

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**SAKARYA HAVZASINDAKİ KISA DÖNEM
METEOROLOJİK KURAKLIĞIN HİBRİT MODELLER
İLE TAHMİN EDİLMESİ**

**Hazırlayan
Ömer COŞKUN**

**Danışman
Doç. Dr. Hatice ÇITAKOĞLU**

Doktora Tezi

**Haziran 2023
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**SAKARYA HAVZASINDAKİ KISA DÖNEM
METEOROLOJİK KURAKLIĞIN HİBRİT MODELLER
İLE TAHMİN EDİLMESİ**

(Doktora Tezi)

**Hazırlayan
Ömer COŞKUN**

**Danışman
Doç. Dr. Hatice ÇITAKOĞLU**

**Haziran 2023
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Ömer COŞKUN

İmza

YÖNERGEYE UYGUNLUK

“Sakarya Havzasındaki Kısa Dönem Meteorolojik Kuraklığın Hibrit Modeller ile Tahmin Edilmesi” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesine uygun olarak hazırlanmıştır.

Hazırlayan

Ömer COŞKUN

İmza

Danışman

Doç. Dr. Hatice ÇITAKOĞLU

İmza

İnşaat Mühendisliği ABD Başkanı

Prof. Dr. A. Alper ÖNER

İmza

TEŞEKKÜR

Tüm yüksek lisans ve doktora öğrenimim süresince her türlü yardım ve fedakârlığı bana sağlayan, farklı fikirler ve önerilerle beni yönlendiren, çalışma azmimi ve umudumu her zaman diri tutan, beraber çalışmaktan büyük keyif aldığım danışmanım, değerli hocam Doç. Dr. Hatice ÇITAKOĞLU'na en içten teşekkürlerimi sunarım.

Tez aşamasında çalışmalarımı ilgili farklı görüş ve önerileri ile birlikte tecrübelerini de benden esirgemeyen Tez İzleme Komitesi üyesi saygıdeğer hocalarım Doç. Dr. Savaş BAYRAM ve Dr. Öğr. Üyesi Levent LATİFOĞLU'na teşekkür ederim.

Çalışmalarım esnasında desteklerini benden esirgemeyen Kayseri DSİ 12. Bölge Müdürlüğü Planlama Şube Müdürlüğü ile Barajlar ve HES Şube Müdürlüğünde beraber çalışmaktan mutluluk duyduğum tüm mesai arkadaşlarıma teşekkür ederim.

Sadece öğrenim hayatımda değil tüm hayatım boyunca maddi ve manevi destekleri ile benim bu günlere gelmemde çok büyük emekleri olan başta annem ve babam olmak üzere, asırlık bir çınar ağacı misali gölgesini hiçbir zaman üstümden eksik etmeyen benim güzel ve geniş ailemin her bir ferdine minnetlerimi sunarım.

Son olarak doktora çalışmalarımı sürdürdüğüm bu dört yıl boyunca desteğini, yardımını ve anlayışını benden esirgemeyen, moralimi yüksek tutarak beni umutlandıran eşim, başarılı diyetisyen Sümeyra COŞKUN ile çalışmalarım boyunca kendisini ihmal ettiğim, oyunlarına eşlik edemediğim canım oğlum Ömer Ozan COŞKUN'a en içten teşekkürlerimi sunarım.

Ömer COŞKUN

Haziran 2023, KAYSERİ

SAKARYA HAVZASINDAKİ KISA DÖNEM METEOROLOJİK KURAKLIĞIN HİBRİT MODELLER İLE TAHMİN EDİLMESİ

Ömer COŞKUN

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Haziran 2023
Danışman: Doç. Dr. Hatice ÇITAKOĞLU

ÖZET

Bu tez çalışması, Sakarya havzasındaki 10 adet meteoroloji istasyonuna ait uzun dönem yağış verileri kullanılarak havzadaki kısa dönem meteorolojik kuraklık değerlerinin tahmin edilmesine yöneliktir. Her bir istasyona ait aylık yağış verileri kullanılarak 1, 3, 6 ve 12 aylık kısa zaman ölçekleri için Standartlaştırılmış Yağış İndeksi (SYİ) kuraklık değerleri hesaplanmıştır. Hesaplanan SYİ kuraklık zaman serilerine, daha kısa ve daha yüksek özniteliklere sahip alt seriler elde edebilmek amacıyla Ayrık Dalgacık Dönüşümü (ADD), Ampirik Mod Ayırıştırma (AMA) ve Varyasyonel Mod Ayırıştırma (VMA) ön işleme teknikleri uygulanmıştır. Tahmin modellerinde bağımsız modeller olarak Yapay Sinir Ağları, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi, Gauss Süreç Regresyonu, Destek Vektör Makine Regresyonu makine öğrenmesi yöntemleri ile Uzun-Kısa Süreli Bellek (UKSB) derin öğrenme yöntemi ele alınmıştır. Bu yöntemlere ADD, AMA ve VMA ön işleme teknikleri dâhil edilerek hibrit modeller elde edilmiş ve tüm bağımsız ve hibrit modellerin tahmin başarıları performans kriterlerine göre birbiri ile karşılaştırılmıştır. Test sonuçlarına göre, hibrit modellerin tahmin performansları bağımsız modellere göre oldukça üstündür. Ancak, bu tez çalışmasında UKSB yöntemi ile elde edilen bağımsız tahmin modelleri, yüksek tahmin performansları göstermiştir. Bundan dolayı kuraklık zaman serilerine farklı ön işleme teknikleri uygulanmadan da UKSB derin öğrenme yöntemi kullanılarak modellerden yüksek tahmin performanslarının elde edilebileceği sonucuna ulaşılmıştır. Ayrıca UKSB yönteminin hibrit modelleri, diğer makine öğrenmesi modellerine göre de daha başarılıdır. Ön işleme teknikleri arasında ise VMA tekniği, diğer tekniklere göre daha çok ön plana çıkmıştır.

Anahtar Kelimeler: Meteorolojik kuraklık, Sakarya havzası, SYİ, Makine öğrenmesi, Derin öğrenme, Ön işleme teknikleri, Hibrit modeller

PREDICTION OF SHORT-TERM METEOROLOGICAL DROUGHT IN THE SAKARYA BASIN WITH HYBRID MODELS

Ömer COŞKUN

Erciyes University, Graduate School of Natural and Applied Sciences

PhD Thesis, June 2023

Supervisor: Assoc. Prof. Dr. Hatice ÇITAKOĞLU

ABSTRACT

This thesis is aimed at predicting short-term meteorological drought values in the basin by using long-term precipitation data from 10 meteorological stations in the Sakarya basin. Standardized Precipitation Index (SPI) drought values were calculated for short time scales of 1, 3, 6 and 12 months using monthly precipitation data of each station. Discrete Wavelet Transform (DWT), Empirical Mode Decomposition (EMD) and Variational Mode Decomposition (VMD) pre-processing techniques were applied to the calculated SPI drought time series in order to obtain sub-series with shorter and higher features. Artificial Neural Networks, Adaptive Neuro-Fuzzy Inference System, Gaussian Process Regression, Support Vector Machine Regression machine learning methods and Long Short-Term Memory (LSTM) deep learning method were considered as stand-alone models in drought prediction models. The hybrid models were obtained by incorporating DWT, EMD and VMD pre-processing techniques into these methods, and the prediction successes of all stand-alone and hybrid models were compared with each other according to performance criteria. The findings indicated that, the prediction performance of the hybrid models is quite superior to that of the stand-alone models. However, stand-alone prediction models obtained by the LSTM method also showed high prediction performances. Therefore, it has been concluded that high prediction performances can be obtained from the models by using the LSTM deep learning method without applying different pre-processing techniques to the drought time series. Moreover, hybrid models of the LSTM method are more successful than other machine learning models. Among the pre-processing techniques, the VMA technique overperformed than the other techniques.

Keywords: Meteorological drought, Sakarya basin, SPI, Machine learning, Deep learning, Pre-processing techniques, Hybrid models

İÇİNDEKİLER

SAKARYA HAVZASINDAKİ KISA DÖNEM METEOROLOJİK KURAKLIĞIN HİBRİT MODELLER İLE TAHMİN EDİLMESİ

BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR VE SEMBOLLER.....	xii
TABLolar LİSTESİ.....	xvi
ŞEKİLLER LİSTESİ	xix
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. İklim ve iklim değışikliğı	5
1.2. İklim değışikliğı-kuraklık ilişkisi.....	8
1.3. Kuraklık.....	10
1.3.1. Kuraklığa Neden Olan Meteorolojik Etkenler.....	11
1.3.2. Kuraklık Sınıflandırması	12
1.3.2.1. Meteorolojik Kuraklık.....	13
1.3.2.2. Tarımsal Kuraklık	14
1.3.2.3. Hidrolojik Kuraklık.....	14
1.3.2.4. Sosyo-ekonomik Kuraklık.....	15
1.3.2.5. Kısa ve Uzun Süreli Kuraklık	16
1.3.3. Kuraklık İndisleri	16
1.3.3.1. Meteorolojik Kuraklık İndisleri	17
1.3.3.2. Tarımsal Kuraklık İndisleri.....	20

1.3.3.3. Hidrolojik Kuraklık İndisleri	21
1.4. Literatür Özetleri.....	22
1.4.1. Dünya’da Yapılan Kuraklık Çalışmaları	23
1.4.2. Türkiye’de Yapılan Kuraklık Çalışmaları	29
1.5. Problem Durumu	36
1.6. Araştırmanın Amacı	37
1.7. Araştırmanın Önemi.....	38

2. BÖLÜM

MATERYAL VE YÖNTEM

2.1. Materyal.....	39
2.1.1. Çalışma Alanı	39
2.1.2. Veri Temini ve Seçimi.....	42
2.2. Yöntem	45
2.2.1. Homojenlik ve Durağanlık Analizleri	45
2.2.1.1. Homojenlik, Durağanlık ve Bağımsızlık Testleri	46
2.2.1.1.1. Standart Normal Homojenlik Testi (SNHT)	47
2.2.1.1.2. Von Neumann Testi (VNT)	48
2.2.1.1.3. Mann-Whitney u Testi (MWT).....	49
2.2.1.1.4. Genişletilmiş Dickey-Fuller Testi (GDFT).....	50
2.2.2. Otokorelasyon Fonksiyonu.....	51
2.2.3. Kuraklık Analizi.....	52
2.2.3.1. Standartlaştırılmış Yağış İndeksi (SYİ)	52
2.2.3.2. SYİ’nin avantajları	55
2.2.4. Drought Indices Calculator (DrinC) Yazılımı.....	55
2.2.5. Veri Ön İşleme Teknikleri.....	57
2.2.5.1. Dalgacık Dönüşümü (DD)	58
2.2.5.1.1. Sürekli Dalgacık Dönüşümü (SDD).....	64
2.2.5.1.2. Ayrık Dalgacık Dönüşümü (ADD).....	65
2.2.5.1.3. Dalgacık Aileleri.....	69
2.2.5.2. Ampirik Mod Ayırıştırma (AMA)	71
2.2.5.3. Varyasyonel Mod Ayırıştırma (VMA)	73
2.2.6. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme.....	77

2.2.6.1. Yapay Zekâ	77
2.2.6.2. Makine Öğrenmesi	78
2.2.6.3. Derin Öğrenme	83
2.2.7. Çalışmada Kullanılan Makine ve Derin Öğrenme Yöntemleri	85
2.2.7.1. Yapay Sinir Ağları (YSA).....	85
2.2.7.1.1. Yapay Sinir Ağının Yapısı.....	86
2.2.7.1.2. Yapay Sinir Ağlarının Sınıflandırması	89
2.2.7.1.3. Geri Yayılm Algoritması	90
2.2.7.1.4. Levenberg-Marquardt Algoritması.....	91
2.2.7.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇŞ)	92
2.2.7.2.1. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (USBÇŞ) Yapısı	94
2.2.7.3. Destek Vektör Makineleri (DVM)	96
2.2.7.3.1. Destek Vektör Makine Regresyonu (DVMR).....	99
2.2.7.4. Gauss Süreç Regresyonu (GSR)	103
2.2.7.5. Uzun-Kısa Süreli Bellek (UKSB)	107
2.2.8. Model Performansı Değerlendirme Kriterleri	112
2.2.9. Model Gelişimi.....	113

