükten büyüğe doğru bir renk skalasına göre renklendirilmektedir. Renk spektogramında yatay eksen zaman serisini, dikey eksen ise gözlenen olayların periyodisitesini belirtmektedir. Böylece meydana gelen olayların büyüklüğü ve periyodisitesi aynı anda gözlemlenebilmektedir. Büyük ölçek değerleri daha uzun periyotlu dalgacıklar üretirken, küçük ölçek değerleri sıkıştırılmış dalgacıklar üretir. Küçük ölçekli (düşük periyotlu) dalgacıklar, hızlı değişir ve detayları daha iyi yakalar ve dolayısıyla yüksek frekans değerlerinin saptanması için uygundur. Büyük ölçekli dalgacıklar ise yavaş değişen özellikleri, bir başka deyişle verinin genel trendini yansıtan özellikleri daha iyi yakalar ve düşük frekans değerlerinin saptanması için uygundur. Sürekli


dalgacık analizi ile rüzgar şiddetine ve güneş radyasyonuna etki eden küçük, orta ve büyük ölçekli atmosferik olayların rolünün saptanması hedeflenmektedir.

3.2.1 Mart Ayı dalgacık analizi


3.2.1.1 Mart Ayı ayrık dalgacık analizi

Eskice Mevki 2016 yılı Mart ayı rüzgar şiddetine ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşımlar Şekil 3.7’de görülmektedir. Veriler 10 dakika aralıklarla kayıtlı olduğu için 144 adet veri 24 saatlik zaman dilimini göstermektedir. İnceleme döneminin ilk 10 günlük başlangıç döneminden sonra kuvvetli rüzgar şiddetleri kaydedilmiştir. Rüzgar şiddeti değişiminde her üç ölçekten olayların rolü gözlenmekte olup, özellikle büyük ölçekli olayların rolünün daha etkin olduğu vurgulanabilir.

Şekil 3.8’de Eskice Mevki 2016 yılı Mart ayı güneş radyasyonuna Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşımlar görülmektedir. Ay boyunca günlük olarak bir periyodiklik söz konusudur. İncelenen ayın 13 ve 14. gününde daha düşük radyasyon değerleri görülmüştür. Bu değişimde büyük ve küçük ölçekten olayların etken olduğu belirtilebilir.




Şekil 3.7 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Mart Ayı)



Şekil 3.8 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m2), Eskice Mevki (2016 Yılı Mart Ayı)


3.2.1.2 Mart Ayı sürekli dalgacık analizi

Şekil 3.9’de 2016 yılı Mart ayına ait Eskice Mevki rüzgar şiddeti zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. Mart ayı boyunca genelde düşük ve orta ölçekli olayların hakimiyeti görülmekle beraber beş farklı büyük ölçekli olayın gerçekleştiği söylenebilir. Ayın ortasına karşı gelen değişimlerde büyük ölçekli bir olayın rüzgar şiddetini artırıcı rol oynadığı söylenebilir. Ayın son döneminde veri kaybı nedeni ile analiz yapılamamıştır.



Şekil 3.9 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Mart Ayı)

Şekil 3.10'de ise 2016 yılı Mart ayına ait Eskice Mevki güneş radyasyonu zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. Mart ayı boyunca küçük, orta ve büyük ölçekli olayların birlikte etkin rol oynadığı gözlenmektedir. Özellikle inceleme döneminin ikinci yarısında büyük ölçekli olayların rolü daha fazladır.




Şekil 3.10 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m^2), Eskice Mevki (2016 Yılı Mart Ayı)

3.2.2 Haziran ayı dalgacık analizi


3.2.2.1 Haziran ayı ayırık dalgacık analizi

Eskice Mevki 2016 yılı Haziran ayı rüzgar şiddetine ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri Şekil 3.11’da görülmektedir. İncelenen ay boyunca kuvvetli rüzgar şiddeti kaydedilmiştir. İncelenen ayın özellikle son 10 gününde belirli bir periyodiklik içerisinde kuvvetli rüzgarlar görülmektedir. Ay boyunca küçük ve orta ölçekli olayların etkisi daha fazla görülmektedir.



Şekil 3.11 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Haziran Ayı)

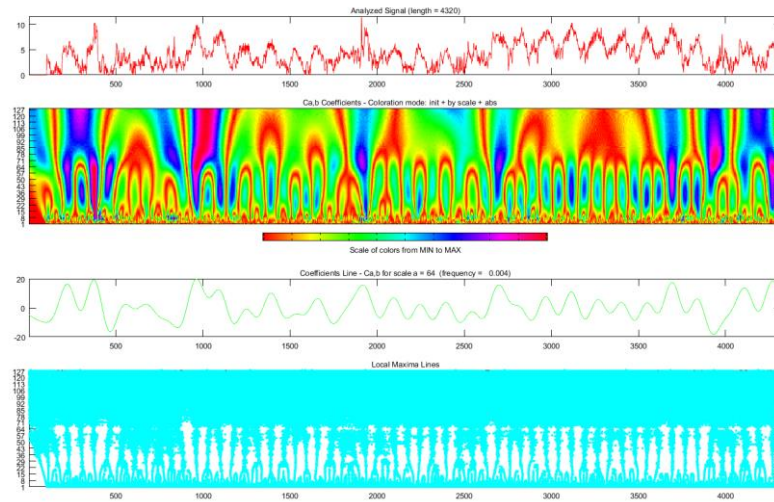
Şekil 3.12’de Eskice Mevki 2016 yılı Haziran ayı güneş radyasyonuna ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri görülmektedir. İncelenen ayın ilk yarısında üç ölçekten de olayların etkisi varken ikinci yarısında büyük ölçekli olaylar daha belirgin etki göstermektedir.



Şekil 3.12 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m²), Eskice Mevki (2016 Yılı Haziran Ayı)


3.2.2.2 Haziran ayı sürekli dalgacık analizi

Şekil 3.13’de 2016 yılı Haziran ayına ait Eskice Mevki rüzgar şiddeti zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. İncelenen ayın üç, yedi ve onüçüncü gününde büyük ölçekli olayların etkisi görülmektedir. Bu olayların kuvvetli rüzgar şiddetine neden olduğu söylenebilir. Ayın son yarısında dört büyük ölçekli olayın daha gerçekleştiği vurgulanabilir.



Şekil 3.13 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Haziran Ayı)

Şekil 3.14’de ise 2016 yılı Haziran ayına ait Eskice Mevki güneş radyasyonu zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. İncelenen ayın başında ve sonunda büyük ölçekli olayların varlığı görülmektedir. Ay boyunca devam eden ve 12 saatte bir gerçekleşen bir periyodiklik söz konusudur.




Şekil 3.14 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m²), Eskice Mevki (2016 Yılı Haziran Ayı)

3.2.3 Eylül ayı dalgacık analizi


3.2.3.1 Eylül ayı ayırık dalgacık analizi

Eskice Mevki 2016 yılı Eylül ayı rüzgar şiddetine ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri Şekil 3.15’te görülmektedir. Ay boyunca düzenli olarak 24 saatte bir yüksek rüzgar şiddetine neden olan bir periyodiklik söz konusudur. İncelenen ayda büyük ölçekli olayların daha belirgin olarak etkili olduğu söylenebilir.



Şekil 3.15 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Eylül Ayı)


Şekil 3.16’te Eskice Mevki 2016 yılı Eylül ayı güneş radyasyonuna ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri görülmektedir. İncelenen ayın ilk 18 gününde düzenli bir periyodiklik söz konusu iken son 12 gününde büyük ve küçük çaplı olaylara bağlı olarak bir düzensizlik söz konudur. Ay boyunca büyük ölçekli olayların daha etkili olduğu söylenebilir.



Şekil 3.16 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m2), Eskice Mevki (2016 Yılı Eylül Ayı)


3.2.3.2 Eylül ayı sürekli dalgacık analizi

Şekil 3.17’de 2016 yılı Eylül ayına ait Eskice Mevki rüzgar şiddeti zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. İncelenen ay boyunca büyük ve küçük ölçekli olayların varlığı beraber gözlemlenmektedir. Ay boyunca düzenli olarak gerçekleşen büyük çaplı olayların varlığından söz edilebilir. Özellikle periyodikliği daha büyük olan beş veya altı büyük ölçekli olayın ay boyunca farklı zamanlarda gerçekleştiği söylenebilir.



Şekil 3.17 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Eylül Ayı)

Şekil 3.18’de ise 2016 yılı Eylül ayına ait Eskice Mevki güneş radyasyonu zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. İncelenen ayın başında büyük ölçekli bir olayın varlığı belirgin bir şekilde görülmektedir. İlk 18 günde düzenli olarak tekrar eden büyük ölçekli olaylara ait bir periyodiklik söz konusudur. Ayın son 10-12 gününde ise büyük, orta ve küçük çaplı olayların beraber görüldüğü düzensiz bir dönem söz konusudur.




Şekil 3.18 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m²), Eskice Mevki (2016 Yılı Eylül Ayı)

3.2.4 Aralık ayı dalgacık analizi


3.2.4.1 Aralık ayı ayırık dalgacık analizi

Eskice Mevki 2016 yılı Aralık ayı rüzgar şiddetine ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri Şekil 3.19’da görülmektedir. İncelenen ay boyunca her üç ölçekten olayların etkisi görülmekle beraber orta ölçekli olayların daha etkili olduğu vurgulanabilir. Ay sonunda yüksek rüzgar şiddeti görülmüştür.



Şekil 3.19 : Wavelet 1D, Db1, 3 Seviye, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Aralık Ayı)


Şekil 3.20’de Eskice Mevki 2016 yılı Aralık ayı güneş radyasyonuna ait Wavelet 1D analizi sonucunda ortaya çıkan detay ve yaklaşım bileşenleri görülmektedir. İncelenen ay boyunca her üç ölçekli olayın da etkili olduğu vurgulanabilir. Ay sonuna doğru büyük ve orta ölçekli olayların etkisi daha fazladır.



Şekil 3.20 : Wavelet 1D, Db1, 3 Seviye, Güneş Radyasyonu (W/m2), Eskice Mevki (2016 Yılı Aralık Ayı)


3.2.4.2 Aralık ayı sürekli dalgacık analizi

Şekil 3.21’de 2016 yılı Aralık ayına ait Eskice Mevki rüzgar şiddeti zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. İncelenen ay başında, ortasında ve sonunda olmak üzere üç grup büyük ölçekli olayın etkisi görülmektedir. Bu olaylar rüzgar şiddetinin 10 m/s’nin üzerine çıkmasını sağlamıştır. Özellikle ay sonunda gerçekleşen büyük ölçekli olaylara bağlı olarak 15 m/s civarında kuvvetli rüzgar şiddetinin varlığı görülmektedir.



Şekil 3.21 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Rüzgar Şiddeti (m/s), Eskice Mevki (2016 Yılı Aralık Ayı)

Şekil 3.22’de ise 2016 yılı Aralık ayına ait Eskice Mevki güneş radyasyonu zaman serisine ait Continuous Wavelet 1D analizi görülmektedir. Ay boyunca büyük ve küçük ölçekli olaylar beraber etkili olmuştur. İncelenen ayın ortasında üç tane büyük ölçekli ve üç tane de küçük ölçekli olayların varlığı görülmektedir. Ayrıca ayın 22 ve 24’cü günlerinde iki büyük ölçekli olayın gerçekleştiği görülmektedir. Son 8 günde küçük ve büyük ölçekli olaylar beraber görülmüştür. Küçük ölçekli olayların gerçekleştiği günlerde güneş radyasyonunun 200 W/m^2 ’nin altına düştüğü vurgulanabilir.



Şekil 3.22 : Continuous Wavelet 1D, Mexh, Örneklem Periyodu: 1, Ölçek :128, Güneş Radyasyonu (W/m²), Eskice Mevki (2016 Yılı Aralık Ayı)

3.3 YSA ile Tahmin Modelleme

3.3.1 Kurulan YSA modellerinin mimarisi

Çalışma kapsamında İleri Beslemeli (*ing.* Feed Forward), Geri Yayılımlı (*ing.* Back Propagation) YSA modelleri kullanılmıştır. Aynı mimariye sahip YSA modellerinden Rüzgar Şiddeti ve Güneş Radyasyonunu tahmin etmek için iki farklı model kurulmuştur. Kurulan modellerde bir adet giriş katmanı, bir adet gizli katman, bir adet çıkış katmanı olmak üzere toplam 3 katman bulunmaktadır. Girişte 6 adet veri grubu olduğu için giriş katmanı 6 nörondan oluşmaktadır. Çıkış katmanında ise Rüzgar Şiddeti veya Güneş Radyasyonu olan tek parametre olduğundan çıkış katmanı tek nöronludur.