3. BÖLÜM

BULGULAR

3.1. Sakarya Havzası Meteoroloji İstasyonları Yağış Verilerinin İstatistiksel.....	129
Özellikleri.....	129
3.2. Sakarya Havzası Meteoroloji İstasyonları Yağış Verilerinde Homojenlik, ...	130
Durağanlık ve Bağımsızlık Testleri	130
3.3. DrinC Yazılımı ile SYİ Kuraklık Değerlerinin Hesaplanması	131
3.3.1. SYİ Kuraklık Değerlendirmesi	132
3.4. Otokorelasyon Varlığının Araştırılması	139
3.5. Ayrık Dalgacık Dönüşümü Sonuçları	142
3.6. Ampirik Mod Ayrıştırması (AMA) Sonuçları.....	150
3.7. Varyasyonel Mod Ayrıştırması (VMA) Sonuçları	152
3.8. Bağımsız ve Hibrit Tahmin Model Sonuçlarının Elde Edilmesi.....	153

4. BÖLÜM**TARTIŞMA-SONUÇ ve ÖNERİLER**

4.1. Tartışma	190
4.2. Sonuç ve Öneriler	198
KAYNAKÇA	202
EKLER.....	222
ÖZGEÇMİŞ.....	233



KISALTMALAR VE SEMBOLLER

ADD	: Ayrık Dalgacık Dönüşümü
AGA	: Aşırı Gradyan Artırma
AGİ	: Akım Gözlem İstasyonu
AKİ	: Akım Kuraklık İndisi
AMA	: Ampirik Mod Ayırıştırma
ARIMA	: Autoregressive Integrated Moving Average
BM	: Birleşmiş Milletler
BM	: Bulanık Mantık
CH₄	: Metan
ChatGPT	: Chat Generative Pre-Trained Transformer
CO₂	: Karbondioksit
ÇDURE	: Çok Değişkenli Uyarlanabilir Regresyon Eğrisi
ÇİBSA	: Çok Katmanlı İleri Beslemeli Sinir Ağları
ÇKA	: Çok Katmanlı Algılayıcı
ÇZİ	: Çin Z İndeksi
DD	: Dalgacık Dönüşümü
DİA	: Derin İnanç Ağları
DMEY	: Discrete Approximation of Meyer
DÖ	: Derin Öğrenme
DSA	: Derin Sinir Ağları
DVM	: Destek Vektör Makinesi
DVMR	: Destek Vektör Makine Regresyonu
DVMS	: Destek Vektör Makine Sınıflandırması
DWT	: Durbin-Watson Testi
EA	: Ekstra Ağaç
EKİ	: Efektif Kuraklık İndeksi
ESA	: Evrişimli Sinir Ağları
FAO	: Birleşmiş Milletler Gıda ve Tarım Örgütü
FD	: Fourier Dönüşümü
GDFT	: Genişletilmiş Dickey-Fuller Testi

GP	: Genetik Programlama
GRSA	: Genel Regresyon Sinir Ağı
GRU	: Gated Recurrent Unit
GS	: Güney Salınımı
GSİ	: Güney Salınım İndeksi
HKİ	: Hibrit Kuraklık İndeksi
IPCC	: Hükümetlerarası İklim Değişikliği Paneli
İBSA	: İleri Beslemeli Sinir Ağları
İMF	: İçsel Mod Fonksiyonu
KAS	: Kuzey Atlantik Salınımı
KBM	: Kısıtlı Boltzmann Makineleri
KEYK	: k-En Yakın Komşu
KKİ	: Kuraklık Keşif İndisi
KO	: Kuraklık Oranı
KOKH	: Kök Ortalama Karesel Hata
KPSS	: Kwiatkowski-Phillips-Schmidt ve Shin testi
KSF	: Kalman Smooth Filtreleme
KSFD	: Kısa Süreli Fourier Dönüşümü
LGP	: Lineer Genetik Programlama
LR	: Lojistik Regresyon
MĞİ	: Meteoroloji Gözlem İstasyonu
MGM	: Meteoroloji Genel Müdürlüğü
MNİ	: Mahsul Nem İndisi
MÖ	: Makine Öğrenmesi
MWT	: Mann-Whitney Testi
N₂O	: Diazot monoksit
NOAA	: ABD Ulusal Okyanus ve Atmosfer Yönetimi
NSE	: Nash-Sutcliffe Etkinliği
NYİYİ	: Normal Yağış Yüzdesi İndisi
Oİ	: Overall Index
OK	: Otomatik Kodlayıcılar
OKH	: Ortalama Karesel Hata
OMH	: Ortalama Mutlak Hata

ÖDRO	: Önyargı Düzeltmeli Rastgele Orman
PET	: Potansiyel Evapotranspirasyon
PHKİ	: Palmer Hidrolojik Kuraklık İndisi
PKŞİ	: Palmer Kuraklık Şiddet İndisi
ppm	: Parts per million
R²	: Determinasyon Katsayısı
ReLU	: Rectified Linear Unit
RMSProp	: Root Mean Squared Propagation
RO	: Rastgele Orman
SAİ	: Standartlaştırılmış Akış İndisi
SDD	: Sürekli Dalgacık Dönüşümü
SDTİ	: Standartlaştırılmış Depolama Temin İndisi
SGDM	: Stochastic Gradient Descent with Momentum
SNHT	: Standart Normal Homojenlik Testi
SYEİ	: Standartlaştırılmış Yağış Evapotranspirasyon İndisi
SYİ	: Standartlaştırılmış Yağış İndeksi
SYSİ	: Standartlaştırılmış Yeraltı Suyu İndisi
TBA	: Temel Bileşen Analizi
TNAİ	: Toprak Nemi Anomali İndisi
TSA	: Tekrarlayan Sinir Ağları
TÜİK	: Türkiye İstatistik Kurumu
UKSB	: Uzun-Kısa Süreli Bellek
USBÇS	: Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
VC	: Vapnik-Chervonenkis Teorisi
VMA	: Varyasyonel Mod Ayrıştırma
VNT	: Von-Neumann Testi
VOY	: Vektör Otoregresif Yaklaşım
YK	: Yağış Kuyrukları
YSA	: Yapay Sinir Ağları
YSTİ	: Yüzey Suyu Temini İndisi
°C	: Santigrat derece
$T(k)$	: Test istatistiği
H₀	: Kurulan hipotez

H_a	: Karşı hipotez
r_k	: Otokorelasyon katsayısı
φ	: Ölçekleme fonksiyonu
ψ	: Dalgacık fonksiyonu
C	: Sürekli dalgacık dönüşüm katsayısı
$g(k)$	: Yüksek geçiren filtre
$h(k)$	: Alçak geçiren filtre
K	: Toplam mod sayısı
λ	: Lagrange Çarpanı
ε	: Sapma değeri
w	: Ağırlık vektörü
b	: Bias değeri
ξ	: Esneklik değişkeni
$R(\alpha)$	: Gerçek risk
$R_{den}(\alpha)$	: Deneysel risk
k_*	: Kovaryans vektörü
C_t	: Bellek hücresi

TABLOLAR LİSTESİ

Tablo 2.1.	Meteoroloji gözlem istasyonları (MGİ) karakteristik bilgileri	43
Tablo 2.2.	SNHT %99 ve %95 güven aralıklarına göre belirlenen T_0 limit değerleri	48
Tablo 2.3.	VNT %99 ve %95 güven aralıklarına göre belirlenen NVN limit değerleri	49
Tablo 2.4.	SYİ kuraklık sınıflandırması.....	55
Tablo 2.5.	Çekirdek tipleri ve fonksiyonları	103
Tablo 2.6.	USBÇS tahmin modeli parametreleri	119
Tablo 2.7.	YSA tahmin modeli parametreleri.....	122
Tablo 2.8.	DVMR tahmin modeli parametreleri.....	123
Tablo 2.9.	GSR tahmin modeli parametreleri	126
Tablo 2.10.	UKSB tahmin modeli parametreleri	127
Tablo 3.1.	Meteoroloji gözlem istasyonları (MGİ) istatistiksel bilgileri	129
Tablo 3.2.	İstasyonlara ait homojenlik, duranlık ve bağımsızlık test sonuçları.....	131
Tablo 3.3.	Sakarya SYİ-1 kuraklık değerleri izleme tablosu	133
Tablo 3.4.	İstasyonların aylara göre SYİ-1 kuraklık sınıfları oluşum sayıları ve yüzdeleri.....	137
Tablo 3.5.	İstasyonların yıllara göre SYİ-12 kuraklık sınıfları oluşum sayıları ve yüzdeleri.....	138
Tablo 3.6.	Sakarya SYİ-1'e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması	143
Tablo 3.7.	Sakarya SYİ-3'e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması	144
Tablo 3.8.	Sakarya SYİ-6'a ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması	145
Tablo 3.9.	Sakarya SYİ-12'e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması	146
Tablo 3.10.	Sakarya SYİ-1 için dmey dalgacık ailesine sahip ADD-USBÇS hibrit modeli gecikme zamanları ve dalgacık bant seviyelerinin karşılaştırması	148

Tablo 3.11. Sakarya istasyonu optimum gecikme zamanları için ADD-USBÇS hibrit modelinde dalgacık ailelerinin başarı sıraları	149
Tablo 3.12. Sakarya istasyonu her bir zaman ölçeği için AMA-USBÇS hibrit model performansları	151
Tablo 3.13. Sakarya istasyonu her bir zaman ölçeği için VMA-USBÇS hibrit model performansları	152
Tablo 3.14. Sakarya istasyonu SYİ-1 tahmin model performanslarının karşılaştırması	154
Tablo 3.15. Sakarya istasyonu SYİ-3 tahmin model performanslarının karşılaştırması	154
Tablo 3.16. Sakarya istasyonu SYİ-6 tahmin model performanslarının karşılaştırması	155
Tablo 3.17. Sakarya istasyonu SYİ-12 tahmin model performanslarının karşılaştırması	155
Tablo 3.18. Ankara istasyonu SYİ-1 tahmin model performanslarının karşılaştırması	158
Tablo 3.19. Ankara istasyonu SYİ-3 tahmin model performanslarının karşılaştırması	158
Tablo 3.20. Ankara istasyonu SYİ-6 tahmin model performanslarının karşılaştırması	159
Tablo 3.21. Ankara istasyonu SYİ-12 tahmin model performanslarının karşılaştırması	159
Tablo 3.22. Kütahya istasyonu SYİ-1 tahmin model performanslarının karşılaştırması	160
Tablo 3.23. Kütahya istasyonu SYİ-3 tahmin model performanslarının karşılaştırması	161
Tablo 3.24. Kütahya istasyonu SYİ-6 tahmin model performanslarının karşılaştırması	161
Tablo 3.25. Kütahya istasyonu SYİ-12 tahmin model performanslarının karşılaştırması	162
Tablo 3.26. Emirdağ istasyonu SYİ-1 tahmin model performanslarının karşılaştırması	163

Tablo 3.27. Emirdağ istasyonu SYİ-3 tahmin model performanslarının karşılaştırması	163
Tablo 3.28. Emirdağ istasyonu SYİ-6 tahmin model performanslarının karşılaştırması	164
Tablo 3.29. Emirdağ istasyonu SYİ-12 tahmin model performanslarının karşılaştırması	164
Tablo 3.30. Bolu istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	166
Tablo 3.31. Polatlı istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	167
Tablo 3.32. Geyve istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	168
Tablo 3.33. Sivrihisar istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	170
Tablo 3.34. Ilgın istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	171
Tablo 3.35. Yunak istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması	172

ŞEKİLLER LİSTESİ

Şekil 1.1.	Etkilediği alanlara göre kuraklık sınıflandırması	13
Şekil 2.1.	Sakarya havzasının Türkiye’deki konumu	39
Şekil 2.2.	Sakarya havzasının alt havzaları	40
Şekil 2.3.	Meteoroloji gözlem istasyonlarının (MGİ) havzadaki konumları.....	42
Şekil 2.4.	Sakarya MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği	44
Şekil 2.5.	Ankara MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği	44
Şekil 2.6.	Kütahya MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği.....	44
Şekil 2.7.	Bolu MGİ 1960–2017 dönemi yıllık toplam yağışlar grafiği	44
Şekil 2.8.	DrinC yazılımı ana menü, veri yönetimi ve işlem sekmesi.....	57
Şekil 2.9.	KSFD pencere fonksiyonunun uygulanması	59
Şekil 2.10.	FD (solda) ve KSFD (sağda) temsili çözünürlükleri.....	60
Şekil 2.11.	FD sinüs fonksiyonu ve DD dalgacık fonksiyonu.....	61
Şekil 2.12.	a ölçek parametresine göre sinüs fonksiyonu ve dalgacık fonksiyonu ...	64
Şekil 2.13.	ADD ile yapılan n . dereceden ardışık ayrıştırma işlemi.....	68
Şekil 2.14.	Yapay zekâ, makine öğrenmesi ve derin öğrenme hiyerarşisi	78
Şekil 2.15.	Makine öğrenmesi aşamaları	80
Şekil 2.16.	Makine öğrenmesine ait öğrenme türleri.....	80
Şekil 2.17.	YSA katman yapısı.....	87
Şekil 2.18.	Yapay sinir hücresinin bölümleri	87
Şekil 2.19.	Yapay sinir ağlarının sınıflandırması	89
Şekil 2.20.	Bulanık mantık bölümleri.....	93
Şekil 2.21.	İki girişli USBÇS genel yapısı	95
Şekil 2.22.	DVM sınıflandırma durumu	98
Şekil 2.23.	DVMR’nin sapma değerli gösterimi	101
Şekil 2.24.	TSA mimarisi	108
Şekil 2.25.	UKSB mimarisi	109
Şekil 2.26.	Çalışmanın akış şeması.....	114
Şekil 2.27.	dmey dalgacık ailesi ile 3 girişli 3. bant seviyesine göre yapılan dalgacık dönüşümü.....	118
Şekil 2.28.	2D bant seviyesine göre yapılan AMA örnek dönüşümü.....	120