YSA modellerinde gizli katmanlardaki nöron sayısını belirlemek için kesin bir kural yoktur. Genellikle belirli sayıdan başlamak suretiyle ve kademeli artırma ile modeller denenerek uygun sayı bulunmaya çalışılır. Olması gerekenden az belirlenen gizli nöron sayısını modellerin kötü sonuçlar vermesine, gereğinden fazla belirlenen gizli nöron sayısı da modellerin verileri ezberlemesine ve sadece eğitim verilerinde iyi sonuçlar verip test verilerinde başarısız olmasına neden olabilir (Çakır, 2018).

Gizli katmandaki hücre sayısının belirlenmesinde kesin bir kural olmamakla beraber genellikle gizli katman hücre sayısı giriş katmanındaki hücre sayısının iki katını

geçmez. Ayrıca piramit kuralı denilen bir yöntem kullanılır. Bu kurala göre bir piramitin yapısına benzer şekilde giriş katmanından çıkış katmanına doğru hücre sayısının azalması gerektiği varsayılır. Giriş ve çıkış katmanındaki hücre sayıları sırayla n ve m olmak üzere piramit kuralına göre Eşitlik (3.1) ile gizli hücre sayısı bulunur (Yücesoy, 2011).


$$\sqrt{m * n} \quad (3.1)$$

Bu çalışmada gizli katmandaki nöron sayısını belirlemek için çok sayıda deneme yapılmıştır. Piramit kuralı da dikkate alınarak yapılan denemelerde gizli katmanda 3 nöron kullanıldığı zaman genel olarak en iyi sonucun alındığı görülmüştür. Bu nedenle gizli katmandaki hücre sayısının 3 olmasına karar verilmiştir. Çalışmada geliştirilen YSA modelleri aşağıdaki şekilde isimlendirilmiştir.

YSA (Giriş Katmanı, Gizli Katman, Çıkış Katmanı) model

YSA modellerinin uygulanması için MATLAB R2016b programının *nntool* aracı ve Ek C’de gösterilen kodlardan yararlanılmıştır. INTEL® Core™ i5 8250U CPU @ 1.80 GHz işlemci, 12Gb DDR4 ana bellek, 64 bit Windows 10 Professional işletim sistemine sahip bilgisayar kullanılmıştır. Şekil 3.23’de MATLAB’ta kurulan YSA modelinin şeması görülmektedir. Kurulan YSA modellerinin genel özellikleri aşağıdaki gibi seçilmiştir.

Eğitim algoritması	: Levenberg Marquand (<i>trainlm</i>)
Gizli katman transfer fonksiyonu	: Tanjant Sigmoid (<i>tansig</i>)
Gizli katman nöron sayısı	: 3
Çıktı katmanı transfer foknsiyonu	: Tanjant Sigmoid (<i>tansig</i>)
Öğrenme oranı	: 0,2
Momentum	: 0,8
Maksimum İterasyon	: 3000



Şekil 3.23 : MATLAB YSA Model Şeması (MATLAB 2016, nntool)

3.3.2 YSA modellerini uygulama

Elde bulunan veriler mevsimlik olarak dört gruba ayrılmıştır. İlkbahar mevsimini temsilen seçilen Mart ayı, yaz mevsimini temsilen seçilen Haziran ayı, sonbahar mevsimini temsilen seçilen Eylül ayı ve kış mevsimini temsilen seçilen Aralık ayı verileri kullanılmıştır. Geliştirilen YSA modeli seçilen dört ayın her biri için ayrı olarak uygulanmış ve sonuçlar aylar bazında gösterilerek değerlendirilmiştir.

YSA ile uygulama işlemine başlamadan önce her aya ait veri setinin ilk %70'i sinir ağlarını eğitmek için belirlenmiştir. Geri kalan %30'luk kısım ise eğitimi tamamlanan modelleri test etmek için saklı veri olarak ayrılmıştır. Veriler seçilirlen rastgele değil, belirli aralık verilerek seçim işlemi yapılmıştır.

3.3.2.1 Rüzgar şiddeti YSA ile tahmin modelleme

Rüzgar Şiddetinin değişik meteorolojik parametrelere bağlı olarak tahmin edilmesi için geliştirilen YSA modeli matematiksel olarak Eşitlik (3.2) 'de gösterilmiştir.

$$Y_{rs+k} = f(X_{rs}, X_{gr}, X_{uv}, X_{s5cm}, X_{s2m}, X_{ry}) \quad (3.2)$$

Y_{rs+k} : 24 saat sonraki Rüzgar Şiddeti çıkış (k = 24 saat)

X_{rs} : Rüzgar Şiddeti giriş (t)

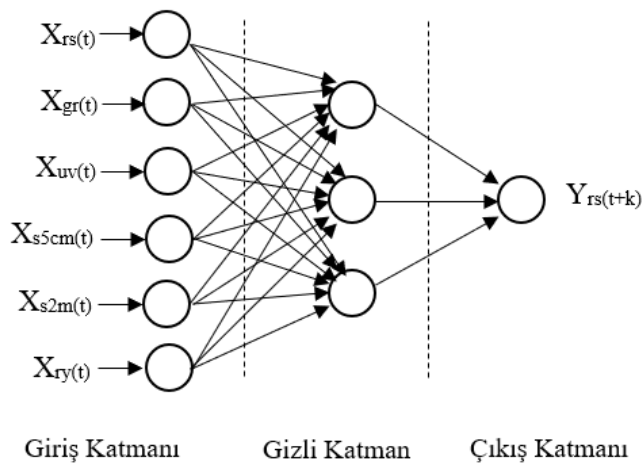
X_{gr} : Güneş Radyasyonu giriş (t)

X_{uv} : UV Radyasyon İndis giriş (t)

X_{s5cm} : Toprak Üstü 5cm Sıcaklık giriş (t)

X_{s2m} : Sıcaklık 2m giriş (t)

X_{ry} : Rüzgar Yönü giriş (t)




Şekil 3.24 : YSA(6,3,1)_{RS} Modelinin Şematik Gösterimi

Şekil 3.24’de YSA(6,3,1)_{RS} modelinin şematik gösterimi görülmektedir. Modele giriş olarak t zamandaki X_{rs} , X_{gr} , X_{uv} , X_{s5cm} , X_{s2m} , X_{ry} verileri verilmiş, çıkışta ise 24 saat sonraki rüzgar şiddeti (Y_{rs+k}) tahmin edilmiştir.

Çizelge 3.7 : Rüzgar Şiddeti (m/s), YSA(6,3,1)_{RS} Modellerinin Performansı


Aylar	Eğitim					Test				
	R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	0,611	0,374	2,55	0,721	57,20	0,252	0,063	2,49	1,658	132,10
Haziran	0,717	0,514	1,55	0,397	31,02	0,748	0,559	1,56	0,332	26,33
Eylül	0,775	0,600	1,37	0,339	26,61	0,633	0,400	1,74	0,516	40,40
Aralık	0,450	0,203	2,75	0,688	56,36	0,269	0,072	4,92	0,782	63,92

Çizelge 3.7’de rüzgar şiddeti için aylar bazında YSA ile tahmin modellerinin başarımlarını gösteren istatistikleri görülmektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. YSA modellerinin rüzgar şiddetini tahmin etmede ÇLR modellerine göre tüm aylarda daha başarılı olduğu ortaya çıkmaktadır. Test verilerine göre rüzgar şiddeti için YSA ile en başarılı tahminler Haziran ayında yapılmıştır. Test verilerinde en yüksek R² değeri 0.559 ile Haziran ayında kaydedilmiştir. MAPE ve nRMSE değerleri de ilgili ayda sırayla %26.33 ve 0.332 ile en düşük değer olarak bulunmuştur.




Şekil 3.25 : Haziran 2016, Rüzgar Şiddeti YSA Modeli Eğitim Aşaması (MATLAB 2016, nntaintool)

Şekil 3.25’de rüzgar şiddeti YSA(6,3,1) modelinin MATLAB programında eğitim aşamasındaki grafikleri görülmektedir.



(a)



(b)

Şekil 3.26 : Haziran Ayı, Rüzgar Şiddeti, YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin zaman Grafiği, Test verileri

Şekil 3.26’de Haziran ayı rüzgar şiddeti test verilerine ait YSA(6,3,1) modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişimini gösteren grafik görülmektedir.

3.3.2.2 Güneş radyasyonu YSA ile tahmin modelleme

Güneş Radyasyonunun değişik meteorolojik parametrelere bağlı olarak tahmin edilmesi için geliştirilen YSA modeli matematiksel olarak Eşitlik (3.3)'de gösterilmiştir.

$$Y_{gr+k} = f(X_{gr}, X_{rs}, X_{uv}, X_{s5cm}, X_{s2m}, X_{ry}) \quad (3.3)$$

Y_{gr+k} : 24 saat sonraki Güneş Radyasyonu çıkış ($k = 24$ saat)

X_{gr} : Güneş Radyasyonu giriş (t)


X_{rs} : Rüzgar Şiddeti giriş (t)

X_{uv} : UV Radyasyon İndis giriş (t)

X_{s5cm} : Toprak Üstü 5cm Sıcaklık giriş (t)

X_{s2m} : Sıcaklık 2m giriş (t)

X_{ry} : Rüzgar Yönü giriş (t)




Şekil 3.27 : YSA(6,3,1)_{GR} Modelinin Şematik Gösterimi

Şekil 3.27'de şematik olarak gösterilen YSA(6,3,1)_{GR} modelinde giriş olarak t zamandaki X_{gr} , X_{rs} , X_{uv} , X_{s5cm} , X_{s2m} , X_{ry} verileri verilmiş, çıkışta ise 24 saat sonraki güneş radyasyonu (Y_{gr+k}) tahmin edilmiştir.

Çizelge 3.8 : Güneş Radyasyonu (W/m^2), YSA(6,3,1)_{GR} Modellerinin Performansı


Aylar	Eğitim					Test				
	R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	0,827	0,683	91,73	0,926	52,19	0,744	0,553	142,86	1,077	60,02
Haziran	0,921	0,848	120,49	0,447	25,00	0,912	0,832	126,98	0,485	28,21
Eylül	0,945	0,893	81,55	0,449	21,93	0,775	0,601	146,14	1,055	52,99
Aralık	0,869	0,756	47,00	0,922	43,83	0,687	0,472	47,81	1,568	69,09

Çizelge 3.8’de güneş radyasyonu için aylar bazında YSA ile tahmin modellerinin başarımları istatistikleri görülmektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. YSA modellerinin güneş radyasyonunu tahmin etmede ÇLR modellerine göre tüm aylarda daha başarılı olduğu ortaya çıkmaktadır. Test verilerine göre Güneş Radyasyonu için YSA modeli ile en başarılı tahminler Haziran ayında yapılmıştır. Test verilerinde en yüksek R² değeri 0.832 ile Haziran ayında kaydedilmiştir. MAPE değeri de ilgili ayda %28.21 ile en düşük değer olarak bulunmuştur. nRMSE değeri de 0.485 ile en düşük Haziran ayında bulunmuştur.




Şekil 3.28 : Haziran 2016, Güneş Radyasyonu YSA Modeli Eğitim Aşaması (MATLAB 2016, nntool)

Şekil 3.28’de güneş radyasyonu YSA(6,3,1) modelinin MATLAB programında eğitim aşamasındaki grafikleri görülmektedir.



(a)



(b)


Şekil 3.29 : Haziran Ayı, Güneş Radyasyonu, YSA(6,3,1) Modeli İçin (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri

Şekil 3.29’de Haziran ayı güneş radyasyonu test verilerine ait YSA(6,3,1) modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişimini gösteren grafik görülmektedir.

3.4 Dalgacık YSA İle Tahmin Modelleme

Dalgacık YSA (D-YSA) modelinde giriş verileri dalgacık dönüşümü ile ön işleme tabi tutularak alt zaman bileşenlerine ayrılmaktadır. Bu çalışmada veriler Daubechies3 (Db3) ana dalgacığı kullanılarak 11 seviye olacak şekilde ayrıştırılmıştır. Şekil 3.30'da örnek olarak Haziran ayı rüzgar şiddeti verisinin Db3 ile 11.seviyeden alt zaman bileşenlerine ayrıştırılması görülmektedir. Ayrıştırma işlemi neticesinde 11 adet detay bileşeni ($d_1, d_2 \dots d_{11}$) ve bir adet yaklaşım bileşeni (a_{11}) elde edilmektedir. ADD'de ayrıştırma işlemi ikinin kuvvetleri şeklinde yapılmakta ve 11 seviyeli ayrıştırma işleminde seviyeler sırayla 2-4-8-16-32-64-128-256-512-1024-2048 periyodiklik zaman dilimlerine denk gelmektedir. Mevcut çalışmada bu periyodiklikler sırayla 20 dak., 40 dak., 1.3 saat, 2.6 saat, 5.3 saat, 10.6 saat, 21.3 saat, 1.7 gün, 3.5 gün, 7.1 gün, 14.2 güne karşılık gelmektedir.

Giriş verilerinin ADD ile ayrıştırılması neticesinde elde edilen 11 adet detay alt bileşenleri ile modelin tahmin edeceği çıkış verisi arasındaki korelasyon ilişkisine bakılarak giriş için uygun alt bileşenler seçilmiştir. Seçme işleminde yüksek korelasyona sahip alt bileşenler seçilirken düşük korelasyona sahip alt bileşenler ise elenmektedir. Böylece her bir giriş verisi için çıkış verisi üzerinde daha etkili olabilecek farklı alt bileşenlerinin toplanması ile yeni zaman serisi elde edilmiştir. Elde edilen bu yeni zaman serileri ile tahmin edilmesi istenilen çıkış verisi arasındaki korelasyona bakıldığında orijinal giriş verileri ile olan korelasyona göre daha yüksek çıktığı görülmüştür.



Şekil 3.30 : Wavelet 1D, Db3, 11.Seviye, Rüzgar Şiddeti, Eskice Mevki, Haziran Ayı

3.4.1 Rüzgar şiddeti D-YSA ile tahmin modelleme

Rüzgar şiddetini tahmin etmek için aylar bazında uygulanan D-YSA modellerinde öncelikle giriş verileri ADD ile alt zaman bileşenlerine ayrılmıştır. Çizelge 3.9'da Haziran ayı için tahmin edilmek istenilen bir gün sonraki rüzgar şiddeti ile diğer meteorolojik verilerin dalgacık dönüşümü sonucu elde edilen alt zaman bileşenleri arasındaki korelasyon değerleri görülmektedir. Rüzgar şiddeti için diğer aylara ait benzer tablolar Çizelge A.5, A.6, A.7 'de verilmiştir.

Çizelge 3.9 : Haziran Ayı, Bir Gün Sonraki Rüzgar Şiddeti ($t + k$) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	0,002	-0,004	-0,004	-0,002	-0,002	0,000
<i>d2</i>	-0,010	0,002	-0,002	0,000	-0,002	0,006
<i>d3</i>	0,015	0,002	0,011	0,007	0,011	0,012
<i>d4</i>	-0,004	0,001	0,005	0,000	0,014	-0,002
<i>d5</i>	0,019	0,034	0,001	0,043	0,061	0,003
<i>d6</i>	0,281	0,361	0,343	0,361	0,328	-0,065
<i>d7</i>	0,378	0,358	0,350	0,361	0,338	-0,025
<i>d8</i>	-0,053	-0,106	-0,086	0,004	-0,024	0,141
<i>d9</i>	0,152	-0,112	-0,090	0,126	0,188	0,118
<i>d10</i>	-0,278	-0,316	-0,371	-0,315	-0,093	-0,326
<i>d11</i>	0,341	0,292	0,357	0,231	0,172	-0,465
<i>a11</i>	0,162	0,079	0,097	0,187	0,223	0,056
<i>s</i>	0,545	0,484	0,476	0,557	0,531	-0,060

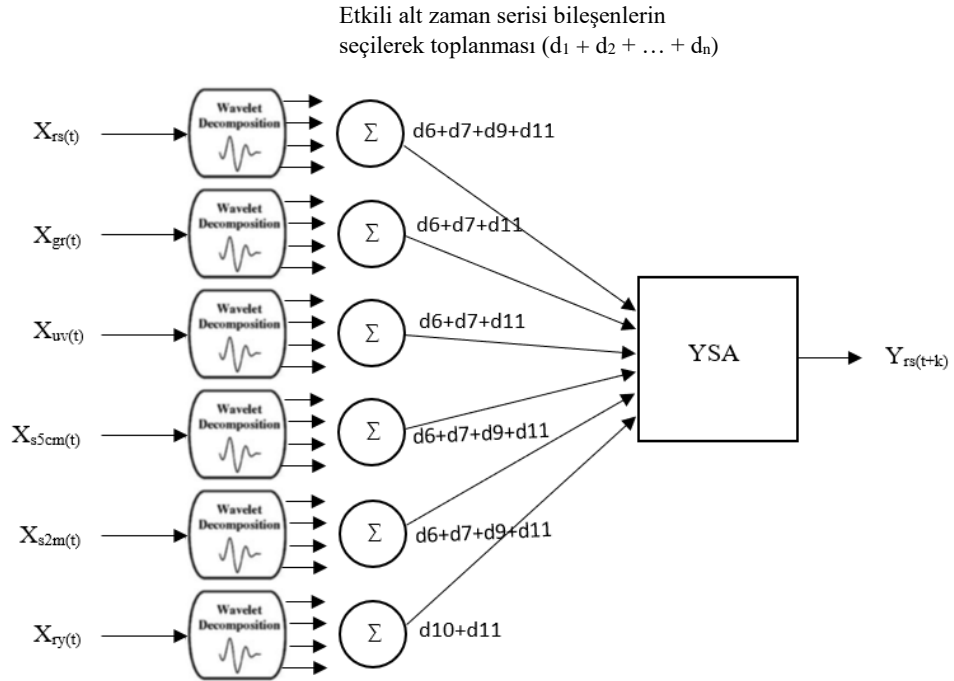
ADD sonucu ortaya çıkan 11 adet detay bileşeni ve bir adet yaklaşım bileşeni tabloda görülmektedir. Orijinal sinyal ise *s* ile gösterilmiştir. Örneğin bir gün sonraki rüzgar şiddeti ile bir gün önceki rüzgar şiddeti alt zaman bileşenleri arasındaki korelasyon değerlerine bakıldığında pozitif yüksek korelasyona sahip olan *d6*, *d7*, *d9*, *d11* detay bileşenleri alınmış, diğer bileşenler ise orijinal sinyale göre düşük korelasyon yada negatif korelasyona sahip oldukları için alınmamıştır. Negatif olmasına rağmen orijinal sinyale göre yüksek değerde korelasyona sahip alt bileşenler de ayrıca giriş parametresi olarak alınabilir. Alınan bu bileşenler toplanarak rüzgar şiddeti giriş parametresi için yeni bir zaman serisi elde edilmiş olur. Bileşenler toplanmadan ayrı olarak da YSA girişine verilebilir fakat bu durumda çok sayıda giriş verisi ortaya çıkar ve model karmaşıklaşır. Bu nedenle alt bileşenlerin toplanması yoluna gidilmiştir. Yüksek korelasyona sahip alt bileşenlerin toplanması ile elde edilen yeni zaman serisi ile tahmin edilmesi gereken hedef parametre olan bir gün sonraki rüzgar şiddeti arasındaki korelasyon değeri artmaktadır. Aynı işlem diğer giriş parametreleri için de uygulanmıştır.

Çizelge 3.10'da aylar bazında bir gün sonrası için rüzgar şiddeti tahmininde kullanılmak üzere geliştirilen D-YSA modellerinde giriş için seçilen alt zaman bileşenleri görülmektedir. Bu bileşenler tahmin edilmesi istenilen bağımlı değişken ile aralarındaki korelasyona bakılarak seçilmişlerdir.

Çizelge 3.10 : Rüzgar Şiddeti D-YSA Modellerininde Giriş İçin Seçilen Alt Zaman Bileşenleri

	Mart	Haziran	Eylül	Aralık
Giriş Adedi	11	6	8	10
Rüzgar Şiddeti (t)	d8, d9+d10+d11	d6+d7+d9+d11	d6+d7+d10	d10, d8+d9
Güneş Radyasyonu (t)	d9, d6+d7+d10	d6+d7+d11	d6+d7	d6+d7+d9, d8+d10+d11
UV Radyasyon İndisi (t)	d9, d6+d10	d6+d7+d11	d6+d7	d8+d10+d11
Toprak Üstü 5cm Sıcaklık (t)	d8, d6+d9+d10	d6+d7+d9+d11	d10, d6+d7+d11	d6+d7+d10, d9+d11
Sıcaklık 2m (t)	d8, d6+d10	d6+d7+d9+d11	d6+d7+d10	d9+d11
Rüzgar Yönü (t)	d9+d11	d10+d11	d10, d11	d8, d11

Şekil 3.31’de D-YSA(6,3,1)_{RS} modelinin şematik gösterimi görülmektedir. Modele giriş olarak t zamandaki X_{rs} , X_{gr} , X_{uv} , X_{s5cm} , X_{s2m} , X_{ry} verilerinin etkili alt bileşen toplamlarından oluşan yeni zaman serileri verilmiş, çıkışta ise 24 saat sonraki rüzgar şiddeti (Y_{rs+k}) tahmin edilmiştir.



Şekil 3.31 : Haziran Ayı D-YSA(6,3,1)_{RS} Modelinin Şematik Gösterimi

Çizelge 3.11’de rüzgar şiddeti için aylar bazında D-YSA ile tahmin modellerinin başarımlarını istatistikleri görülmektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$


seviyesinde istatistiksel anlamlıdır. D-YSA modellerinin rüzgar şiddeti için tüm aylarda tahmin başarısını artırdığı ve YSA modellerine göre daha başarılı olduğu görülmektedir. Test verilerine göre D-YSA modellerinde en yüksek R^2 değeri 0.634 ile Haziran ayında kaydedilmiştir. nRMSE ve MAPE değerleri de sırayla 0.327 ve %26.07 ile en düşük Haziran ayında çıkmıştır.

Haziran ayında $MAPE < \%30$ olduğu için modelin performansı iyi olarak yorumlanabilir. Eylül (%36.74) ve Aralık (%40.08) Aylarında $MAPE < \%50$ olduğu için model sonuçları kabul edilebilir sınırlar içinde kalmaktadır. Mart ($MAPE = \%87.45$) ayında model performansı güvenilir değildir.


Çizelge 3.11 : Rüzgar Şiddeti (m/s), D-YSA Modellerinin Performansı

Aylar	Model	Eğitim					Test				
		R	R^2	RMSE	nRMSE	MAPE (%)	R	R^2	RMSE	nRMSE	MAPE (%)
Mart	D-YSA (11,3,1) _{RS}	0,857	0,734	1,67	0,470	35,93	0,591	0,350	1,97	1,312	87,45
Haziran	D-YSA (6,3,1) _{RS}	0,802	0,643	1,32	0,340	26,48	0,796	0,634	1,53	0,327	26,07
Eylül	D-YSA (8,3,1) _{RS}	0,838	0,702	1,19	0,292	22,61	0,698	0,487	1,62	0,482	36,74
Aralık	D-YSA (10,3,1) _{RS}	0,876	0,768	1,48	0,371	28,92	0,778	0,606	3,34	0,532	40,08

Şekil 3.32’da Haziran ayı rüzgar şiddeti test verilerine ait D-YSA(6,3,1) modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişim grafiği görülmektedir.