Şekil 2.29.	2D bant seviyesine göre yapılan VMA örnek dönüşümü.....	120
Şekil 2.30.	YSA tahmin modeli öğrenme süreci	122
Şekil 2.31.	DVMR yöntemi ile optimum hiper düzlemin ve minimum hata oranının bulunmasına ait örnek model	124
Şekil 2.32.	UKSB tahmin modeli örnek öğrenme süreci.....	128
Şekil 3.1.	Sakarya SYİ-1 kuraklık zaman serisi grafiği.....	134
Şekil 3.2.	Sakarya SYİ-1 aylara göre kuraklık sınıfları oluşumu yüzde grafiği....	134
Şekil 3.3.	Sakarya SYİ-12 kuraklık zaman serisi grafiği.....	136
Şekil 3.4.	Sakarya SYİ-12 kuraklık değerleri ve kuraklık sınıfları grafiği.....	136
Şekil 3.5.	Sakarya SYİ-12 yıllara göre kuraklık sınıfları oluşumu yüzde grafiği .	136
Şekil 3.6.	Sakarya istasyonu SYİ-1 otokorelasyon fonksiyonu grafiği.....	140
Şekil 3.7.	Sakarya istasyonu SYİ-3 otokorelasyon fonksiyonu grafiği.....	140
Şekil 3.8.	Sakarya istasyonu SYİ-6 otokorelasyon fonksiyonu grafiği.....	141
Şekil 3.9.	Sakarya istasyonu SYİ-12 otokorelasyon fonksiyonu grafiği.....	141
Şekil 3.10.	Sakarya istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait dağılım ve zaman serisi grafikleri	174
Şekil 3.11.	Ankara istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait dağılım ve zaman serisi grafikleri	176
Şekil 3.12.	Kütahya istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait dağılım ve zaman serisi grafikleri	178
Şekil 3.13.	Sakarya istasyonu SYİ-1 için her bir yöntemle ait en iyi sonucu veren tahmin modellerine ait Taylor diyagramı	180
Şekil 3.14.	Ankara istasyonu SYİ-1 için her bir yöntemle ait en iyi sonucu veren modellere ait Taylor diyagramı	180
Şekil 3.15.	Kütahya istasyonu SYİ-1 için her bir yöntemle ait en iyi sonucu veren modellere ait Taylor diyagramı	181
Şekil 3.16.	Emirdağ istasyonu SYİ-1 için her bir yöntemle ait en iyi sonucu veren modellere ait Taylor diyagramı	182
Şekil 3.17.	Bolu istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	182
Şekil 3.18.	Polatlı istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	183

Şekil 3.19.	Geyve istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	183
Şekil 3.20.	Sivrihisar istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	184
Şekil 3.21.	İlgın istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	184
Şekil 3.22.	Yunak istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı	185
Şekil 3.23.	Sakarya ve Ankara istasyonları SYİ-12 için en iyi test sonucunu veren beş modele ait radar grafikleri.....	186
Şekil 3.24.	Kütahya ve Emirdağ istasyonları SYİ-12 için en iyi test sonucunu veren beş modele ait radar grafikleri.....	186
Şekil 3.25.	Bolu ve Polatlı istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri.....	187
Şekil 3.26.	Geyve ve Sivrihisar istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri.....	188
Şekil 3.27.	İlgın ve Yunak istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri.....	189

GİRİŞ

Dünya milletleri tarih boyunca çeşitli savaşlar, afetler ve salgın vakaları ile karşılaşmış ve bunların acı etkilerine de belirli zaman dilimleri boyunca maruz kalmıştır. İnsan türü, geçmişte yaşanan acı tecrübelerden dersler çıkartıp bunlara göre bir yaşam planı oluşturduğunda buna paralel olarak refah ve medeniyet çitasını daha da yukarı çekmiş, tersi durumda ise her zaman maddi ve manevi kayıplarla yüzleşmek zorunda kalmıştır. Bilindiği üzere insan türü diğer türlere göre zor şartlara daha kolay uyum sağlayabilmesi sayesinde doğada varlığını korumuş ve günden güne kendini geliştirebilmiştir. İnsan, doğanın kendisine sunduğu ve sunacağı kaynakların sonsuz olduğunu düşünerek bu kaynaklara yönelik gerekli tedbirleri almadığı sürece karşılaşacağı tüm olumsuz vakalarda yine çeşitli sıkıntılar yaşayacaktır. Son dönemde insanoğlunu en çok meşgul eden ve üzerinde çeşitli tartışmaların halen devam ettiği liste başı konulardan biri küresel iklim değişikliğidir. 2023 yılı Ocak ayında yayınlanan Dünya Ekonomik Forumu Küresel Risk Raporunda; önümüzdeki 10 yılda dünyanın karşılaşacağı en büyük on tehlikeden altısının küresel iklim değişikliği ve buna bağlı olarak ortaya çıkacak olan çevresel sorunlar olduğu belirtilmiştir [1]. Küresel iklim değişikliğinin etkilerini gün geçtikçe tüm dünya ve canlılar farklı zamanlarda, farklı yerlerde ve farklı şekillerde hissetmeye başlamışlardır. İklim değişikliğine bağlı olarak ortaya çıkan küresel ısınmanın hidrolojik döngü içerisinde yer alan hidrometeorolojik parametreleri doğrudan etkilediği ve bu nedenle sistemin dengesini bozduğu kaçınılmaz bir gerçektir. Dünyanın bazı noktalarında aşırı yağışlara bağlı sel felaketleri gözlemlenirken, bazı noktalarında ise şiddetli kuraklıklar görülmektedir. Bu şekilde meydana gelen doğa olayları uzun periyotlarda ve geniş alanlarda görülebileceği gibi kısa periyotlarda ve dar alanlarda da yıkıcı etkilerini gösterebilmektedir. Örneğin taşkın gibi doğal felaketler aniden ortaya çıkıp dar bir bölgeye etki ederken, kuraklık gibi doğal felaketler ise yavaş yavaş ortaya çıkar ve geniş bir alanda etkisini gösterir. Kuraklık, bu özelliğinden dolayı oldukça sinsi ve tehlikeli bir doğal felaket olarak görülmektedir. Tez çalışmasının ana konusunu oluşturan ve ilerleyen bölümlerde daha detaylı bir şekilde ele alınacak olan

kuraklık kavramı, genel manada “Uzun bir dönem boyunca ve geniş bir bölgede yağışların normal seviyelerine göre önemli ölçüde düşmesi sonucu su varlığında ortaya çıkan azalma veya eksiklik” olarak tanımlanır [2]. Kuraklık felaketi, insan türü başta olmak üzere tüm canlıların temel gereksinimlerine erişimini zorlaştırır, doğanın süregelen dengesini bozar ve yaşamın birçok alanında da bu etkileri ortaya çıkar. Yetersiz yağışlarla başlayan kuraklık süreci, bitkinin suya erişememesi nedeniyle tarımsal faaliyetleri olumsuz etkiler ve gıda arz-talep dengesini bozar. Aynı zamanda insan türünün ve diğer canlıların içme-kullanma suyu ihtiyacının da karşılanamadığı durumda hem suya hem de gıdaya erişim zora gireceği için susuzluklar ve açlıklar görülmeye başlar. Kuraklık devam ettiği sürece, bu susuzluk ve açlık durumlarına bağlı olarak kıtlık ortaya çıkar ve büyük boyutlu ölümler gözlemlenebilir. Kuraklık olayı ciddi sosyo-ekonomik problemlere neden olan yıkıcı bir doğal afettir [3].

Diğer doğal afetlere nazaran kuraklık birçok sektörü doğrudan etkilediği için etkisinin daha uzun sürdüğü rahatlıkla söylenebilir. Aynı zamanda kuraklığın tespiti ve izlenmesi de oldukça zor bir süreçtir. Bu nedenle insanoğlu sahip olduğu kaynakların potansiyelini bilerek kuraklık olayını hem küçük ölçeklerde hem de küresel ölçekte sağlıklı bir şekilde tespit etmek zorundadır. İşte bu noktada bilim ve teknolojiadaki gelişmeler de dikkate alınarak geçmişteki verilerden kuraklığa etki eden parametrelerle kuraklık arasındaki ilişki doğru bir şekilde ortaya konulmalı, mevcut durum ile gelecekte karşılaşılabilecek olan muhtemel kuraklık durumları öngörülebilmelidir. Bu sayede hem yerel hem de merkezi yönetimlerin kuraklığa yönelik projeksiyonlar geliştirebilmesi mümkün olabilecek, gerçekçi ve entegre politikalar çerçevesinde çeşitli önlemler alınabilecek, başta insan hayatı olmak üzere tüm canlı hayatını olumsuz etkileyen bu yıkıcı afetle mücadele daha da kolaylaşacaktır.

Bu çalışmada ele alınan meteorolojik kuraklık, karmaşık kuraklık sürecinin ilk aşaması olduğundan bölgesel anlamda kuraklığın genel gidişatı ile ilgili olarak çeşitli fikirler sunabilmektedir. Meteorolojik kuraklığın erken tespiti; diğer kuraklık türleri olan tarımsal kuraklık, hidrolojik kuraklık ve sosyo-ekonomik kuraklığın yıkıcı etkilerini önleyebilmek adına oldukça önem arz etmektedir. Kuraklık sürecinde tüm fiziksel, meteorolojik, iklimsel ve beşeri etkenler göz önünde bulundurularak bir değerlendirme yapmak zordur. Bu yüzden kuraklığın saptanıp kategorize edilmesinde, zamana bağlı gözlemlenen meteorolojik ve iklimsel normallerin dikkate alınması gerekir. Kuraklığın

konumu, süresi, şiddeti, frekansı ve periyodu gibi bazı özel karakteristikler çeşitli kuraklık indisleri veya göstergelerle belirlenip kategorize edilebilmektedir [4].

Son dönemlerde hidrometeoroloji alanında yapılan tahmin çalışmaları gelişen teknoloji ve yeni tekniklere bağlı olarak popüler bir araştırma alanı olmuştur. Hidrometeorolojik tahmin çalışmaları içerisinde ise yapay zekâ teknikleri ve alt kategorisinde yer alan makine öğrenmesi yöntemleri literatürde sıklıkla tercih edilen yöntemlerdir. Yine yapay zekâ ve makine öğrenmesi alt kategorisinde yer alan derin öğrenme algoritmaları da bu alanda yeni yeni kullanılmaya başlanmıştır. Tüm bu yöntemler bağımsız bir şekilde kullanılabildiği gibi diğer yöntemlerle de beraber kullanılıp her bir yöntemin seçkin özelliği ortaya çıkartılarak daha bütüncül ve etkili modeller oluşturulabilmektedir. Bu tarz modeller ‘hibrit modeller’ olarak adlandırılmakta olup, yine son dönemlerde çok tercih edilen bir yaklaşımdır. Esasen hibrit yöntemlerle oluşturulan tahmin modellerinin performansları klasik yöntemlere göre daha başarılı olup, hibrit yöntemler kısa sürelerde ve geniş perspektifte sonuçlar verebilmektedirler.

Bu tez çalışmasının birinci bölümünde; iklim değişikliği, kuraklık, iklim değişikliği-kuraklık ilişkisi, kuraklığa neden olan meteorolojik etmenler, kuraklık türleri, kuraklık indisleri ile kuraklığın belirlenmesine yönelik genel bilgiler sunulacak olup, kuraklık ve kuraklık tahmini ile ilgili literatür özetleri sunulacaktır. Aynı zamanda problem durumu, araştırmanın amacı ve önemi ortaya konulacaktır.