(a)



(b)

Şekil 3.32 : Haziran Ayı, Rüzgar Şiddeti, D-YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri

3.4.2 Güneş radyasyonu D-YSA ile tahmin modelleme

Güneş radyasyonunu tahmin etmek için aylar bazında uygulanan D-YSA modellerinde öncelikle giriş verileri ADD ile alt zaman bileşenlerine ayrılmıştır. Çizelge 3.12’de Haziran ayı için tahmin edilmek istenilen bir gün sonraki güneş rasyasyonu ile diğer meteorolojik verilerin dalgacık dönüşümü sonucu elde edilen alt zaman bileşenleri arasındaki korelasyon değerleri görülmektedir. Güneş rasyasyonu için diğer aylara ait benzer tablolar Çizelge A.8, A.9, A.10’da verilmiştir.

Çizelge 3.12 : Haziran Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri


Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndisi (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
d1	0,009	0,002	0,010	0,005	-0,001	-0,002
d2	-0,006	-0,002	-0,013	-0,004	-0,007	-0,001
d3	0,018	-0,005	0,025	0,004	0,001	0,003
d4	0,012	0,011	0,007	0,015	0,024	0,009
d5	0,131	0,032	0,129	0,085	0,053	-0,007
d6	0,519	0,365	0,516	0,489	0,434	-0,119
d7	0,712	0,568	0,709	0,693	0,573	0,014
d8	-0,011	-0,006	0,010	0,028	0,027	0,062
d9	-0,017	-0,005	-0,034	-0,096	-0,093	-0,044
d10	-0,047	-0,04	-0,059	-0,064	-0,039	-0,065
d11	-0,010	0,003	0,002	0,027	0,030	-0,033
a11	0,061	0,068	0,063	0,070	0,074	0,058
s	0,860	0,452	0,859	0,751	0,536	-0,016

Çizelge 3.13’de bir gün sonraki güneş radyasyonunu tahmini için geliştirilen D-YSA modellerinde aylar bazında hangi alt zaman bileşenlerin giriş olarak seçildiği verilmiştir. Etkili alt zaman bileşenleri bağımlı ve bağımsız değişkenler arasındaki korelasyon ilişkisine bakılarak seçilmektedir. Yüksek korelasyona sahip bileşenler alınmakta, düşük korelasyona sahip bileşenler ise elenmektedir. Her bir veri grubu için seçilen etkili alt zaman bileşenleri toplanarak elde edilen yeni zaman serileri D-YSA modellerinde giriş olarak kullanılmaktadır.

Çizelge 3.13 : Güneş Radyasyonu D-YSA Modellerinde Giriş İçin Seçilen Alt Zaman Bileşenleri

	Mart	Haziran	Eylül	Aralık
Giriş Adedi	6	6	6	6
Rüzgar Şiddeti (t)	d6+d7	d5+d6+d7	d5+d6+d7+d11	d5+d6+d7
Güneş Radyasyonu (t)	d5+d6+d7+d9+d11	d6+d7	d6+d7	d6+d7
UV Radyasyon İndisi (t)	d5+d6+d7+d9+d11	d5+d6+d7	D5+d6+d7+d11	d5+d6+d7
Toprak Üstü 5cm Sıcaklık (t)	d5+d6+d7+d11	d6+d7	d6+d7	d5+d6+d7
Sıcaklık 2m (t)	d5+d6+d7+d11	d6+d7	d5+d6+d7+d11	d5+d6+d7
Rüzgar Yönü (t)	d6+d7+d9+d11	d6+d9+d10	d6	d4+d5+d6+d8+d9

Şekil 3.33’de Haziran ayı D-YSA(6,3,1)_{GR} modeli görülmektedir. Modele giriş olarak t zamandaki X_{rs} , X_{gr} , X_{uv} , X_{s5cm} , X_{s2m} , X_{ry} verilerinin etkili alt bileşen toplamlarından oluşan yeni zaman serileri verilmiş, çıkışta ise 24 saat sonraki güneş radyasyonu (Y_{gr+k}) tahmin edilmiştir.




Şekil 3.33 : Haziran Ayı D-YSA(6,3,1)_{GR} Modelinin Şematik Gösterimi

Çizelge 3.14’de güneş radyasyonu için aylar bazında D-YSA ile tahmin modellerinin başarımlar istatistikleri görülmektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. Güneş radyasyonunun tahmini için kullanılan D-YSA modellerinin tüm aylarda tahmin başarısını artırdığı ve YSA modellerine göre daha başarılı olduğu görülmektedir. Test verilerine göre D-YSA modellerinde en yüksek R^2 değeri 0.842 ile Haziran ayında kaydedilmiştir. MAPE değeri de %27.84 ile en düşük Haziran ayında hesaplanmıştır. nRMSE değeri de en düşük 0.471 ile Haziran ayında bulunmuştur. MAPE sonuçlarına göre güneş radyasyonu tahmininde gözlem ve tahmin değerleri arasında iyi uyum sadece Haziran ayında (MAPE < %30) saptanmıştır. MAPE sonuçlarına göre modelin Mart, Eylül ve Aralık aylarındaki tahmin yönteminin iyileştirilmesi gerekmektedir.


Çizelge 3.14 : Güneş Radyasyonu (W/m^2), D-YSA Modellerinin Performansı

Aylar	Model	Eğitim					Test				
		R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	D-YSA (6,3,1) _{GR}	0,861	0,741	82,94	0,838	46,39	0,767	0,589	132,19	0,996	59,34
Haziran	D-YSA (6,3,1) _{GR}	0,922	0,850	119,72	0,444	26,50	0,918	0,842	123,05	0,471	27,84
Eylül	D-YSA (6,3,1) _{GR}	0,952	0,907	76,28	0,420	21,73	0,796	0,634	141,16	1,019	51,74
Aralık	D-YSA (6,3,1) _{GR}	0,895	0,801	42,38	0,831	41,76	0,725	0,525	44,71	1,466	62,09

Şekil 3.34'da Haziran ayı güneş radyasyonu test verilerine ait D-YSA(6,3,1) modelinin saçılma grafiği ile tahmin-gözlem değerlerinin zamansal değişim grafiği görülmektedir.



(a)



(b)

Şekil 3.34 : Haziran Ayı, Güneş Radyasyonu, D-YSA(6,3,1) Modeli (a) Saçılma Grafiği (b) Gözlem-Tahmin Zaman Grafiği, Test Verileri

4. BULGULAR VE ÖNERİLER

Rüzgar ve güneş enerjisi önemli yenilenebilir enerji kaynaklarından ve kullanımları gittikçe artmaktadır. Rüzgar ve güneşe dayalı enerji sistemlerinin kurulumu ve işletilmesinde şebekeye entegrasyon, enerji verimliği ve sürdürülebilirlik açısından rüzgar şiddeti ve güneş radyasyonunun önden kestirimi büyük önem taşımaktadır. Özellikle rüzgar enerjisi stokastik yapısından dolayı oldukça değişkendir ve rüzgar şiddetinin önden kestirimi enerji üretim planlaması için önemlidir. Bu nedenle rüzgar şiddeti ve güneş radyasyonunun karakteristikleri ile bunlara etki eden büyük ve küçük ölçekli olayları bilmek, bunların gelecek değerlerini önceden tahmin etmek enerji üretim planlaması için oldukça önemlidir.

Bu çalışmada İstanbul İli Büyükçekmece İlçesi Eskice Mevki bölgesinde 10 dakikalık ortalamalar şeklinde kaydedilen 2016 yılı rüzgar şiddeti, güneş radyasyonu, UV radyasyon indis, toprak üstü 5cm sıcaklık, sıcaklık 2m, rüzgar yönü verileri kullanılmıştır. Mevsimsel etkileri saptamak üzere her mevsimi temsilen mevsimlerin ilk ayları olan Mart, Haziran, Eylül ve Aralık ayları seçilmiş ve bu aylara ait verilerle çalışılmıştır. Bazı aylarda kayıt problemi veri eksikliğine neden olduğu için her mevsime ait birer aylık örneklem yapılmıştır.

4.1 İstatistiksel Analiz Sonuçları

Eskice Mevkisi 2016 yılındaki veriler yıllık bazda değerlendirildiğinde yıllık ortalama rüzgar şiddetinin 3,3 m/s, yıllık ortalama güneş radyasyonunun ise 152 W/m² olduğu görülmektedir (Çizelge 3.1). Aylık ortalama veriler incelendiğinde ortalama rüzgar şiddeti ve güneş radyasyonunun mevsimlere göre farklılık gösterdiği saptanmıştır. Rüzgar şiddetinin Ağustos ayında 5,32 m/s aylık ortalama ile en yüksek değere ulaştığı, güneş radyasyonunun Temmuz ayında 280 W/m² ile en yüksek değerini aldığı belirlenmiştir (Şekil 3.1 ve Şekil 3.2). Bu verilere göre çalışma bölgesi için rüzgar şiddetine bağlı olarak rüzgar enerji potansiyelinin Ağustos ayında en yüksek, güneş radyasyonuna bağlı olarak da güneş enerji potansiyelinin Temmuz ayında en yüksek seviyede olduğu söylenebilir. Bununla birlikte aylık ortalamalar tek tek dikkate alındığında yıl boyunca Mart ayı hariç bütün aylarda yeterli rüzgar enerji potansiyeli

olduğu söylenebilir. Çalışma bölgesinde Nisan, Mayıs, Haziran, Temmuz ve Ağustos aylarında güneş radyasyonu ortalamaları 200 W/m^2 üzerinde olduğundan ilgili aylarda yüksek güneş enerji potansiyelinin varlığından söz edilebilir.

Rüzgar şiddeti ve güneş radyasyonunun diğer verilerle aralarındaki ilişkinin değerlendirmesi amacıyla aylar bazında korelasyon katsayılarına bakılmıştır. Mart ayında rüzgar şiddetinin rüzgar yönü verisi ile negatif, Haziran ayında toprak üstü 5cm sıcaklık verisi ile pozitif, Eylül ayında güneş radyasyonu verisi ile pozitif, Aralık ayında rüzgar yönü verisi ile negatif ilişkileri olduğu saptanmıştır. Bu veri çiftleri arasında $\alpha < 0.01$ seviyesinde istatistiksel anlamlı bir ilişki olduğu görülmektedir. Mart, Haziran, Eylül ve Aralık aylarında güneş radyasyonunun, UV radyasyon indis değerleri ile pozitif ($\alpha < 0.01$ seviyesinde anlamlı) ilişkiye sahip olduğu görülmektedir (Çizelge A.1, Çizelge A.2, Çizelge A.3, Çizelge A.4).

Rüzgar şiddeti ve güneş radyasyonu verilerine ait frekans dağılımını gösteren histogram grafiklerine bakıldığında dört mevsimi temsil eden tüm aylarda her iki veri grubunda da pozitif çarpıklık görülmektedir (Şekil B.1, Şekil B.2, Şekil B.3, Şekil B.4).

4.2 ÇLR Modelleme Sonuçları

ÇLR modellemesinde rüzgar şiddeti, güneş radyasyonu, UV radyasyon indis, toprak üstü 5cm sıcaklık, sıcaklık 2m, rüzgar yönü verileri bağımsız değişken olarak kullanılmıştır. Tahmin zamanından 24 saat öncesine ait mereorolojik veriler kullanarak yaklaşık 8-10 günlük bir zaman diliminde 10 dakikalık zaman adımlarıyla rüzgar şiddeti ve güneş radyasyonu değerlerinin tahmine çalışılmıştır. Tezin bu aşamasında kullanılan ÇLR modelleri ile en yüksek başarı Haziran ayında elde edilmiştir. Haziran ayında rüzgar şiddeti için R^2 , nRMSE ve MAPE(%) değerleri sırayla 0.513, 0.342, 26.45 ; güneş radyasyonu için sırayla 0.813, 0.539, 36.74 olarak bulunmuştur, (Çizelge 3.5, Çizelge 3.6). Sonuç olarak Haziran ayında ÇLR modellerinin rüzgar şiddeti ve güneş radyasyonu tahmininde yeter güvenilirlikte ($\alpha < 0.01$) kullanılabileceği vurgulanabilir. Bulgular Mart, Eylül ve Aralık ayının sonuçlarına göre ÇLR modelinin bu aylarda tahmin için kullanılmasının uygun olmadığını göstermektedir.