Çalışmanın ikinci bölümünde; çalışma alanı olan Sakarya havzası ve özellikleri başta olmak üzere iklimsel ve meteorolojik koşullar, veri seçimi, istasyonların karakteristik özellikleri gibi materyaller hakkında bilgiler verilecektir. Tez çalışmasında ele alınacak olan Standartlaştırılmış Yağış İndeksi (SYİ) kuraklık değerlerinin hesabı, DrinC yazılımı, homojenlik, durağanlık ve bağımsızlık testleri, otokorelasyon analizi, veri ön işleme teknikleri, makine öğrenmesi ve derin öğrenme yöntemleri hakkında detaylı bilgiler verilecektir. Yine bu bölümde, çalışmanın metodolojisi ve model gelişimi ortaya konulacaktır. Tahmin modellerinde ele alınacak olan yöntemler için tercih edilen model parametreleri tanıtılacaktır.

Çalışmanın üçüncü bölümünde; kuraklık tahminine yönelik yapılan tüm analizlerden elde edilen bulgular ortaya konulacak olup tahmin modellerine ait sonuçlar, performans

kriterlerine göre saçılma ve zaman serisi grafikleri, Taylor diyagramları ve radar grafikleri üzerinden birbiri ile karşılaştırılacaktır.

Çalışmanın dördüncü ve son bölümünde ise elde edilen bulgular üzerinden konu ile ilgili tartışma, sonuç ve öneriler sunulacaktır.



1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. İklim ve İklim Değişikliği

İklim; sıcaklık, nem, hava basıncı, yağış, rüzgâr gibi meteorolojik olayların geniş bir bölgede ve uzun bir dönem boyunca baskın karakteristik özelliklerini temsil eden ortalama koşullardır. İklimi geniş bir çerçevede ele alan bilim dalına ise klimatoloji denir. Genellikle iklim kavramı hava durumu ile çok karıştırılır ve yanlış ifade edilir. Hava durumu, atmosferde görülen ve meteorolojik olayları meydana getiren sıcaklık, nem, hava basıncı, yağış, rüzgâr gibi değişken iklim elemanlarının belli bir yerde kısa süreler içerisinde almış oldukları görünümüdür. Hava olaylarını inceleyen bilim dalı ise meteorolojidir. İklim değişikliği ise meteorolojik olaylardaki uzun dönem boyunca oluşan ortalama koşullarda görülen büyük sapmalar veya büyük değişimlerdir [5]. İklim değişikliği toplumlarda ve devletlerde en çok tartışılan ve kaygı yaratan konuların başında gelmektedir. Ancak iklim değişikliği bu kadar gündemde olmasına rağmen bu kavramla ilgili yanlış çıkarımlar söz konusudur. Hava durumunun aksine baskın iklim koşullarının oluşabilmesi için yukarıda tanımlı yapılırken bahsedildiği üzere çok uzun yıllar gerekmektedir. Meteorolojik bir olayın belli bir normale ulaşması için gereken süre en az 30 yıl olarak kabul edilirken, klimatolojide bu süre 300 yıla kadar çıkabilmektedir [6]. Belirli bir bölgenin karakteristik iklim koşullarından bahsedilebilmesi için bu ölçekte uzun bir döneme ait veri setinin olması gerekir. Yine aynı perspektifle bakılacak olursa, iklim değişikliğinden bahsedilebilmesi için de uzun bir gözlem süresine ihtiyaç vardır. Konunun uzmanı olmayan kişi veya kurumlarca kısa süreli hava durumlarına bakılarak iklimin değiştiğine dair yapılan çıkarımlar çok rasyonel değildir. Bununla birlikte; iklim koşulları, yerkürenin milyar yıllık varlığından beri tüm bölgeler ve tüm zaman ölçeklerinde değişim eğiliminde olmuştur [7].

İklim değışikliđinin genel tanımı Birleşmiş Milletler İklim Deđişikliği Çerçeve Sözleşmesinde (United Nations Framework Convention on Climate Change, UNFCCC) yapılmıştır. İklim değışikliđi; karşılaştırılabilir iki zaman dilimi içerisinde iklim sisteminde gözlenen doğal iç değışikliklere ek olarak doğrudan veya dolaylı bir şekilde küresel atmosferin bileşimini değıştiren insan faaliyetlerine atfedilen iklimdeki değışikliklerdir. Burada iklim sisteminin kısa bir tanımı da yapılmış olup atmosferin (hava tabakası), hidrosferin (su tabakası), biyosferin (canlı tabaka) ve jeosferin (yer tabakası) bütünü ve bunların etkileşimleri iklim sistemi anlamına gelmektedir [8]. İklim sistemindeki doğal iç değışikliklere sebep olan etkenlere; jeolojik devirlerdeki iklim değışiklikleri, volkanik faaliyetler, buzul hareketleri, deniz seviyesindeki yükselme ve alçalmalar örnek gösterilebilir [9]. Son yıllarda sürekli gündeme gelen ve iklim sisteminin dengesini bozan insan kaynaklı faaliyetler ise yaklaşık 18. yüzyılın ortalarında başlayan endüstri devrimi ile birlikte hızlanmıştır. Bu dönemden itibaren fosil yakıtların yakılması, ormanların yok edilmesi, arazi kullanımı, sera gazlarının (su buharı, karbondioksit, metan, diazotmonoksit, ozon, aerosoller vb. gazlar) atmosferdeki miktarlarının önemli ölçüde artması iklim değışikliđine sebep olan insan kaynaklı faaliyetlerdir. Özellikle sera gazlarının iklim sistemindeki yeri tartışılmaz derecede önemlidir. Yeryüzü ile Güneş arasında kısa ve uzun dalga boylarında meydana gelen radyasyon etkileşimini doğrudan etkileyen sera gazları atmosferdeki miktarlarına göre yeryüzünün ve atmosferin alt bölümlerinin ısınmasına sebep olmaktadır. Endüstri devrimi öncesinde 280 ppm olan atmosferdeki CO₂ konsantrasyonu, ABD Ulusal Okyanus ve Atmosfer Yönetimince (NOAA) 2022 yılı mayıs ayında 420 ppm olarak ölçülmüş olup kayıtlara giren en yüksek değerdir [10]. Dünyanın aldığı ya da yansıttığı Güneş ışığı miktarı da dünya yüzeyindeki sıcaklığı etkileyen önemli bir parametredir. Burada bahsedilen ısınma ve sıcaklık artışları, yine çok karıştırılan bir kavram olan küresel ısınmaya sebebiyet vermektedir.

Küresel iklim değışikliđi ile ilgili en kapsamlı çalışmalar ve değerlendirmeler 800'den fazla bilim insanı ve araştırmacının yer aldığı bir platform olan Hükümetlerarası İklim Deđişikliği Paneli (Intergovernmental Panel on Climate Change, IPCC) tarafından yapılmaktadır. 1988 yılında Birleşmiş Milletlere bağlı olarak kurulan bu platform, küresel iklim değışikliđi ile ilgili günümüze kadar geniş çapta hazırlanan değerlendirme

raporları üzerinde çalışmıştır. 2014 yılı Eylül ayında yayınlanan 5. Değerlendirme Raporundaki küresel iklim değişikliği ile ilgili öne çıkan bazı değerler şu şekildedir:

- ❖ 1901–2012 yılları arasında küresel sıcaklıklarda yaklaşık $0,9^{\circ}\text{C}$ 'lik bir artış söz konusudur. Bu yıllar arasında yerkürenin neredeyse tüm yüzeyi ısınmıştır. Ortalama yüzey sıcaklığı ise endüstri devrimi öncesine göre 2°C daha yüksektir.
- ❖ Geride kalan son 30 yıl (1984–2014) 19. yüzyılın ortalarından itibaren kaydedilen en sıcak ardışık 30 yıl olarak, 21. yüzyılın ilk 10 yılı ise en sıcak 10 yıl olarak değerlendirilmiştir.
- ❖ Küresel yüzey sıcaklığı 21. yüzyılın sonlarına doğru, yapılan projeksiyon ve senaryoların büyük bir kısmında endüstri devrimi öncesine göre $1,5^{\circ}\text{C}$ 'yi, birkaç projeksiyona göre ise 2°C 'yi geçecektir.
- ❖ 1950'li yıllardan itibaren hava olaylarındaki ekstrem durumlarda da ciddi değişiklikler gözlenmiş ve özellikle sıcaklık artışlarından kaynaklı küresel ölçekte soğuk gün ve gecelerin sayısı azalmış, sıcak gün ve gecelerin sayısı ise artmıştır.
- ❖ 1951–2010 yılları arasında küresel sıcaklıklardaki artış, %95 civarında bir ihtimalle insan faaliyetlerinden kaynaklanmıştır.
- ❖ Atmosferdeki karbondioksit (CO_2), metan (CH_4) ve diazot monoksit (N_2O) gazlarının birikimleri 2014 yılı itibariyle son 800.000 yıllık dönemdeki kadar yüksek bir düzeyde seyretmemiştir.
- ❖ Atmosferdeki karbondioksit (CO_2) birikimi, özellikle fosil yakıt yakılması ve arazi kullanımındaki değişimler nedeniyle endüstri devrimi öncesine göre %40 oranında artmıştır.
- ❖ 19. yüzyılın ortalarından beri gözlenen deniz seviyesi yükselme oranı önceki iki bin yıllık dönemdeki ortalamalarına göre daha yüksektir. Küresel ortalama deniz seviyesi 1901–2010 yılları arasında 19 cm yükselmiştir [11].

Küresel iklim değişikliğinin, yerküre ve canlılar üzerinde birçok olumsuz etkisi bulunmaktadır. Mevcutta ve gelecekte karşılaşılabilecek olan bu olumsuz etkiler ise kısaca şöyle özetlenebilir:

- ❖ Bazı biyolojik türlerin yeni ekosisteme adaptasyonu zorlaşacağından bu türler yok olma tehlikesi yaşayacaklardır.
- ❖ Dağlık bölgelerdeki buzullar ve kar örtüsünün azalmasından dolayı öncelikle hidrolojik sistem ve toprak dengesi bozulacaktır. Tarım, turizm, kerestecilik gibi ekonomik sektörler olumsuz etkileneceklerdir.
- ❖ Deniz seviyesinin son 100 yılda ortalama 15–25 cm yükselmiş olması ve bu değerin 2100 yılına kadar 15–95 cm'ye ulaşabileceğinin öngörülmesi nedeniyle bazı ülkelerin kıyı kesimleri sular altında kalacak ve küçük adalar kaybolacaktır. Balıkçılık, tarım, turizm, şehircilik ve sigorta gibi sektörler olumsuz etkilenecektir.
- ❖ Tatlı su kaynaklarına tuzlu su karışacağından dolayı canlıların ihtiyacı olan içme ve kullanma suyunun kalitesi bozulacaktır.
- ❖ Yeryüzünün bazı bölümlerinde yağışlar artarken bazı bölümlerinde yağışlar azalacaktır. Bu nedenle hidrolojik döngü bozulacaktır.
- ❖ Yağış paternlerindeki değişimler nedeniyle sağanak yağışlar artacak, böylece suyun topraktaki süzülüşü azalacağından dolayı sel olayları ciddi oranda artacaktır. Bu değişimler yerüstü ve yeraltı su kaynaklarının dağılımını ve potansiyelini olumsuz etkileyecektir.
- ❖ Su kaynaklarındaki azalma nedeniyle özellikle tarım ve çevre sektörlerinin olumsuz etkilenmesinin insanlar üzerinde birçok negatif etkisi olacaktır.
- ❖ Doğal kaynakların potansiyelinde görülebilecek gerilemelerden dolayı kırsal kesimlerde yaşayan insanların kentlere göçü artacaktır.
- ❖ Küresel ısınmaya bağlı olarak gerçekleşebilecek kalp ve solunum rahatsızlıkları başta olmak üzere, bazı hastalıklardan dolayı insanların psikolojisi olumsuz etkilenecektir. Psikolojik rahatsızlıklar, diğer hastalıklar ve ölümler artacaktır [12].

1.2. İklim Değişikliği-Kuraklık İlişkisi

Tez çalışmasının ilerleyen bölümlerinde daha detaylı bir şekilde ele alınacak olan kuraklık kavramı, iklim koşullarını oluşturan doğal süreçlerden sadece biridir.

Yağışların azalmasına bağlı olarak su arz-talep dengesinin bozulması ile birlikte ortaya çıkan kuraklık, iklim koşullarının su kaynaklarına, tarım ve canlı hayatına etkilerini ortaya çıkartan ve çok önem verilmesi gereken tehlikeli bir doğal afettir. Son dönemlerde iklim değişiklikleri ile birlikte kuraklık olayları da geniş bölgelerde etkisini artırmış ve en çok tartışılan konulardan biri haline almıştır. Ancak yeryüzünde görülen her kuraklık olayını da iklim değişikliğine bağlamak çok sağlıklı bir yaklaşım değildir. İklim değişikliğinin etkisinin arttığı dönemlerden önceleri de dünyanın farklı bölgelerinde şiddetli kuraklık olayları gözlenmiştir [13]. Son dönemlerde kuraklığın bu kadar çok gündemde olmasının önemli nedenlerinden biri de ciddi oranlarda artış gösteren küresel ısınmanın hayatı birçok alanda olumsuz etkilemesidir. Küresel ısınmaya bağlı olarak sıcaklıkların artması ve yağışların da kayda değer bir şekilde azalması sonucu ortaya çıkan kuraklığın olumsuz etkileri yeryüzünün büyük bir kısmında günden güne daha da hissedilir bir hal almıştır [14].