4.3 YSA Modelleme Sonuçları

Seçilen aylardaki sonuçlara göre YSA modelleri tahmin çalışmasında ÇLR modellerinden daha başarılı olmuştur. YSA ile yapılan tahmin çalışmasında en iyi sonuçlar Haziran ayında elde edilmiştir. Haziran ayında rüzgar şiddeti için R^2 , nRMSE ve MAPE(%) değerleri sırayla 0.559, 0.332, 26.33 ; güneş radyasyonu için sırası ile 0.832, 0.485, 28.21 olarak bulunmuştur (Çizelge 3.7, Çizelge 3.8). Güneş radyasyonu tahmininde ÇLR modellerinin kestiremediği minimum değerleri YSA modelinin başarı ile tahmin ettiği vurgulanabilir (Şekil B.13, Şekil B.14, Şekil B.15, Şekil B.16). YSA modelleri rüzgar şiddeti ve güneş radyasyonu tahmininde Haziran ve Eylül aylarında daha başarılı olmuştur. Fakat Mart ve Aralık ayları için YSA modellerinin rüzgar şiddeti ve güneş radyasyonu tahmin çalışmalarında kullanılmasının uygun olmadığı görülmüştür (Çizelge 3.7, Çizelge 3.8).

4.4 D-YSA Modelleme Sonuçları

Mevsimleri temsilen seçilen Mart, Haziran, Eylül ve Aralık aylarında rüzgar şiddeti ve güneş radyasyonun tahmini için D-YSA modelleri ile yapılan analiz sonuçlarına göre her iki veri grubunda YSA'ya göre iyileşme sağlanmıştır. En başarılı sonuçların alındığı Haziran ayında rüzgar şiddeti için R^2 , nRMSE ve MAPE(%) değerleri sırayla 0.634, 0.327, 26.07 ; güneş radyasyonu için sırası ile 0.842, 0.471, 27.84 olarak bulunmuştur (Çizelge 3.11, Çizelge 3.14). Gözlem ve tahmin verileri arasında $\alpha < 0.01$ güven seviyesinde ve MAPE < %30 skalasında anlamlı ve iyi ilişki olduğu vurgulanabilir. Her iki parametrenin ve bu parametrelere bağlı rüzgar ve güneş enerjisi potansiyelinin tahmin çalışmalarında Eskice Mevkiğinde Haziran ayında D-YSA modelinin yeter güvenilirlikle kullanılabileceği sonucuna varılmıştır.

4.5 Genel Sonuç ve Öneriler

Tahmin zamanından 24 saat önceki 10 dakikalık aralıklarla kayıtlı verilere dayalı olarak ve ÇLR, YSA, D-YSA modelleri kullanılarak rüzgar şiddetinin tahmin edilmesi için gerçekleştirilen çalışmaların toplu olarak başarımlı istatistikleri Çizelge 4.1'de görülmektedir.

Çizelge 4.1 : Rüzgar Şiddeti (m/s), Model Performanslarının Karşılaştırılması

Aylar	Model	Eğitim					Test				
		R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	MLR _{RS}	0,328	0,107	3,05	0,861	71,96	0,169	0,029	2,49	1,660	140,83
	YSA (6,3,1) _{RS}	0,611	0,374	2,55	0,721	57,20	0,252	0,063	2,49	1,658	132,10
	D-YSA (11,3,1) _{RS}	0,857	0,734	1,67	0,470	35,93	0,591	0,350	1,97	1,312	87,45
Haziran	MLR _{RS}	0,658	0,433	1,67	0,428	34,45	0,716	0,513	1,60	0,342	26,45
	YSA (6,3,1) _{RS}	0,717	0,514	1,55	0,397	31,02	0,748	0,559	1,56	0,332	26,33
	D-YSA (6,3,1) _{RS}	0,802	0,643	1,32	0,340	26,48	0,796	0,634	1,53	0,327	26,07
Eylül	MLR _{RS}	0,698	0,488	1,56	0,383	30,37	0,569	0,324	3,66	1,086	95,90
	YSA (6,3,1) _{RS}	0,775	0,600	1,37	0,339	26,61	0,633	0,400	1,74	0,516	40,40
	D-YSA (8,3,1) _{RS}	0,838	0,702	1,19	0,292	22,61	0,698	0,487	1,62	0,482	36,74
Aralık	MLR _{RS}	0,217	0,047	3,00	0,752	62,50	0,116	0,013	5,36	0,852	68,32
	YSA (6,3,1) _{RS}	0,450	0,203	2,75	0,688	56,36	0,269	0,072	4,92	0,782	63,92
	D-YSA (10,3,1) _{RS}	0,876	0,768	1,48	0,371	28,92	0,778	0,606	3,34	0,532	40,08

Rüzgar şiddeti tahmininde test sonuçlarına göre YSA modelleri dört ayda da ÇLR modellerinden daha başarı olmuştur. YSA modellerinin başarımını artırmak için geliştirilen D-YSA hibrit modelleri kullanılarak gerçekleştirilen tahminlerde bütün aylarda başarımın arttığı görülmüştür. Böylece giriş verilerine dalgacık ayrıştırması ön işlemi uygulanmasının YSA tahmin modellerinin başarımını artırdığı ortaya konulmuştur. YSA modeli kullanılarak gerçekleştirilen rüzgar şiddeti tahminlerinde en iyi sonuçlar Haziran ayında alınmıştır. Haziran ayı için D-YSA modeli kullanılarak gerçekleştirilen tahminlerdeki sonuçlar YSA modellerine göre biraz daha iyileşmiştir. Rüzgar şiddeti tahmini için en iyi sonuçların alındığı Haziran ayında YSA modelinin R², nRMSE ve MAPE(%) değerleri sırayla 0.559, 0.332, 26.33 iken aynı ayda D-YSA modelinin değerleri sırayla 0.634, 0.327, 26.07 olarak hesaplanmıştır.

Tahmin zamanından 24 saat önceki 10 dakikalık aralıklarla kayıtlı verilere dayalı olarak ve ÇLR, YSA, D-YSA modelleri kullanılarak güneş radyasyonunun tahmin edilmesi için gerçekleştirilen çalışmaların toplu olarak başarım istatistikleri Çizelge 4.2’de görülmektedir.

Çizelge 4.2 : Güneş Radyasyonu (W/m²), Model Performanslarının Karşılaştırılması

Aylar	Model	Eğitim					Test				
		R	R ²	RMSE	nRMSE	MAPE (%)	R	R ²	RMSE	nRMSE	MAPE (%)
Mart	ÇLR _{GR}	0,771	0,594	103,82	1,048	65,62	0,640	0,410	158,58	1,195	68,74
	YSA (6,3,1) _{GR}	0,827	0,683	91,73	0,926	52,19	0,744	0,553	142,86	1,077	60,02
	D-YSA (6,3,1) _{GR}	0,861	0,741	82,94	0,838	46,39	0,767	0,589	132,19	0,996	59,34
Haziran	ÇLR _{GR}	0,876	0,767	149,26	0,554	34,16	0,902	0,813	140,93	0,539	36,74
	YSA (6,3,1) _{GR}	0,921	0,848	120,49	0,447	25,00	0,912	0,832	126,98	0,485	28,21
	D-YSA (6,3,1) _{GR}	0,922	0,850	119,72	0,444	26,50	0,918	0,842	123,05	0,471	27,84
Eylül	ÇLR _{GR}	0,929	0,864	92,08	0,507	28,10	0,726	0,527	163,93	1,184	94,56
	YSA (6,3,1) _{GR}	0,945	0,893	81,55	0,449	21,93	0,775	0,601	146,14	1,055	52,99
	D-YSA (6,3,1) _{GR}	0,952	0,907	76,28	0,420	21,73	0,796	0,634	141,16	1,019	51,74
Aralık	ÇLR _{GR}	0,824	0,679	53,73	1,054	55,02	0,596	0,355	53,55	1,751	102,58
	YSA (6,3,1) _{GR}	0,869	0,756	47,00	0,922	43,83	0,687	0,472	47,81	1,568	69,09
	D-YSA (6,3,1) _{GR}	0,895	0,801	42,38	0,831	41,76	0,725	0,525	44,71	1,466	62,09

Güneş radyasyonu tahmininde YSA modellerinin başarısı oldukça yüksek çıkmış ve tüm aylarda ÇLR modellerinden daha güvenilir olduğu görülmüştür. En başarılı tahminler Haziran ayında gerçekleşmiştir. Test verilerine göre Haziran ayında güneş radyasyonu tahmininde YSA modelinin R² ve MAPE(%) değerleri sırayla 0.832 ve 28.21 ile en iyi sonucu vermiştir. nRMSE değeri de 0.485 ile en düşük Haziran ayında hesaplanmıştır. D-YSA modelinin R² ve MAPE(%) değerleri sırayla 0.842 ve 27.84, olmak üzere en iyi Haziran ayında, nRMSE değeri de 0.471 ile en düşük Haziran ayında elde edilmiştir. Bu sonuçlar giriş verilerine uygulanan dalgacık dönüşümü ön işleminin YSA sonuçlarını iyileştirdiğini ve tahmin başarı oranını yükselttiğini ortaya koymaktadır.

Her mevsimdeki meteorolojik olaylar ve etkileri farklı olduğundan dolayı rüzgar şiddeti ve güneş radyasyonu tahmin çalışmalarında daha güvenilir sonuçlar elde edebilmek için modellemelerin mevsimsel yapılması ve mümkün ise aylık olarak ayrı ayrı çalışılması gerektiği vurgulanabilir.

Tahmin çalışmasının zaman ufku ve adımları değiştirilerek farklı zaman ufku ve zaman adımları için başarıyı test edilebilir. Bu çalışmada ileri beslemeli geri yayımlı YSA modelleri seçilmiştir. YSA modellerinde Levenberg Marquand eğitim

algoritması ile Tanjant Sigmoid transfer fonksiyonu kullanılmıştır. Kullanılan YSA modeli gizli katmanda farklı nöron sayıları ve farklı transfer fonksiyonları ile denenmiş olmakla beraber mevcut YSA modeli farklı eğitim algoritmaları ile denenebilir. İleri beslemeli geri yayımlı modelden farklı YSA modelleri denenerek daha ayrıntılı çalışmalar yapılabilir.

Hibrit olarak geliştirilen D-YSA modellerinde dalgacık ayrıştırması sonucu ortaya çıkan alt zaman bileşenlerinin seçilmesinde farklı yöntemler denenerek model başarımları test edilebilir. Ayrıca çalışmada kullanılan YSA ve D-YSA modelleri farklı bölgelerde uygulanarak test edilebilir.

Çalışmada geliştirilen tahmin modellerine dayalı olarak gelecek için enerji üretim planlaması yapılabilir veya rüzgar ve güneş enerji sistemlerinde olası dalgalanmalara karşı erken uyarı sistemleri geliştirilebilir. Elde edilen bulguların İstanbul İli Büyükçekmece İlçesi ve civarında mevcut bulunan rüzgar ve güneş enerji sistemlerinin enerji verimliliğinin artırılmasında, ayrıca gelecekte kurulması planlanan sistemlerin kurulum ve işletim aşamalarında yararlı olması beklenmektedir.