Canlı-cansız ekosisteminin en önemli döngüsü denilebilecek hidrolojik çevrimde, küresel iklim değişikliğine bağlı olarak son dönemlerde normal koşullardan önemli derecede sapmalar gözlenmektedir. Yaşamın temel kaynağı olan su, yeryüzünde maddenin katı, sıvı ve gaz halleri şeklinde bulunur ve bu haller arasında sürekli bir dönüşüm eğilimindedir. Büyük bir oranda (%97,5) okyanuslarda ve az bir oranda (%2,5) karada bulunan su; buharlaşma ile atmosfere, atmosferden ise yoğunlaşma sonucu çeşitli yağış formlarında tekrar yeryüzüne ulaşır. Yeryüzüne dönen su, yüzeysel akış ve yeraltı suyu şeklinde nehirlerle ve oradan da tekrar okyanuslara ulaşır. Sürekli devam eden bu döngüde yer alan meteorolojik olaylar doğal hızından daha uzun veya kısa bir sürede, dar veya geniş bir alanda meydana geldiği zaman tüm ekosistemi önemli derecede etkilemektedir. Bu etkilerin başında da yeryüzündeki su varlığı ve su dağılımı gelmektedir. Bu sonsuz döngü içerisinde yeryüzünün bazı bölgelerinde yağış yetersizliğine bağlı olarak kuraklık olayı görülebilmektedir [15]. Ayrıca bu sonsuz döngü bazında iklim koşullarına ve kuraklığa daha büyük bir perspektifte bakıldığında kuraklığın iklim koşulları içerisinde nasıl bir süreçte yer aldığı net bir şekilde anlaşılmaktadır. Bu sürece bağlı olarak yağış paternindeki değişiklikler, kar birikimindeki azalma, erime rejimleri ve evapotranspirasyondaki artışlar kuraklık koşullarını daha da şiddetlendirmektedirler [16].

1.3. Kuraklık

Kuraklık, ekolojik bir sistemde su varlığında veya su kaynaklarında beklenen değerlere göre ciddi orandaki azalmalar sonucu ortaya çıkan ve canlıların suya olan talebinin karşılanamamasına neden olan çok tehlikeli bir doğa olayıdır. Kuraklık süreci ilk olarak yağış eksikliği ile başlar, daha sonra toprak neminde azalmalar görülür, devamında ise akışlarda, nehir akımlarında, kaynaklarda, sulak alanlarda ve depolamalarda, yeraltı suyu rezervlerinde azalmalar görülür ve en sonunda ise canlıların su taleplerinin karşılanamaması nedeniyle çeşitli sosyo-ekonomik etkileri ortaya çıkar.

Kuraklıkla ilgili olarak oluşum, şiddet, frekans, konum, zaman ve süre gibi kriterlere göre birçok tanım geliştirilmiş olup kuraklığın göreceli olmasından dolayı belirli bir tanımı bulunmamaktadır. Bununla birlikte kuraklığın en net ve kullanışlı tanımı 1997 yılında İtalya'da düzenlenen Birleşmiş Milletler Çölleşme ile Mücadele Sempozyumunda yapılmıştır. Burada kuraklık; 'kaydedilen normal seviyelerin önemli ölçüde altına düşen yağışlar nedeniyle hidrolojik dengenin bozulması sonucu, su ve toprak kaynaklarının olumsuz etkilenmesine neden olan tehlikeli bir doğa olayı' olarak tanımlanmıştır [17]. Kuraklık, bütüncül bir şekilde değerlendirildiğinde mutlak değil göreceli bir doğa olayı olarak bilinmektedir. Kuraklıkla ilgili referans noktası normallere göre yağış ve su eksikliği olduğundan dolayı, fazla ya da az yağış alması fark etmeksizin hemen hemen bütün iklim kuşaklarında ve rejimlerinde kuraklık olayı görülebilmektedir [18].

Kuraklık, yağışlar ve yağışların özellikleri ile doğrudan ilgili olmakla birlikte sıcaklık, rüzgâr, bağıl nem, hava basıncı, buharlaşma gibi iklim elemanlarına da bağlı olarak değişiklik gösterebilmektedir. Bahsedilen bu iklim elemanları kuraklığın başlangıç zamanı, coğrafi dağılımı, süresi ve şiddeti gibi kriterler üzerinde etkili olabilmektedir. Bundan dolayı kuraklıkla iklim arasında yakın bir ilişkiden söz etmek mümkündür. Kuraklık olayı, su kaynakları üzerindeki baskıyı artırarak insanların, bitkilerin ve hayvanların su ihtiyaçlarını karşılamasında zorluklar ve problemler yaratmaktadır. Bununla birlikte kuraklığın şiddeti, diğer iklim faktörlerinin dışında insan faaliyetlerine ve su taleplerine göre de artmakta ya da azalmaktadır. Mevcut su kaynaklarının israf edilmesi ve hali hazırda sınırlı durumdaki kaynakların da sorumsuz ve etkisiz kullanımı

sonucu, tarımsal faaliyetler başta olmak üzere insan ve doğa önemli ölçüde etkilenmektedir [19].

Kuraklığın karakteristiklerini tanımlamak, ölçmek ve izlemek; sebep olduğu çevresel, toplumsal ve ekonomik etkilerden dolayı oldukça güçtür. Kuraklık ile mücadele, kuraklığın oldukça ağır ilerlemesi ve seneler boyunca birikimli olarak büyük bölgeleri etkisi altına alması nedeniyle diğer doğa olaylarına göre epey zordur. Kuraklıkla mücadeleyi zorlaştıran bir diğer etken de kuraklığın başlangıç ve bitiş tarihlerinin genellikle belirsiz olmasıdır. Özellikle insanın doğayı bozmaya devam etmesi halinde ekolojik dengedeki bozulmalar giderek artacak olup küresel ısınma ve iklim değişikliği ile birlikte kuraklık olayı canlılar ve dünyamız açısından daha büyük bir problem haline gelecektir [20].

Kuraklık olayı, oluşumu ve başlangıcı açısından tek başına bir felaket gibi olmamasına rağmen canlı hayatı üzerine etkileri ve ekolojik çevrenin kuraklığa karşı gösterdiği dayanıklılık durumuna göre çok yıkıcı olabilmektedir. Dünyanın birçok bölgesinde ve farklı iklim kuşaklarında kuraklığın etkisi görülmektedir. Kuraklığın yıkıcı etkisi şiddetine bağlı olarak hem çok kısa dönemlerde hem de uzun dönemlerde ortaya çıkmaktadır [21].


1.3.1. Kuraklığa Neden Olan Meteorolojik Etkenler

Yerkürenin yaklaşık 4,6 milyar yıllık bir jeolojik tarihi bulunmakta olup bu süreç boyunca hem yerüstü ve yeraltı hareketlerindeki değişimler, hem yörünge hareketleri hem de atmosferdeki etkileşimlerden dolayı küresel iklim sürekli değişmektedir. Bu konu, hem jeolojinin hem de klimatolojinin içerisinde değerlendirilen geniş bir konu olup tez konusunu dağıtmamak adına detaylarına girilmeyecektir. Atmosferdeki etkileşimler içerisinde en önemli olay Güneş ışınları ve Güneşten alınan enerji miktarıdır. Güneşten alınan enerji miktarı sürekli artış eğiliminde olup, bu da küresel iklim koşullarını etkilemektedir. Sıcaklık, buharlaşma, yağışlar, rüzgâr, nem gibi meteorolojik değişkenler, iklim değişimlerine bağlı olarak normallere göre sapmalar gösterir. Kurak dönemlerin görülmesinde bu meteorolojik değişkenlerdeki sapma miktarları önemli bir yer tutmaktadır.

Kuraklığa neden olan önemli etkenlerden biri de atmosferdeki dolaşım sistemlerinde görülen salınımlar, başka bir ifadeyle basınç farklılıklarıdır. Salınımların etkisi altında bulunan bir bölgenin bazı bölümlerinde normallerin üzerinde sıcaklık, yağış, rüzgâr değerleri görülürken bazı bölümlerinde ise bu değişkenlerin normallerin altında seyrettiği görülür. Bir bölgede kararlı iklim koşullarının görülebilmesi için atmosferde mümkün olduğunca salınımların olmaması gerekir. Dünyanın 30° enlemlerine yakın bölümlerinde (ekvator) alçak basınç, 60° enlemleri civarında (kutuplar) ise yüksek basınç koşulları hâkim olmaktadır. Bu iki zıt basınç koşullarının birbiri ile etkileşimleri sonucu da hava olayları oluşmaktadır. Isınmanın fazla olduğu 30° enlemleri civarında meydana gelen nemli hava akımları, bu bölgelerde Dünyanın yörünge hareketlerine bağlı olarak havayı soğutur ve alçalmaya zorlar. Bu atmosferik alçalma olayına ‘sübsidans’ denilmekte olup sübsidansın gerçekleştiği durumda hava adyabatik olarak ısındığından dolayı daha kuru bir hava formunda yeryüzüne ulaşmaktadır [22]. Kuraklık olayına neden olan bir diğer sübsidans durumu da subtropikal yüksek basınç hareketi ile meydana gelmektedir. Subtropikal yüksek basınç hareketi; yazları kutuplar bölgesine, kışları ise ekvator bölgesine doğru bir salınım yapar. Bu salınım sonucunda 30° enlemleri civarında kurak bir kuşağa neden olan yağış rejimi görülür. Tüm bunlara ek olarak havanın nem durumu da yağışları ve dolayısıyla kuraklık olayını doğrudan etkileyen bir etkidir.

1.3.2. Kuraklık Sınıflandırması

Kuraklığın göreceli ve karmaşık bir doğa olayı olduğundan daha önce bahsedilmişti. Bu nedenle, kuraklıkla ilgili çok çeşitli sınıflandırmalar söz konusudur. Ancak literatürde kabul gören kuraklık sınıflandırması, özellikle etkilediği alana ve etkileme süresine göre yapılmaktadır. Yine daha önce belirtildiği üzere kuraklık, sistemdeki su eksikliğinden kaynaklanan ve canlıların su taleplerinin karşılanamadığı bir durumdur. Sistemdeki su eksikliğinin etkilemiş olduğu alanlara göre kuraklık; meteorolojik, tarımsal, hidrolojik ve sosyo-ekonomik kuraklık olarak dört sınıfa ayrılmaktadır [23]. Etkileme süresine göre ise kısa süreli ve uzun süreli kuraklık olarak ayrılmaktadır. Şekil 1.1’de etkilediği alanlara göre kuraklık sınıfları gösterilmiştir.



Şekil 1.1. Etkilediği alanlara göre kuraklık sınıflandırması

1.3.2.1. Meteorolojik Kuraklık

Belirli bir bölgede ve belirli bir sürede normal dönemlerde kaydedilen yağıştan daha az bir yağışın görülmesiyle birlikte kuraklık sürecinde ilk olarak ortaya çıkan kuraklık türüdür. Meteorolojik kuraklıkta, bölgesel bazda ele alınan bir kuraklık türü olmasından dolayı bölgesel iklim modelleri kullanılmaktadır. Yağış seviyeleri ile birlikte kurak veya nemli dönemler bölgesel ölçekte yapılan iklimsel karşılaştırmalarla belirlenmektedir [24]. Yağış eksikliğine bağlı olarak ortaya çıkan meteorolojik kuraklığın zaman ölçekleri aylık, mevsimsel, yıllık veya çok yıllık dönemler olarak ayrılmaktadır. Meteorolojik kuraklık seviyesi ile ilgili yapılan değerlendirmeler yağış toplamalarına, yağış normallerine ve yağışsız geçen süreye göre belirlenmekte olup, belirli bir bölgede kaydedilen yağış normallerinin 1/3'ünden daha düşük olan yağış miktarı ya da yağışsız geçen 15 günlük süre, meteorolojik kuraklık olarak değerlendirilebilmektedir [25]. Bunların yanı sıra diğer kuraklık türlerinde olduğu gibi kuraklığı izlemek amacıyla

geliştirilen özel kuraklık indisleri ile meteorolojik kuraklığın büyüklüğü ya da şiddeti belirlenmektedir. Meteorolojik kuraklıkta yağış azlığına bağlı olarak yüzey akışında ve yeraltı sularının miktarında azalmalar gibi sonuçlar görülmektedir. Yüksek sıcaklık, yüksek rüzgâr hızı, düşük nem ve az bulutluluk gibi etkenlerden dolayı suyun toprakta buharlaşması ve bitkiler tarafından gerçekleştirilen terleme de meteorolojik kuraklığı etkilemektedir. Meteorolojik kuraklık, genellikle kısa sürelerde ve hızlı bir şekilde gelişmektedir [26].

1.3.2.2. Tarımsal Kuraklık

Kuraklık sürecinin ikinci aşaması olan tarımsal kuraklık türü, bitkilerin büyümesi ve gelişmesi için gereken suyun ya da toprak neminin, bitkilerin ihtiyaç duyduğu miktara göre yetersiz kaldığı durumlarda ortaya çıkmaktadır. Hiyerarşik olarak tarımsal kuraklık, meteorolojik kuraklıktan sonra ve hidrolojik kuraklıktan önce meydana gelen bir kuraklık türüdür. Bu kuraklık türünün görülmesinin başlıca iki nedeni vardır. Bunlar; meteorolojik kuraklığın uzun sürmesi ve bitkilerin büyüme döneminde toprağın nemini kaybetmesidir. Tarımsal kuraklığın meydana geldiği yerlerde, toprak derinlerde yağışa ve suya doymuş bile olsa, elde edilecek son ürünün verimi ve kalitesi önemli ölçüde düşebilmektedir [27]. Çünkü yağışların artmasıyla birlikte doğrudan toprak neminin de artacağı söylenemez. Toprağın nemi; bölgenin iklim koşullarına, toprağın eğim başta olmak üzere topografik koşullarına, toprağın su tutma kapasitesine ve diğer fiziksel ve kimyasal özelliklerine göre değişmektedir. Toprağın su tutma kapasitesi yüksek olan bölgeler, kuraklık koşullarına daha çok direnç göstermektedirler [28]. Bir bölgedeki tarımsal kuraklığa dayanıklılık toprak yapısı ile birlikte bitki türlerinin ve hayvan ırklarının da kuraklık direnci ile ilişkilidir. Yağışlar ve toprak neminin düşmesinin yanı sıra artan sıcaklıklar, azalan nem oranı ve rüzgârların kurutucu etkisi, bu kuraklık türünün etkilerinin giderek yükselmesini tetiklemektedir. Tüm bunların yanı sıra, tarım arazilerinin ekim ve sulama yöntemleri de tarımsal kuraklığın şiddetini etkileyebilmektedir [29].

1.3.2.3. Hidrolojik Kuraklık

Yüzey su kaynakları, nehir akımları, sulak alanlar, göl ve baraj-gölet depolamaları, yeraltı su kaynakları ile diğer su kaynaklarının normal seviyelerinin altına düştüğü durumlarda hidrolojik kuraklık olayı görülmektedir. Bahsedilen bu su kaynaklarında

belli bir dönem boyunca görülen aşırı boşalmalar, su seviyelerindeki düşümler ya da hacim azalmaları, hidrolojik kuraklığa neden olur. Hidrolojik çevrimin yüzeydeki bileşenleri olan başta nehir akımları olmak üzere tüm yerüstü ve yeraltı kaynaklarındaki değişimler ya da azalmalar, bütün sistemin dengesini bozabilecek bir duruma sebep olabileceğinden hidrolojik kuraklık tüm canlı hayatı için oldukça öneme sahiptir. Hidrolojik kuraklık türü, meteorolojik kuraklığın çok uzun sürmesi sonucu görülen yağış eksikliği ve su tüketimindeki artışlardan dolayı ortaya çıkmaktadır. Yağış eksikliğinin vuku bulması ile akarsu, dere ve rezervuarlardaki su eksikliği arasında belirli bir zaman aralığı geçtiğinden dolayı hidrolojik ölçümler, kuraklığın ilk göstergelerinden değildir. Bununla ilgili olarak da zaman zaman kavram kargaşası yaşanabilmektedir. Meteorolojik kuraklığın bitişinden itibaren, uzun bir zaman sonra dahi hidrolojik kuraklık durumu hala var olabilir [30]. Tüm bunların yanı sıra, başta tarım arazileri olmak üzere arazi kullanımlarındaki değişiklikler ve toprağın fiziksel ve kimyasal yapısındaki bozulmalar da hidrolojik kuraklığın frekans ve büyüklük gibi niteliklerini etkilemektedirler [31].

1.3.2.4. Sosyo-ekonomik Kuraklık

Kuraklık sürecinin en son aşamasında ortaya çıkan sosyo-ekonomik kuraklık türü, diğer kuraklık türlerine bağlı olarak yağış ve su eksikliğinden kaynaklı insan türü başta olmak üzere, canlıların üretim ve tüketim faaliyetlerinin etkilenmesi ya da kısıtlanması şeklinde tanımlanabilir. Suyu erişimdeki zorluk ve kısıtlamalar, suyun kalitesindeki bozulmalar ve suyun üretim, tüketim ve dağıtımındaki ekonomik faktörler nedeniyle ortaya çıkan bir kuraklık türüdür. Sosyo-ekonomik kuraklık, fiziksel kuraklık olayları nedeniyle insanların sosyal ve ekonomik koşullarının olumsuz etkilendiği ve kuraklık sürecinin en bariz şekilde hissedildiği aşamasıdır. Bu kuraklık türü, temiz ve güvenilir içme suyu temini başta olmak üzere gıda sıkıntısı, işsizlik, göçler, su kaynakları üzerindeki rekabet ve hatta çatışmalar gibi birçok sosyal ve ekonomik soruna neden olabilmektedir. Özellikle başlıca gelir kaynağı tarım ve tarıma bağlı faaliyetler olan yerel ya da ulusal ölçekteki bölgelerde meydana gelecek olan ciddi yağış ve su eksiklikleri, bu bölgelerde sosyo-ekonomik kuraklığın daha keskin bir şekilde hissedilmesine neden olmaktadır. İnsanların yaşam kalitesini ve standartlarını doğrudan etkileyen bu kuraklık türü; ekonomik, sosyal ve çevresel etkilerinden dolayı oldukça yıkıcıdır [32].

1.3.2.5. Kısa ve Uzun Süreli Kuraklık

Etkileme sürelerine göre kuraklık; kısa süreli kuraklık ve uzun süreli kuraklık olmak üzere iki gruba ayrılmaktadır [29]. Kısa süreli kuraklıklar genellikle 6 ay ve daha kısa periyotlarda etkisini gösterirken, uzun süreli kuraklıklar bu süreden daha fazla olan periyotlarda görülmektedir. Kısa süreli kuraklık, yağış eksikliğinden dolayı kuraklığın ilk etkilerinin ortaya çıktığı ve meteorolojik kuraklık türünün yaşandığı evredir. İçme suyu ve tarımsal sulama başta olmak üzere, su taleplerinin karşılanamaması gibi durumlar kısa süreli kuraklık döneminde etkisini göstermektedir. Normalin altındaki yağışların aylar ve yıllar boyunca devam etmesi ile birlikte kuraklığın etkilerinin uzun dönemlere yayılması halinde ise uzun süreli kuraklıkların yaşandığı evreye geçilmektedir. Uzun süreli kuraklık döneminde, meteorolojik kuraklık türünden sonra görülen tarımsal, hidrolojik ve sosyo-ekonomik kuraklık türlerinin etkileri daha da ciddi bir şekilde hissedilmektedir. Yağış eksikliğinin uzun dönemler boyunca devam etmesi ile tüm su kaynakları önemli oranda etkileneceğinden dolayı bu dönemlerde hidrolojik kuraklık öne çıkmaktadır. Uzun süreli kuraklıklar, kuraklık süreci içerisinde oldukça ekstrem bir durum olmasına rağmen her zaman ihtimal dâhilindedir.

1.3.3. Kuraklık İndisleri

Kuraklık indisleri, belirli bir zamanda belirli bir bölgedeki kuraklığa ait şiddet, süre, frekans ve yerel dağılım gibi özellikleri tespit etmek, ölçmek veya izlemek için kullanılan matematiksel formüllerdir. Kuraklık değerlendirmelerinin, acil eylem planları ve erken uyarı sistemlerinin doğru ve güvenilir bir şekilde yapılabilmesi için kuraklık indislerinin önemi büyüktür. Kuraklık indisleri; meteorolojik, hidrolojik ve tarımsal değişkenlere sahip zaman serilerinin incelenerek, kuraklığın büyüklüğünü ya da şiddetini hesaplamaya yarar. Karmaşık kuraklık sürecinin koşullarının tanımlanması ve ekosisteme olan etkilerinin belirlenmesi için de indislerden yararlanılmaktadır. Kuraklık indisleri, bir bölgenin başta yağış ve sıcaklık olmak üzere çeşitli meteorolojik değişkenlerini kullanarak, bölgenin su kaynaklarındaki değişimlerini, toprağın nem durumunu, bitki büyümesini ve diğer kuraklık etkilerini belirlemeye yardımcı olur. Bu indisler, ele alınan bölgenin normal meteorolojik ve iklim koşullarına göre, o anda yaşanan kuraklığın belirlenmesini sağlarlar. Ayrıca bir kuraklık durumunun ne zaman başladığının, ne zaman sona erdiğinin ya da kuraklık koşullarının hangi coğrafi alanda

etkisini gösterdiğinin bilinebilmesi için kuraklık indisleri aracılığı ile bir şiddet referans değeri üzerinden değerlendirme yapılır [18].

İlk dönemlerde geliştirilen kuraklık indisleri, genellikle dar ve yerel ölçeklerde ele alınmış olup sınırlı hesap adımlarına sahiptirler. Daha sonraki dönemlerde ise bu indislerin küresel ölçeklerde ve farklı iklim koşullarında da kullanılabilmesi için çalışmalar yapılmıştır. Dünyanın bazı bölgelerinde hala o bölgenin iklim koşulları ve su talepleri dikkate alınarak geliştirilmiş bölgesel kuraklık indisleri kullanılmaktadır. Farklı hesap yöntemleri ve kullanım amaçlarına göre çok değişik kuraklık indisleri kullanılmaktadır. Yine kuraklık türlerinde olduğu gibi indisler için de meteorolojik, tarımsal ve hidrolojik kuraklık indisleri olmak üzere bir sınıflandırma yapılmaktadır [21]. Bunun sebebi, başka bir yöntem ya da amaca yönelik geliştirilen bir kuraklık indisinin ele alınan kuraklık türünün çeşitli özellikleri ya da etkilerinden dolayı bu kuraklık durumuna uyum sağlayamaması ve beklenen işlemleri yapamamasıdır.

1.3.3.1. Meteorolojik Kuraklık İndisleri

Kuraklığın yağış başta olmak üzere sıcaklık, evapotranspirasyon, nem, rüzgâr hızı, Güneş radyasyonu gibi meteorolojik değişkenlere bağlı olarak hesaplanması ya da belirlenmesi gerektiğinde meteorolojik kuraklık indisleri kullanılmaktadır. Bunlardan en çok kullanılan meteorolojik değişken, doğal olarak yağış değişkenidir. Günlük, haftalık, aylık, mevsimsel ya da yıllık olarak farklı zaman ölçeklerinde değerlendirilen yağış zaman serileri kullanılarak normal değerlere göre kuraklığa ait, sapmalar, trendler ve ekstrem noktalar bulunmaktadır. En yaygın kullanılan meteorolojik kuraklık indisleri; Standartlaştırılmış Yağış İndeksi (SYİ), Palmer Kuraklık Şiddeti İndisi (PKŞİ), Standartlaştırılmış Yağış-Evapotranspirasyon İndisi (SYEI), Ondalıklar (Deciles), De Martonne formülü, Thornthwaite yöntemi, Normal Yağışın Yüzdesi İndisi (NYYİ), Aridite Anomali İndeksi (AAİ), Efektif Kuraklık İndisi (EKİ), Çin-Z İndeksi (ÇZİ), Erinç Kuraklık İndisi, Yağış Anomali İndisi (YAI) ve Kuraklık Keşif İndisi (KKİ)'dir. Yaygın olarak kullanılan yedi farklı meteorolojik kuraklık indisi, sırasıyla aşağıda özetlenmektedir.