KAYNAKLAR

- Aghajani, A., Kazemzadeh, R., & Ebrahimi, A.** (2016). A novel hybrid approach for predicting wind farm power production based on wavelet transform, hybrid neural networks and imperialist competitive algorithm. *Energy Conversion and Management*, 121, 232-240.
doi:10.1016/j.enconman.2016.05.024
- Akarşlan, E., Hocaoğlu, F. O., & Edizkan, R.** (2014). A novel M-D (multi-dimensional) linear prediction filter approach for hourly solar radiation forecasting. *Energy*, 74, 978-986. doi:10.1016/j.energy.2014.06.113
- Akcan, S.** (2017). Wind speed forecasting using time series analysis methods. *Cukurova Univ J Fac Eng Archit*, 32(2), 161-172.
[https://mmf.cu.edu.tr/tr/Dergi/\(32_2_2017\)/16.pdf](https://mmf.cu.edu.tr/tr/Dergi/(32_2_2017)/16.pdf) adresinden alındı
- Alkan, Ö., Öztürk, A., & Tosun, S.** (2018). Rüzgar ve Güneş Santrallerinde Kısa Dönem Enerji Üretim Tahmini İçin Matematiksel Modellerin Oluşturulması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(1), 188-195.
doi:10.29130/dubited.359698
- Amrouche, B., & Le Pivert, X.** (2014). Artificial neural network based daily local forecasting for global solar radiation. *Applied Energy*, 130, 333-341.
doi:10.1016/j.apenergy.2014.05.055
- Arı, N., Özen, Ş., & Çolak, Ö. H.** (2008). *Dalgacık Teorisi (Wavelet)*. Ankara: Palme Yayıncılık.
- Aslan, Y., Yavasca, S., & Yasar, C.** (2011). Long term Electric Peak load forecasting of Kutahya using different approaches. *International Journal on Technical and Physical Problems of Engineering*, 3(2), 87-91.
- Ata, R.** (2015). Artificial neural networks applications in wind energysystems: a review. *Renewable and Sustainable Energy Reviews*, 49(534-562).
doi:10.1016/j.rser.2015.04.166
- Benali, L., Notton, G., Fouilloy, A., Voyant, C., & Dizene, R.** (2019). Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. *132*, 871-884. doi:10.1016/j.renene.2018.08.044
- Bou-Rabee, M., Sulaiman, S. A., Saleh, M. S., & Marafi, S.** (2017). Using artificial neural networks to estimate solar radiation in Kuwait. *Renewable and Sustainable Energy Reviews*, 72, 434-438.
doi:10.1016/j.rser.2017.01.013

- Cantürk, S. (2018).** Cantürk, S. (2018). Bir rüzgar çiftliğinden yapay sinir ağlarıyla kısa süreli elektrik üretim tahmini. *Master's thesis*. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü. Mayıs 20, 2019 tarihinde <http://hdl.handle.net/11655/4362> adresinden alındı
- Catalão, J. P., Pousinho, H. M., & Mendes, V. M. (2011).** Short-term Wind Power Forecasting in Portugal by. *Renewable energy*, 36(4), 1245-1251. doi:10.1016/j.renene.2010.09.016
- Chen, S. X., Gooi, H. B., & Wang, M. Q. (2013).** Solar radiation forecast based on fuzzy logic and neural networks. *Renewable Energy*, 60, 195-201. doi:10.1016/j.renene.2013.05.011
- Çakır, F. S. (2018).** *Yapay Sinir Ağları* (1. b.). Ankara: Nobel.
- Çelik, Ö., Teke, A., & Yıldırım, H. B. (2016).** Çelik, Ö., Teke, A., & Yıldırım, H. B. (2016). 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, 1-12. doi:10.1016/j.jclepro.2015.12.082
- Damodar, N. G. (2004).** *Basic econometrics* (4th edition b.). New York: The McGraw-Hill.
- Dhiman, H. S., Anand, P., & Deb, D. (2019).** Wavelet Transform and Variants of SVR with Application in Wind Forecasting. *Innovations in Infrastructure*, 501-511. doi:10.1007/978-981-13-1966-2_45
- Duran, K. (2013).** Rüzgar Karakteristiklerinin Dalgacık Dönüşümü İle Ortaya Konması. *Thesis (M.Sc.)*. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü. Nisan 20, 2019 tarihinde <http://hdl.handle.net/11527/7145> adresinden alındı
- El Mghouchi, Y., Chham, E., Zemmouri, E. M., & El Bouardi, A. (2019).** El Mghouchi, Y., Chham, E., Zemmouri, E. M., & El Bouardi, A. (2019). Assessment of different combinations of meteorological parameters for predicting daily global solar radiation using artificial neural networks. *Building and Environment*, 149, 607-622. doi:10.1016/j.buildenv.2018.12.055
- Elmas, Ç. (2016).** *Yapay Zeka Uygulamaları* (3. b.). Ankara: Seçkin Yayıncılık.
- Erdil, A., & Arcaklioglu, E. (2013).** The prediction of meteorological variables using artificial neural network. *Neural Computing and Applications*, 22(7-8), 1677-1683. doi:10.1007/s00521-012-1210-0
- Fan, J., Wu, L., Zhang, F., Cai, H., Zeng, W., Wang, X., & Zou, H. (2019).** Empirical and machine learning models for predicting daily global solar radiation from sunshine duration: A review and case study in China. *Renewable and Sustainable Energy Reviews*, 100, 186-212. doi:10.1016/j.rser.2018.10.018

- Fidan, M., Hocaoğlu, F. O., & Gerek, Ö. N.** (2014). Harmonic analysis based hourly solar radiation. *IET Renewable Power Generation*, 9(3), 218-227. doi:10.1049/iet-rpg.2014.0057
- Fugal, D. L.** (2009). *Conceptual Wavelets*. Mart 30, 2019 tarihinde http://www.conceptualwavelets.com/docs/satmag_0509.pdf adresinden alındı
- Ghofrani, M., Azimi, R., & Youshi, M.** (2019). Pattern Recognition and Its Application in Solar Radiation Forecasting. *IntechOpen*. doi:10.5772/intechopen.83503
- Ghorbani, M. A., Khatibi, R., FazeliFard, M. H., Naghipour, L., & Makarynskyy, O.** (2016). Short-term wind speed predictions with machine learning techniques. *Meteorology and Atmospheric Physics*, 128(1), 57-72. doi:10.1007/s00703-015-0398-9
- Graps, A.** (1995). An introduction to wavelets. *IEEE computational science and engineering*, 2(2), 50-61. doi: 10.1109/99.388960
- Guo, Z. H., Wu, J., Lu, H. Y., & Wang, J. Z.** (2011). A case study on a hybrid wind speed forecasting method using BP neural network. *Knowledge-Based Systems*, 24(7), 1048-1056. doi:10.1016/j.knosys.2011.04.019
- Hocaoğlu, F. O., Fidan, M., & Gerek, Ö. N.** (2009). Mycielski approach for wind speed prediction. *Energy Conversion and Management*, 50(6), 1436-1443. doi:doi.org/10.1016/j.enconman.2009.03.003
- Huang, J., Korolkiewicz, M., Agrawal, M., & Boland, J.** (2013). Forecasting solar radiation on an hourly time scale using a Coupled AutoRegressive and Dynamical System (CARDS) model. *Solar Energy*, 87, 136-149. doi:10.1016/j.solener.2012.10.012
- Hussain, S., & AlAlili, A.** (2017). A hybrid solar radiation modeling approach using wavelet multiresolution analysis and artificial neural networks. *Applied energy*, 208, 540-550. doi:10.1016/j.apenergy.2017.09.100
- Kılıç, F. Ç.** (2015). Güneş Enerjisi, Türkiye'deki Son Durumu ve Üretim Teknolojileri. *Engineer & The Machinery Magazine*, 56(671), 28-40. Mart 19, 2019 tarihinde http://www1.mmo.org.tr/resimler/dosya_ekler/09677e0899d72e8_ek.pdf adresinden alındı
- Kırbaş, İ.** (2018). Short-term multi-step wind speed prediction using statistical methods and artificial neural networks. *Sakarya University Journal of Science*, 22(1), 22-38. doi:10.16984/saufenbilder.305224
- Korkmaz, E., İzgi, E., & Tutun, S.** (2018). Forecasting of short-term wind speed at different heights using a comparative. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(5). doi:10.3906/elk-1601-213

- Li, G., & Shi, J.** (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7), 2313-2320. doi:10.1016/j.apenergy.2009.12.013
- Liu, H., Tian, H. Q., & Li, Y. F.** (2012). Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*, 98, 415-424. doi:10.1016/j.apenergy.2012.04.001
- Long, H., Zhang, Z., & Su, Y.** (2014). Analysis of daily solar power prediction with data-driven approaches. *Applied Energy*, 126, 29-37. doi:10.1016/j.apenergy.2014.03.084
- Lydia, M., Kumar, S. S., Selvakumar, A. I., & Kumar, G. P.** (2016). Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy Conversion and Management*, 112, 115-124. doi:10.1016/j.enconman.2016.01.007
- Mallat, S. G.** (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 11(7), 674-693. doi:10.1109/34.192463
- Melit, A., Benhanem, M., & Kalogirou, S. A.** (2006). An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*, 87(3), 705-722. doi:10.1016/j.apenergy.2005.06.003
- Monjoly, S., André, M., Calif, R., & Soubdhan, T.** (2017). Hourly forecasting of global solar radiation based on multiscale decomposition methods: A hybrid approach. *Energy*, 119, 288-298. doi:10.1016/j.energy.2016.11.061
- Nabiyev, V. V.** (2016). *Yapay Zeka* (5. b.). Ankara: Seçkin Yayıncılık.
- Nourani, V., Komasi, M., & Mano, A.** (2009). A multivariate ANN-wavelet approach for rainfall-runoff modeling. 23(14), 2877-2894. doi:10.1007/s11269-009-9414-5
- Nury, A. H., Hasan, K., & Alam, J. B.** (2017). Comparative study of wavelet-ARIMA and wavelet-ANN models for temperature time series data in northeastern Bangladesh. 29(1), 47-61. doi:10.1016/j.jksus.2015.12.002
- Özkan, Y.** (2016). *Veri Madenciliği Yöntemleri* (3. b.). İstanbul: Papatya Yayıncılık Eğitim.
- Öztemel, E.** (2016). *Yapay Sinir Ağları* (4. b.). İstanbul: Papatya Yayıncılık.
- Partal, T.** (2007). Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. *Doctoral dissertation*. İTÜ, Fen Bilimleri Enstitüsü. Mayıs 20, 2019 tarihinde <https://polen.itu.edu.tr/handle/11527/7607> adresinden alındı
- Partal, T.** (2016). Comparison of wavelet based hybrid models for daily evapotranspiration estimation using meteorological data. *KSCE Journal of Civil Engineering*, 20(5), 2050-2058. doi:10.1007/s12205-015-0556-0

- Partal, T., Kahya, E., & Cıgızođlu, K.** (2008). Yađıř verilerinin yapay sinir ađları ve dalgacık dđnüşümü. *İTÜDERGİSİ/d*, 7(3), 73-85. Nisan 23, 2019 tarihinde http://itudergi.itu.edu.tr/index.php/itudergisi_d/article/view/321 adresinden alındı
- Peleg, N.** (2000). Introduction to Wavelets. *Ders Notu*. University of Haifa. Mayıs 16, 2019 tarihinde <http://cs.haifa.ac.il/~nimrod/Compression/Wavelets/w1intro.pdf> adresinden alındı
- Rahman, M. M., B. Mostafiz, S., Paatero, J. V., & Lahdelma, R.** (2014). Extension of energy crops on surplus agricultural lands: A potentially viable option in developing countries while fossil fuel reserves are diminishing. *Renewable and Sustainable Energy Reviews*, 29, 108-119. doi:10.1016/j.rser.2013.08.092
- Ramasamy, P., Chandel, S. S., & Yadav, A. K.** (2015). Wind speed prediction in the mountainous region of India using anartificial neural network model. *Renewable Energy*, 80, 338-347. doi:10.1016/j.renene.2015.02.034
- Ramesh, B., & Arulmozhivarman, P.** (2013). Improving Forecast Accuracy of Wind Speed Using Wavelet. *Journal of Electrical Engineering and Technology*, 8(3), 559-564. doi:10.5370/JEET.2013.8.3.559
- Singh, S. N., & Mohapatra, A.** (2019). Singh, S. N., & Mohapatra, A. (2019). Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. *Renewable Energy*, 136, 758-768.
- Sun, S., Wang, S., Zhang, G., & Zheng, J.** (2018). A decomposition-clustering-ensemble learning approach for solar radiation forecasting. *Solar Energy*, 163, 189-199. doi:10.1016/j.solener.2018.02.006
- řenel, M. C., & Koç, E.** (2015). Dđnyada ve Tđrkiye'de Rüzgar Erenjisi Durumu- Genel Deđerlendirme. *Engineer & The Machinery Magazine*, 56(663), 46-56. Mart 19, 2019 tarihinde https://www.mmo.org.tr/sites/default/files/8453498933681d8_ek.pdf adresinden alındı
- Taşcıkaraođlu, A., & Uzunođlu, M.** (2011). Dalgacık Dđnüşümü ve Yapay Sinir Ađları ile Rüzgar Hızı Tahmini. *Elektrik-Elektronik ve Bilgisayar Sempozyumu*, (s. 106-111). Mayıs 1, 2019 tarihinde <http://web.firat.edu.tr/feeb/kitap/C12/32.pdf> adresinden alındı
- Terzi, Ö., & Barak, M.** (2015). Dalgacık-Sinir Ađı Yaklaşımı ile Yađıř-Akış Tahmini: Kızılırmak Nehri Örneđi. *Journal of Agricultural Sciences*, 21(4), 546-557. Nisan 23, 2019 tarihinde <http://dergipark.gov.tr/ankutbd/issue/1940/25068> adresinden alındı
- Trapero, J. R., Kourentzes, N., & Martin, A.** (2015). Short-term solar irradiation forecasting based on Dynamic Harmonic. *Energy*, 84, 289-295. doi:10.1016/j.energy.2015.02.100

- Yarımçam, D.** (2009). Ses sıkıştırma tekniklerinin başarımlarının analizi. *Thesis (M.Sc.)*. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü. Mayıs 16, 2019 tarihinde <http://acikerisim.istanbul.edu.tr/handle/123456789/4497> adresinden alındı
- Yılmaz, E. A., & Öziç, H. C.** (2018). Türkiye'nin Yenilenebilir Enerji Potansiyeli Ve Gelecek Hedefleri. *ODÜ Sosyal Bilimler Araştırmaları Dergisi (ODÜSOBIAD)*, 8(3), 525-535. <http://dergipark.gov.tr/odusobiad/issue/40617/388868> adresinden alındı
- Yücesoy, M.** (2011). Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini. *Thesis (M.Sc.)*. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü. Mayıs 1, 2019 tarihinde <http://hdl.handle.net/11527/5756> adresinden alındı
- Zang, H., Cheng, L., Ding, T., Cheung, K. W., Wang, M., Wei, Z., & Sun, G.** (2019). Estimation and validation of daily global solar radiation by day of the year-based models for different climates in China. *Renewable Energy*, 135, 984-1003. doi:10.1016/j.renene.2018.12.065
- Zhang, Y., Yang, S., Guo, Z., Guo, Y., & Zhao, J.** (2019). Wind speed forecasting based on wavelet decomposition and wavelet neural networks optimized by the Cuckoo search algorithm. *Atmospheric and Oceanic Science Letters*, 12(2), 107-115. doi:10.1080/16742834.2019.1569455

İnternet Kaynakları:

- Url-1** <http://www.yegm.gov.tr/YEKrepa/REPA-duyuru_01.html>, alındığı tarih: 19.03.2019.
- Url-2** <<http://www.yegm.gov.tr/MyCalculator/Default.aspx>>, alındığı tarih: 19.03.2019.
- Url-3** <<https://www.google.com/maps/place/41%C2%B004'20.0%22N+28%C2%B034'41.5%22E/@41.1210471,28.6443404,10.75z/data=!4m5!3m4!1s0x0:0x0!8m2!3d41.072208!4d28.5782>>, alındığı tarih : 17.06.2019.

EKLER

EK A : Çizelgeler

EK B : Şekiller

EK C : Kodlar

EK A

Çizelge A.1 : Mart Ayı Pearson Korelasyon Katsayıları

		Rüzgar Şiddeti	Güneş Radyasyon	Sıcaklık 2m	Toprak Üstü 5cm Sıcaklık	UV Radyasyon İndis	Rüzgar Yönü
Rüzgar Şiddeti	R	1	0,018	0,104**	0,138**	0,004	-0,185**
	α		0,222	0,000	0,000	0,765	0,000
	N	4457	4457	4457	4457	4457	3201
Güneş Radyasyon	R	0,018	1	0,429**	0,632**	0,943**	0,170**
	α	0,222		0,000	0,000	0,000	0,000
	N	4457	4457	4457	4457	4457	3201

** Korelasyon $\alpha < 0.01$ düzeyinde istatistiksel anlamlı.

Çizelge A.2 : Haziran Ayı Pearson Korelasyon Katsayıları

		Rüzgar Şiddeti	Güneş Radyasyon	Sıcaklık 2m	Toprak Üstü 5cm Sıcaklık	UV Radyasyon İndis	Rüzgar Yönü
Rüzgar Şiddeti	R	1	0,484**	0,471**	0,505**	0,458**	-0,245**
	α		0,000	0,000	0,000	0,000	0,000
	N	4320	4320	4162	4320	4320	4213
Güneş Radyasyon	R	0,484**	1	0,628**	0,828**	0,950**	-0,021
	α	0,000		0,000	0,000	0,000	0,168
	N	4320	4320	4162	4320	4320	4213

** Korelasyon $\alpha < 0.01$ düzeyinde istatistiksel anlamlı.

Çizelge A.3 : Eylül Ayı Pearson Korelasyon Katsayıları

		Rüzgar Şiddeti	Güneş Radyasyonu	Sıcaklık 2m	Toprak Üstü 5cm Sıcaklık	UV Radyasyon İndis	Rüzgar Yönü
Rüzgar Şiddeti	R	1	0,575**	0,534**	0,169**	0,547**	-0,085**
	α		0,000	0,000	0,000	0,000	0,000
	N	4320	4320	4320	4320	4320	4206
Güneş Radyasyonu	R	0,575**	1	0,597**	0,059**	0,951**	0,030
	α	0,000		0,000	0,000	0,000	0,051
	N	4320	4320	4320	4320	4320	4206

** Korelasyon $\alpha < 0.01$ düzeyinde istatistiksel anlamlı.

Çizelge A.4 : Aralık Ayı Pearson Korelasyon Katsayıları

		Rüzgar Şiddeti	Güneş Radyasyon	Sıcaklık 2m	Toprak Üstü 5cm Sıcaklık	UV Radyasyon İndis	Rüzgar Yönü
Rüzgar Şiddeti	R	1	0,000	0,063**	0,081**	-0,043**	-0,203**
	α		0,986	0,000	0,000	0,005	0,000
	N	4309	4307	4309	4309	4303	4172
Güneş Radyasyon	R	0,000	1	0,350**	0,588**	0,740**	0,055**
	α	0,986		0,000	0,000	0,000	0,000
	N	4307	4307	4307	4307	4302	4170

** Korelasyon $\alpha < 0.01$ düzeyinde istatistiksel anlamlı.

Çizelge A.5 : Mart Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
d1	-0,001	0,004	0,004	0,008	0,001	0,005
d2	-0,002	0,002	-0,009	-0,008	-0,012	0,009
d3	-0,001	0,003	0,012	-0,001	0,013	0,002
d4	0,035	0,024	0,011	0,016	0,018	0,021
d5	0,006	0,033	0,036	0,015	-0,002	-0,058
d6	0,088	0,141	0,141	0,140	0,100	0,084
d7	-0,038	0,101	0,091	0,095	0,087	0,040
d8	-0,204	-0,036	-0,025	-0,235	-0,146	0,042
d9	0,491	-0,528	-0,522	0,238	0,038	-0,234
d10	0,225	0,109	0,108	0,395	0,377	0,041
d11	0,357	-0,064	-0,071	-0,036	-0,035	-0,099
a11	0,199	0,188	0,199	-0,241	-0,244	-0,325
s	0,248	0,099	0,092	0,129	0,044	-0,100

Çizelge A.6 : Eylül Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	-0,002	-0,006	-0,006	0,000	-0,007	0,003
<i>d2</i>	0,000	-0,003	-0,009	0,004	0,004	0,009
<i>d3</i>	0,005	0,000	0,003	0,017	0,001	-0,004
<i>d4</i>	0,024	0,005	0,002	-0,014	0,006	0,005
<i>d5</i>	0,077	0,087	0,060	-0,018	0,068	-0,016
<i>d6</i>	0,355	0,336	0,315	-0,102	0,362	0,082
<i>d7</i>	0,517	0,493	0,487	-0,116	0,462	-0,040
<i>d8</i>	0,066	0,078	0,063	0,026	0,032	0,060
<i>d9</i>	-0,061	0,144	0,112	-0,029	0,035	0,011
<i>d10</i>	0,277	-0,112	-0,081	0,247	0,227	0,115
<i>d11</i>	0,152	0,139	0,142	-0,109	0,034	-0,116
<i>a11</i>	0,030	-0,165	-0,160	0,062	0,025	-0,149
<i>s</i>	0,585	0,557	0,545	0,213	0,614	0,021

Çizelge A.7 : Aralık Ayı, Bir Gün Sonraki Rüzgar Şiddeti (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	0,002	0,000	0,001	0,000	0,004	-0,003
<i>d2</i>	-0,007	-0,002	-0,004	-0,002	0,002	-0,005
<i>d3</i>	-0,002	-0,009	-0,003	-0,007	-0,010	0,016
<i>d4</i>	-0,001	0,039	0,017	0,014	-0,004	0,008
<i>d5</i>	0,041	0,093	0,049	0,082	0,077	-0,018
<i>d6</i>	0,067	0,106	0,079	0,102	0,093	-0,003
<i>d7</i>	-0,009	0,127	0,125	0,148	0,131	0,082
<i>d8</i>	-0,256	-0,189	-0,116	-0,071	-0,045	0,162
<i>d9</i>	-0,252	0,141	-0,059	-0,192	-0,197	0,060
<i>d10</i>	0,469	-0,302	-0,267	0,198	0,020	0,016
<i>d11</i>	0,130	-0,237	-0,264	-0,235	-0,246	-0,274
<i>a11</i>	0,045	0,056	-0,190	-0,170	-0,146	0,090
<i>s</i>	0,071	0,100	0,034	0,128	0,071	0,075

Çizelge A.8 : Mart Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	-0,005	-0,001	0,002	-0,001	0,000	0,004
<i>d2</i>	0,032	-0,002	-0,006	-0,004	-0,002	0,006
<i>d3</i>	0,031	-0,004	-0,013	0,021	-0,005	-0,011
<i>d4</i>	0,091	0,031	0,074	0,016	0,036	0,008
<i>d5</i>	0,203	0,097	0,185	0,167	0,109	-0,085
<i>d6</i>	0,557	0,332	0,541	0,496	0,318	0,158
<i>d7</i>	0,503	0,224	0,492	0,458	0,393	0,192
<i>d8</i>	-0,085	0,008	-0,078	-0,049	-0,048	-0,006
<i>d9</i>	0,120	-0,059	0,117	-0,084	-0,056	0,094
<i>d10</i>	-0,047	-0,023	-0,052	-0,055	-0,059	-0,011
<i>d11</i>	0,154	0,039	0,154	0,159	0,159	0,143
<i>a11</i>	-0,025	-0,019	-0,023	0,006	0,006	-0,054
<i>s</i>	0,756	0,176	0,725	0,542	0,353	0,164

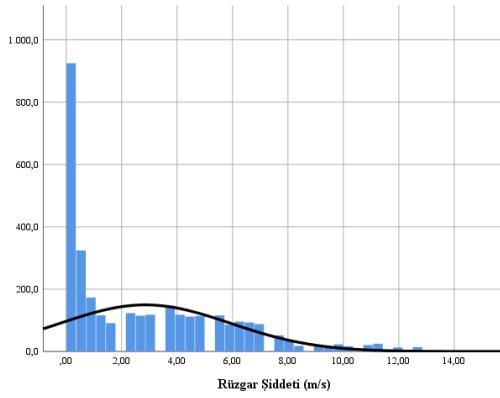
Çizelge A.9 : Eylül Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	0,001	-0,005	-0,001	-0,002	0,001	0,002
<i>d2</i>	0,014	0,005	0,006	0,008	-0,004	0,004
<i>d3</i>	-0,004	0,007	-0,008	0,004	-0,001	0,005
<i>d4</i>	0,038	0,021	0,031	0,002	0,038	0,010
<i>d5</i>	0,264	0,094	0,247	-0,069	0,158	0,014
<i>d6</i>	0,587	0,466	0,578	-0,213	0,511	0,151
<i>d7</i>	0,669	0,585	0,664	-0,194	0,544	0,001
<i>d8</i>	0,010	0,022	0,004	-0,006	0,022	0,009
<i>d9</i>	0,086	-0,064	0,050	-0,104	-0,061	-0,061
<i>d10</i>	0,031	0,003	0,014	-0,099	-0,079	-0,093
<i>d11</i>	0,106	-0,097	0,100	-0,149	0,155	-0,064
<i>a11</i>	0,024	0,177	0,040	0,169	0,176	-0,094
<i>s</i>	0,922	0,577	0,912	-0,152	0,658	-0,021