Meteorolojik kuraklık indislerine yönelik ilk çalışma Palmer (1965) tarafından geliştirilen Palmer Kuraklık Şiddeti İndisi (PKŞİ) yöntemidir. Bu yöntemdeki asıl amaç; belirli bir bölgedeki meteorolojik anomaliyi, kuraklık şiddetinin zaman ve mekân

karşılaştırmalarına izin veren bir indis üzerinden değerlendirerek genel bir metodoloji geliştirmektedir. Belirli bir bölgedeki su dengesinde gözlenen yağış açığına bağlı olarak evapotranspirasyon, akışlar ve nem miktarındaki sapma bulunarak bu indis geliştirilmiştir. PKŞİ, bir meteorolojik kuraklık indisi olup anormal kurak veya anormal nemli meteorolojik koşullarda etkili sonuçlar vermektedir. PKŞİ’de kabul edilen sınıflandırma, -4 ile +4 kuraklık şiddetleri referans alınarak bu değerlere karşılık gelen farklı kuraklık sınıflarının belirlenmesi ile yapılmaktadır. -4 değeri ve daha küçük kuraklık şiddetlerinde aşırı kurak, +4 değeri ve daha büyük kuraklık şiddetlerinde ise aşırı nemli dönemin görüldüğü kabulü yapılmaktadır [33].

Kuraklık süreci yağış azlığından dolayı ilk olarak ortaya çıkan meteorolojik kuraklıkla başlar. Meteorolojik kuraklıkla ilgili çalışmalarda en çok kullanılan ve en pratik olan indis, McKee ve ark. (1993) tarafından geliştirilen Standartlaştırılmış Yağış İndeksi (SYİ)’dir. SYİ, sadece yağış parametresine bağlı olarak hesaplanabilen ve tek değişkenli bir hesap mantığına dayanmaktadır. Belirli bir bölgenin belli bir zaman dilimindeki kaydedilen yağış verileri, normal değerlerine göre kıyaslanarak o bölgenin ne kadar kurak ya da ne kadar nemli olduğu standart normal dağılıma uyan SYİ ile belirlenir. SYİ, karmaşık kuraklık sürecinin başlangıcını, bitişini, yoğunluğunu ve büyüklüğünü bir bütün olarak temsil edecek şekilde geliştirilmiş ve olumlu sonuçlar alınmıştır. SYİ’nin kabul gören kuraklık sınıflandırması -2 ile +2 kuraklık şiddet değerleri referans alınarak belirlenmektedir. -2 değeri ve daha küçük kuraklık şiddetlerinde aşırı kurak, +2 değeri ve daha büyük kuraklık şiddetlerinde ise aşırı nemli dönemin yaşandığı kabulüne göre kuraklık analizleri gerçekleştirilir [34].

Yaygın olarak kullanılan meteorolojik kuraklık indislerinden biri de Vicente Serrano ve ark. (2010) tarafından geliştirilen Standartlaştırılmış Yağış-Evapotranspirasyon İndisi (SYEİ)’dir. Bu indiste hem yağış hem de sıcaklık parametresi kullanılmıştır. Ele alınan bölgede aylık olarak yağışlardan potansiyel buharlaşma (PET) çıkarılarak bulunur. PET değerlerinin hesabı için gerekli olan sıcaklık, rüzgâr hızı, güneş radyasyonu, bağıl nem gibi verilere ihtiyaç olduğundan karmaşık bir yaklaşımdır. SYİ yönteminin eksikliklerini azaltabilmek amacıyla geliştirilmiştir. SYEİ yönteminde yapılan kuraklık sınıflandırması SYİ’de yapılan sınıflandırma ile aynıdır [35].

Bir diğer önemli meteorolojik kuraklık indisi olan Normal Yağışın Yüzdesi İndisi (NYYİ), Willeke ve ark. (1994) tarafından geliştirilmiştir [36]. Belirli bir bölgedeki gözlenen yağış miktarının normalden ne kadar sapma gösterdiğini belirlemek için kullanılır. Bu indis, bölgenin mevsimsel değişkenliklerini ve iklim değişikliklerini dikkate almaz, sadece belirli bir referans dönemi boyunca ortalama yağış miktarına göre yağış miktarının yüzdesini hesaplar. NYYİ’de %100’den büyük bir yağış değeri normalden fazla yağış olduğunu, %100’den küçük bir yağış değeri normalden az yağış olduğunu, %100’e eşit bir değer ise normal yağış olduğunu göstermektedir [37]. Bu indis genellikle farklı sektörlerle yönelik su kaynakları yönetimi ile ilgili çalışmalarda kullanılmaktadır.

Erinç (1965), kuraklık analizinde maksimum sıcaklıkların ortalamasını hesaba katarak Erinç Kuraklık İndisini geliştirmiştir. Kuraklığın sadece yağış azlığından değil buharlaşma etkisinden dolayı da önemli ölçüde arttığı kabulü ile geliştirilmiş olan bu indise diğer indislerden farklı olarak maksimum sıcaklık ortalamaları dâhil edilmiştir. Türkiye’de yaygın olarak kullanılan bir kuraklık indisi [38].

Gibbs ve Maher (1967) tarafından yalnızca yağış verisini kullanan Onluklar (Deciles) indeksi geliştirilmiştir. Bazı kaynaklarda yağış kuyrukları olarak da adlandırılmaktadır. Bu yaklaşımda, bir bölgedeki yağış verilerine ait veri seti on eşit parçaya ayrılır ve bu setteki aşılabilen yağışı temsil eden en düşük %10’luk kısım ilk ondalıktır. İkinci ondalık aşılabilen yağışı temsil eden en düşük %20’lik kısımdır ve bu sıralama böyle devam eder. Veri setindeki medyan değerleri ise beşinci ondalıktır. Kendine özgü kuraklık sınıflandırması olan bu yöntemde ondalık değerlere göre kuraklık analizi yapılmaktadır [39].

Çin Ulusal İklim Merkezi tarafından 1995 yılında Çin’de geliştirilen Çin-Z İndeksi (ÇZİ), SYİ tarafından sağlanan hesap kolaylığını temel alarak hesaplamaları daha da kolaylaştırmak amacıyla geliştirilmiştir. Çin-Z İndeksi, kuraklık dönemlerini belirlemek ve kuraklığı izlemek için istatistiksel bir Z-skorunu kullanmaktadır. Bu indisin kuraklık sınıflandırması SYİ’nin kuraklık sınıflandırması ile aynıdır [40].

1.3.3.2. Tarımsal Kuraklık İndisleri

Tarımsal kuraklıkta görülen bitki su ihtiyacı ve topraktaki nem eksikliğinin en önemli sonucu, tarımsal üretimlerde verim ve ürün miktarındaki düşüşlerdir. Topraktaki nem miktarı ve toprağın su tutma kapasitesi, o bölgenin tarımsal kuraklığa karşı direncini de göstermektedir. Tarımsal kuraklığa neden olan buna benzer parametrelere yönelik spesifik indisler geliştirilmiştir. Literatürde kabul gören ve küresel ölçekte kullanılan tarımsal kuraklığa yönelik indisler; Mahsul Nem İndisi (MNI), NOAA Kuraklık İndeksi (NOAA), Toprak Nemi Anomali İndisi (TNAİ) ve Tarımsal-Hidropotansiyel İndisi (THİ) şeklinde sıralanabilir. Belirtilen bu indislerden önemli görülen üç tanesi ile ilgili bilgiler aşağıda verilmiştir.

Mahsul Nem İndisi (MNI), tarımsal kuraklıkların gözlemi için 1960'ların başında Palmer tarafından geliştirilmiştir. Daha sonraki dönemlerde daha da geliştirilerek PKŞİ'nin bir bileşeni olarak birlikte değerlendirilmiştir. Toprak nemini ölçerek bitkilerin ihtiyaç duyduğu suyun yeterli olup olmadığını belirler. MNI, haftalık ölçekte yağış, toprak nem içeriği, bitki örtüsü, sıcaklık ve diğer faktörler dikkate alınarak hesaplanır. Tarımsal üretim sistemlerinde bitkinin büyümesi ve ürün verimliliği ile ilişkili olan toprak nemi miktarının birkaç aylık bitki büyümesi dönemlerinde izlenmesi amacıyla bu indis kullanılmaktadır [41]. MNI değerleri, -10 ila +10 arasında değişmekte olup negatif MNI değerleri, toprak nemi düzeylerinin normalin altında olduğunu ve tarımsal kuraklığın mevcut olduğunu gösterirken, pozitif değerler normalin üzerinde ve aşırı nemli koşulların mevcut olduğunu göstermektedir [42].

NOAA tarımsal kuraklık indeksi, 1980'lerin başında Amerika Birleşik Devletleri Tarım Bakanlığı'nın dünya çapında mahsul üretimi tahminleri için meteoroloji ve iklim verilerini kullanarak geliştirilmiş bir indekstir. Bitkinin büyüme mevsimi boyunca ölçülen yağış değerlerinin normal değerlerle karşılaştırıldığı bir hesap yöntemine dayalıdır. Haftalık olarak gerçek yağışlar ölçülür ve sekiz haftalık dönem için bu yağış ortalamaları toplanır. Gerçek yağış, sekiz haftalık dönem için normal yağışların %60'ından fazlaysa, mevcut haftanın su stresinin çok az olduğu veya hiç olmadığı varsayılır. %60 değerinden düşükse o hafta için su stresinin fazla olduğu yani bitkinin su ihtiyacını tam olarak karşılayamadığı varsayılır [43].

Toprak Nemi Anomali İndisi (TNAİ), toprak nemindeki değişimleri normal koşullara göre ölçmek için kullanılan bir tarımsal kuraklık indisi. TNAİ, ayrıca yeraltı suyu seviyelerindeki değişimleri de hesaba katarak, bir bölgedeki kuraklık durumunu ölçmektedir. Bir bölgedeki toprak neminin uzun vadeli trendleri ve mevsimsel değişimleri bu indis aracılığı ile izlenmektedir. TNAİ'nin pozitif veya negatif değeri, normal koşullardan daha fazla ya da daha az toprak nemi durumunu göstermektedir [44].

1.3.3.3. Hidrolojik Kuraklık İndisleri

Hidrolojik kuraklıkta bahsedilen yerüstü ve yeraltı su kaynakları ile ilgili bileşenlerin ele alındığı indisler, hidrolojik kuraklık indisleridir. Hidrolojik kuraklık indisleri, meteorolojik kuraklık indislerinden farklı olarak daha dar ve spesifik yerlerde ele alınır. Örneğin bir yeraltı suyu kaynağı, baraj depolaması ya da nehir çıkışı gibi noktasal yerlerde hidrolojik kuraklığın şiddetini ölçmek için bu indisler kullanılır. Akım Kuraklık İndisi (AKİ), Standartlaştırılmış Akış İndisi (SAİ), Standartlaştırılmış Yeraltı Suyu İndisi (SYSİ), Palmer Hidrolojik Kuraklık İndisi (PHKİ), Yüzey Suyu Temini İndisi (YSTİ) ve Standartlaştırılmış Depolama Temin İndisi (SDTİ) yaygın olarak kullanılan hidrolojik kuraklık indisleridir. Yine burada da önemli görülen dört farklı indisle ilgili özet bilgiler aşağıda verilmiştir.

Akım Kuraklık İndisi (AKİ), Nalbantis ve Tsakiris (2008) tarafından Atina'da iki nehir havzası için SYİ metodolojisi ve hesaplamaları temel alınarak geliştirilmiş bir indistir. Aylık akış verilerini kullanan bu indis, SYİ ile ilişkili normalleştirme yöntemlerini dikkate alır. SYİ'deki gibi bir çıktı değeri elde edilerek kuraklığın şiddeti hesaplanır ve böylece hem nemli hem de kurak dönemler incelenebilmektedir [45].

Standartlaştırılmış Akış İndisi (SAİ), bir bölgedeki akarsu debisinin ne kadar yüksek veya düşük olduğunu ölçmek için geliştirilmiş bir indistir. Bu indis, akarsu debisindeki mevsimsel ve yıllık değişkenlikler dikkate alınarak hesaplanır ve belirli bir bölgedeki akarsu debilerinin, belirli bir referans dönemi boyunca (genellikle 30 yıl) ortalama debilerine göre ne kadar yüksek veya düşük olduğunu ölçer. Bu indis, aynı bölgedeki akarsu debilerinin yıllar içindeki değişimlerini karşılaştırmak için kullanılır [46].

Standartlaştırılmış Yeraltı Suyu İndisi (SYSİ), bir bölgedeki yeraltı suyu seviyesinin ne kadar yüksek veya düşük olduğunu ölçmede kullanılan bir hidrolojik kuraklık indisi. SYSİ, belirli bir bölgedeki yeraltı suyu seviyelerinin, belirli bir referans dönemi boyunca (genellikle 10 yıl) ortalama seviyelerine göre sapmalarını hesaplamaktadır. Bu indis aracılığı ile aynı bölgedeki yeraltı suyu seviyelerinin boşalım ve beslenimleri de tespit edilerek yıllar içindeki değişimleri karşılaştırılabilmektedir [47]. Pozitif bir SYSİ değeri, ortalama yeraltı suyu seviyesinden daha yüksek bir seviye olduğunu, negatif bir değer ise daha düşük bir seviye olduğunu gösterir. SYSİ, tarım başta olmak üzere inşaat, su yönetimi ve diğer sektörlerdeki yeraltı suyu kaynaklarının sürdürülebilir yönetimi için kullanılmaktadır.