Çizelge A.10 : Aralık Ayı, Bir Gün Sonraki Güneş Radyasyonu (t + k) ile Giriş Verilerine Ait Alt Zaman Bileşenleri Arasındaki Korelasyon Değerleri

Bileşen	Rüzgar Şiddeti (t)	Güneş Radyasyonu (t)	UV Radyasyon İndis (t)	Toprak Üstü 5cm Sıcaklık (t)	Sıcaklık 2m (t)	Rüzgar Yönü (t)
<i>d1</i>	0,006	-0,002	0,000	0,003	-0,004	-0,010
<i>d2</i>	0,032	-0,003	-0,012	-0,019	-0,007	0,007
<i>d3</i>	0,090	0,003	0,065	0,008	-0,013	0,004
<i>d4</i>	0,131	0,026	0,033	-0,009	0,025	-0,027
<i>d5</i>	0,334	0,052	0,279	0,279	0,208	-0,035
<i>d6</i>	0,523	0,298	0,450	0,442	0,382	-0,027
<i>d7</i>	0,555	0,221	0,473	0,449	0,353	0,011
<i>d8</i>	-0,065	0,042	-0,057	0,032	0,046	-0,014
<i>d9</i>	-0,018	0,071	0,004	0,006	0,003	-0,011
<i>d10</i>	0,083	-0,057	0,078	-0,085	-0,086	0,017
<i>d11</i>	0,055	0,041	0,055	0,051	0,051	0,046
<i>a11</i>	-0,053	0,029	0,056	0,015	0,004	-0,060
<i>s</i>	0,817	0,202	0,624	0,512	0,321	-0,025

EK B




(a)




(b)

Şekil B.1 : 2016 Yılı Mart Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri

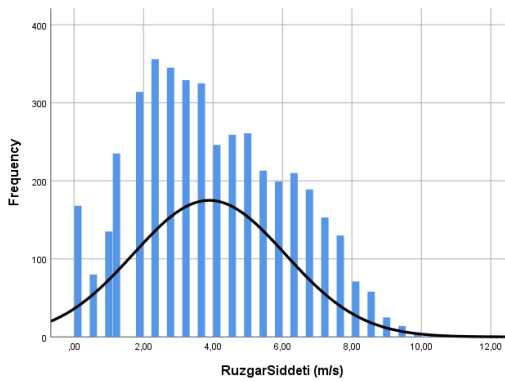


(a)




(b)

Şekil B.2 : 2016 Yılı Haziran Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri




(a)




(b)


Şekil B.3 : 2016 Yılı Eylül Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri





Şekil B.4 : 2016 Yılı Aralık Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Histogram Grafikleri





Şekil B.5 : 2016 Yılı Mart Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları




Şekil B.6 : 2016 Yılı Haziran Ayı (a) Rüzgar Şiddeti (b) Güneş Radyasyonu Boxplot Diyagramları





Şekil B.7 : 2016 Yılı Eylül Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları





Şekil B.8 : 2016 Yılı Aralık Ayı (a) Rüzgar Şiddeti, (b) Güneş Radyasyonu Boxplot Diyagramları




(a)




(b)




(c)




Şekil B.9 : Rüzgar Şiddeti (m/s), Mart Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



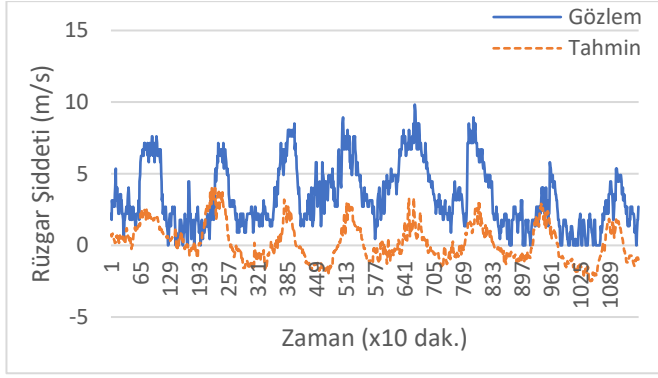
(a)





(b)





Şekil B.10 : Rüzgar Şiddeti (m/s), Haziran Ayı Test verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri




(a)




(b)





(c)





Şekil B.11 : Rüzgar Şiddeti (m/s), Eylül Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



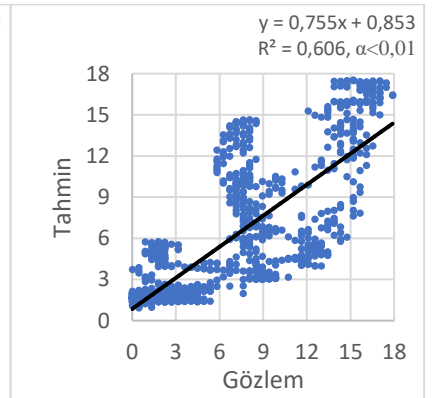
(a)




(b)




(c)




Şekil B.12 : Rüzgar Şiddeti (m/s), Aralık Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



(a)

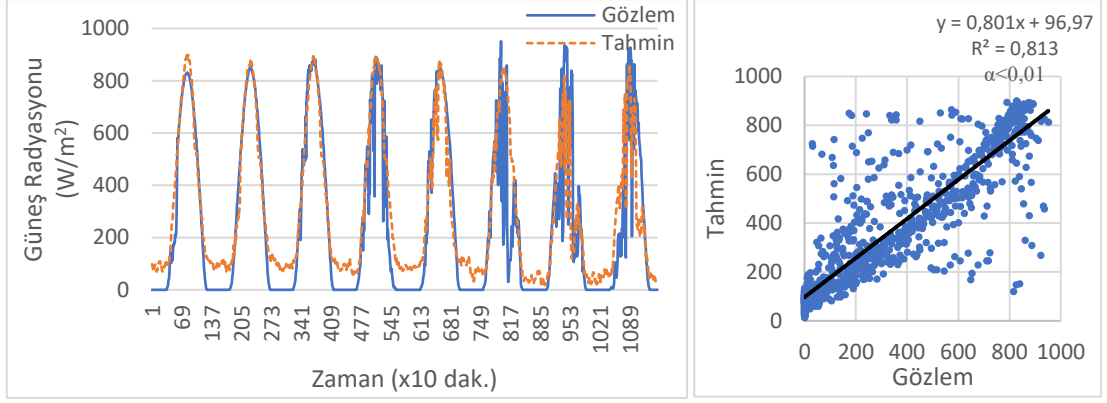


(b)




(c)


Şekil B.13 : Güneş Radyasyonu (W/m^2), Mart Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



(a)

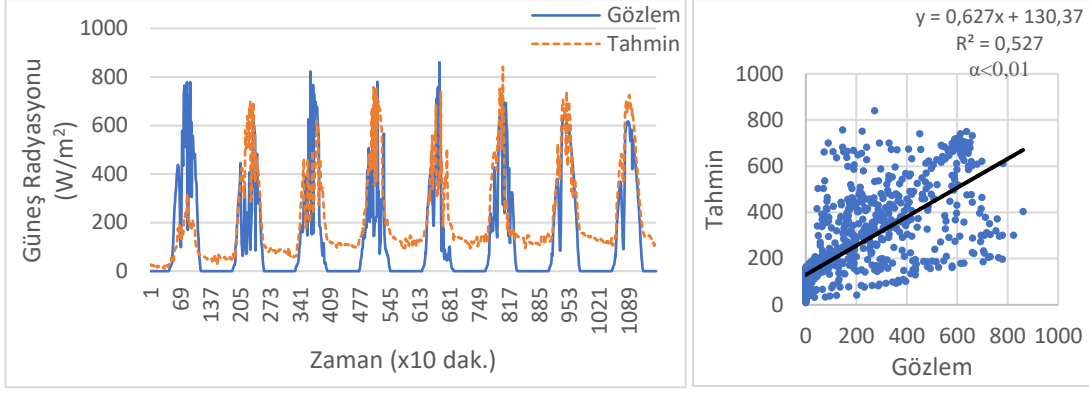


(b)




(c)


Şekil B.14 : Güneş Radyasyonu (W/m^2), Haziran Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



(a)




(b)




(c)


Şekil B.15 : Güneş Radyasyonu (W/m²), Eylül Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



(a)




(b)



(c)

Şekil B.16 : Güneş Radyasyonu (W/m²), Aralık Ayı Test Verileri (a) ÇLR (b) YSA (c) D-YSA Modellerinin Gözlem Tahmin Zaman Çizelgeleri ve Saçılma Grafikleri



Şekil B.17 : Tez Çalışması Akış Diyagramı

EK C

```
% YSA eğitme, test ve değerlendirme kodu
% Durhan GABRALI
clear;
clc;
num_hidden_neuron = 3;
%-----
data = xlsread('GrHaziranData.xlsx');
input_train = data(1:3024,1:6)';
target_train = data(1:3024,7)';
%-----
input_test = data(3025:4176,1:6)';
target_test = data(3025:4176,7)';
%-----
input_train_normalize = mapminmax(input_train,0,1);
[target_train_normalize,ps1] = mapminmax(target_train,0,1);
input_test_normalize = mapminmax(input_test,0,1);
[target_test_normalize,ps2] = mapminmax(target_test,0,1);
%-----
tic
net=newff(input_train_normalize,target_train_normalize,num_hidden_neuron);
net.layers{1}.transferFcn = 'tansig';
net.layers{2}.transferFcn = 'tansig';
net.trainFcn = 'trainlm';
net.performFcn='mse';
net.trainParam.lr = 0.2; %Learning rate 0.2 - 0.4
net.trainParam.mc = 0.8; %Momentum constant 0.6 - 0.8
% net.trainParam.mu = 0,001;
% net.trainParam.mu_dec = 0.3;
% net.trainParam.mu_inc = 3;
% net.trainParam.min_grad= 1e-6;
% net.trainParam.time = 60*25;
net.trainParam.max_fail = 1000;
net.trainParam.epochs = 3000;
[net,tr] =
train(net,input_train_normalize,target_train_normalize);
time2end = toc;
output_train_normalize = net(input_train_normalize);
output_test_normalize = sim(net,input_test_normalize);
plotregression(target_test_normalize,output_test_normalize);
%-----
output_train =
mapminmax('reverse',output_train_normalize,ps1);
output_test = mapminmax('reverse',output_test_normalize,ps2);
%-----
output_train = output_train';
output_test = output_test';
target_train = target_train';
target_test = target_test';
%-----
diff = (target_test - output_test);
diff_square = (target_test - output_test).^2;
MSE = mean(diff_square);
```

```

RMSE = MSE^(1/2);
MPE = mean((output_test - target_test)./mean(target_test));
MAPE = mean((abs(output_test -
target_test))./mean(target_test))*100;
CorrCoef = corr(output_test , target_test);
%-----
% perf = perform(net,input_test,output_test);
%-----
fprintf('Number of hidden layer neurons : %d , time:%f
\n',num_hidden_neuron , time2end);
fprintf('-----\n');
fprintf('MSE : %f \n', MSE);
fprintf('RMSE : %f \n', RMSE);
fprintf('MPE : %f \n', MPE);
fprintf('MAPE : %f \n', MAPE);
fprintf('R : %f \n', CorrCoef);
fprintf('R2 : %f \n', CorrCoef^2);

```

ÖZGEÇMİŞ



Ad-Soyad : Durhan GABRALI
Doğum Tarihi : 18.09.1977
Doğum Yeri : Kırcaali (Bulgaristan)
E-posta : gabralidurhan@gmail.com

Öğrenim Durumu

- **Lisans** : Marmara Üniversitesi – Teknik Eğitim Fakültesi
Bilgisayar ve Kontrol Sistemleri Öğretmenliği
- **Yüksek Lisans** : İstanbul Aydın Üniversitesi – Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği

Mesleki Deneyim

- **Çalıştığı Kurumlar ve Yıllar**
 - Takirdağ – Merkez Mesleki ve Teknik Anadolu Lisesi, 2001-2005
 - İstanbul – İsmet Aktar Mesleki ve Teknik Anadolu Lisesi, 2005-2015
 - İstanbul – Nahit Menteşe Mesleki ve Teknik Anadolu Lisesi, 2015-Halen

Yabancı Diller

- Bulgarca, İngilizce