Shafer ve Dezman (1982) tarafından ilk defa tanıtılan Yüzey Suyu Temini İndisi (YSTİ), PKŞİ’de bulunan bazı sınırlamaları ortadan kaldırarak onu tamamlamaya yönelik olarak geliştirilmiştir. Çok değişkenli bir hidrolojik kuraklık indisi olan YSTİ, belirli bir dönem boyunca (genellikle bir yıl) su kaynaklarının ortalamalarına göre hesaplanmaktadır. Yağış, kar erimesi, nehir akımları, yüzey suyu depolama seviyeleri ve buna benzer diğer hidrolojik değişkenler dikkate alınarak yüzey suyunun temin durumu ortalamalara göre değerlendirilmektedir. PKŞİ’de kullanılan kuraklık sınıflandırması bu indis için de geçerlidir [48].

1.4. Literatür Özetleri

Canlı ve cansız hayatı üzerinde birçok olumsuz etkisi bulunan ve çok tehlikeli bir doğal afet olan kuraklık, her geçen gün önemini artırmaktadır. Kuraklık olayının tüm aşamalarından itibaren detaylı bir şekilde ele alınması ve özellikle olumsuz etkilerinin azaltılmasına yönelik çalışmalar üzerinde durulması, dünyamızın bugünü ve geleceği açısından oldukça elzem bir konudur. Bununla birlikte; birçok farklı türü ve karakteristik özelliği bulunan kuraklık felaketinin araştırmacılar, kurum-kuruluşlar ya da devletler tarafından öngörülebilmesi ya da tahmin edilebilmesi, kuraklıkla mücadelenin en kritik aşamasıdır. Bu sayede geleceğe yönelik çeşitli senaryo ve projeksiyonlar oluşturularak kuraklık felaketine ve onun olumsuz etkilerine yönelik politikalar geliştirilebilecektir.

Kuraklık konusunun hidrometeoroloji alanında son dönemin en popüler konularından biri olduğu rahatlıkla söylenebilir. Bunda küresel iklim değişikliğinin ve kuraklığa olan

etkisinin payı yüksektir. Kuraklıkla ilgili farklı amaçlara yönelik olarak birçok yerli ve yabancı çalışma bulunmaktadır. Kuraklıkla ilgili yapılan erken dönem çalışmalarında, genellikle kuraklığın oluşumu, dağılımı, frekansı ve süresi gibi başlıca karakteristik özelliklerine yönelik araştırmalar yapılmıştır. Bu çalışmalara paralel olarak kuraklığın tespiti ve izlenmesine olanak sağlayan kuraklık indislerinin geliştirilmesi yine erken dönemlerde yoğunluk kazanmıştır. Son dönemlerde ise kuraklığın tahmini, tespiti ve izlenmesine yönelik olarak yapay zekâ teknikleri ve alt kümelerinde bulunan makine öğrenmesi ile derin öğrenme yöntemlerinin kullanımı çok popüler olmuştur. Bu tez çalışmasında yapılan literatür taraması da daha çok kuraklığın tahmini ile yapay zekâ ve alt kümelerinde yer alan yöntemlerin ele alındığı çalışmalara yönelik olmuştur.

1.4.1. Dünya’da Yapılan Kuraklık Çalışmaları

Dünya’da kuraklıkla ilgili yapılan ilk öncül çalışmalar, 20.yüzyılın ortalarına kadar dayanmakta olup; büyük bir oranda kuraklık indislerine yöneliktir. Daha önceki bölümde kuraklık indisleri ile ilgili bilgiler verilmiş olduğundan bu kısımda tekrar bahsedilmeyecektir. Daha çok kuraklıkla birlikte yapay zekâ yöntemleri ve tahmin modelleri üzerine yapılan çalışmalara ağırlık verilmiştir.

Shin ve Salas (2000), Colorado’nun güneybatısındaki bölgesel kuraklığı analiz etmek amacıyla Yapay Sinir Ağları (YSA) yaklaşımını kullanmışlardır. Yıllık yağış verileri kullanılarak parametrik olmayan bir mekânsal analiz sinir ağı algoritması oluşturmuşlardır. Yağış verileri üzerine, bu algoritma aracılığı ile normalleştirme ve standartlaştırma işlemleri uygulanmış olup daha sonra normal dağılımın belirli olasılık yüzdelerine göre belirlenen referans değerleri baz alınarak kuraklık şiddetlerine göre sınıflandırma yapılmıştır. Bu şekilde belirlenen kuraklık şiddetlerinin sonuçlarına göre bölgesel kuraklık haritaları elde edilmiştir [49].

Kim ve Valdez (2003), Meksika’daki Conchos Nehir Havzasındaki kuraklıkları tahmin etmek amacıyla Dalgacık Dönüşümü (DD) ile Yapay Sinir Ağları (YSA) bağlantılı bir tahmin modeli önermişlerdir. DD ile alt serilerine ayrılan Palmer Kuraklık Şiddet İndisi (PKŞİ) kuraklık verileri, Çok Katmanlı İleri Beslemeli Sinir Ağında (ÇİBSA) analiz edilmiştir. Bu çalışmada, DD tekniğinin kuraklık zaman serilerinin tahmin becerilerini önemli ölçüde artırdığı görülmüştür [50].

Mishra ve ark. (2007), Hindistan'daki Kansabati Nehir Havzasında kuraklık tahmini için doğrusal stokastik modeli ve doğrusal olmayan yapay sinir ağları modelini birleştiren hibrit bir model geliştirmişlerdir. Bu hibrit model içerisinde Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA), Yapay Sinir Ağları (YSA), zaman serileri ve kompleks otokorelasyon yapıları bulunmaktadır. Geliştirilen bu hibrit model, performans kriterlerine göre hem stokastik model hem de yapay sinir ağlarına kıyasla kuraklıkları daha doğru tahmin etmiştir [51].

Karamouz ve ark. (2009), İran'ın orta kesimlerinde yer alan Zayandeh-Rud (Gav-Khuni) havzasının kuraklık şiddetlerini tahmin etmek ve hibrit bir kuraklık indeksi elde etmek amacıyla olasılıksal sinir ağı ve çok katmanlı algılayıcı olmak üzere iki farklı algoritma önermişlerdir. Hibrit bir kuraklık indeksi elde edebilmek için SYİ, PKŞİ ve Yüzey Suyu Temini İndisleri (YSTİ) kombine edilerek Hibrit Kuraklık İndeksi (HKİ) geliştirilmiştir. Bu çalışmada elde edilen model sonuçlarına göre her iki algoritma da kuraklık şiddetlerinin tahmininde üstün başarı göstermiştir [52].

Karavitis ve ark. (2011), yarı kurak bir iklim rejimine sahip Yunanistan'daki kuraklığın süresi, büyüklüğü ve mekânsal boyutu için ileriye yönelik kuraklık değerlendirmeleri yapmışlardır. 46 adet yağış istasyonunun 1947–2004 yılları arasındaki yağış verilerinden hesaplanan 1, 3, 6, 12 ve 24 aylık zaman ölçeklerine ait Standartlaştırılmış Yağış İndeksi (SYİ) kuraklık değerleri analiz edilmiştir. Daha sonra SURFER-9 yazılım paketi kullanılarak jeo-istatistiksel yöntemlerle SYİ değerlerinin mekânsal dağılımı gerçekleştirilmiştir [53].

Chen ve ark. (2012), Çin'deki Huaihe Nehri Havzasında 1958–2006 yılları arasındaki kısa vadeli (3, 6, 9 ve 12 aylık) SYİ kuraklık değerlerini tahmin etmek için bir derin öğrenme algoritması olan Derin İnanç Ağları (DİA) modelini önermişlerdir. Bu modelin kısa vadeli kuraklık tahminlerinde geleneksel geri yayımlı sinir ağlarına göre daha iyi performans gösterdiği sonucuna varılmıştır. Önerilen bu derin öğrenme algoritmasının kuraklık tahmin teknolojilerini geliştireceği ve karar vericilere kuraklık felaketinin yönetiminde yardımcı olacağı vurgulanmıştır [54].

Xie ve ark. (2013), Pakistan'da 1960–2007 yılları arasındaki kuraklıkların görülme sıklığının zamansal ve alansal değişkenliğini araştırmışlardır. SYİ değerleri kullanılarak yapılan önemli çalışmalardan biri olan bu çalışmada, kuraklık analizlerinde yağış

verilerinden hesaplanan SYİ'nin 3, 6 ve 12 aylık zaman ölçekleri ele alınmıştır. Bu çalışmada ele alınan Temel Bileşen Analizi (TBA), kuraklıkların geniş alanlarda yaygın ve sık bir şekilde meydana geldiğini ortaya koymuştur. Ayrıca kuraklık periyoduna yönelik yapılan spektral analiz sonucunda 16 yıl tekerrür periyoduna sahip şiddetli kuraklıkların görüldüğü belirlenmiştir [55].

Belayneh ve ark. (2016), Etiyopya'nın Awash nehir havzasında uzun vadeli kuraklık durumlarını tahmin etmek için makine öğrenmesi yöntemlerini kullanarak farklı tahmin modelleri oluşturmuştur. Bu çalışmada; dalgacık dönüşümü ilaveli Otoresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA), Yapay Sinir Ağları (YSA) ve Destek Vektör Makine Regresyonu (DVMR) modelleri ele alınmıştır. Dalgacık dönüşümü ile oluşturulan hibrit modeller, kuraklık tahminlerinde diğer bağımsız modellerden daha üstün sonuçlar vermiştir [56].

Mokhtarzad ve ark. (2017), İran'ın Kuzey Horasan Eyaleti'nin merkezi olan Bojnourd şehrinde görülmesi muhtemel kuraklık durumunu tahmin etmek amacıyla 1984–2012 yılları arasındaki yağış verilerine bağlı hesaplanan 3 aylık zaman ölçeğine ait SYİ değerlerini kullanmışlardır. Kuraklık tahmini ile ilgili bu çalışmada; Yapay Sinir Ağları (YSA), Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (USBÇS) ve Destek Vektör Makinesi (DVM) yöntemleri ele alınmış ve tüm yöntemler birbiri ile kıyaslanmıştır. Modellerin giriş parametreleri sıcaklık, nem ve mevsimsel yağış değerleri olup çıkış parametresi ise tek bir SYİ değeridir. Tahmin modellerine ait sonuçlar, DVM modelinin daha doğru ve güvenilir sonuçlar verdiğini göstermiştir [57].

Agana ve Homafair (2018), Colorado nehir havzasında farklı zaman ölçeklerindeki kuraklık yoğunluğunu tahmin edebilmek için Ampirik Mod Ayırıştırması (AMA) ile birlikte Derin İnanç Ağları (DİA) modelini oluşturmuşlardır. Kuraklık indisi olarak Standartlaştırılmış Akış İndisi (SAİ) verileri ele alınmış olup orijinal kuraklık zaman serileri AMA ile alt bantlarına ayrılmıştır. Oluşturulan bu model, Çok Katmanlı Algılayıcı (ÇKA) ve Destek Vektör Regresyonu (DVR) makine öğrenmesi yöntemleri ile karşılaştırılmış olup bu yöntemlere göre tahmin yeteneği daha üstündür [58].

Poornima ve Pushpalatha (2019), Hindistan'ın Haydarabad Bölgesi için 1958–2014 gözlem periyodunda kaydedilen çeşitli parametreleri kullanarak 1, 6 ve 12 aylık zaman ölçeklerinde SYİ ve SYEİ kuraklık indekslerini tahmin etmişlerdir. Tek değişkenli

Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) istatistiksel modelini, çok değişkenli girdi kullanan Uzun-Kısa Süreli Bellek (UKSB) derin öğrenme modeliyle karşılaştırmışlardır. Bu çalışma sonucunda, UKSB modelinin ARIMA modeline göre zaman ölçeği arttığında daha iyi sonuçlar verdiği görülmüştür [59].

Huang ve ark. (2019), Çin'in en büyük ikinci nehri olan Sarı Nehrin orta kesimlerinde bulunan Lanzhou bölgesindeki kuraklığı tahmin etmek için Kopula entropisi ile Genel Regresyon Sinir Ağını (GRSA) birleştiren bir yöntemi kullanmışlardır. Tahmin modelinin giriş verisi olarak kuraklığa etki eden iklim parametreleri seçilmiştir. Elde edilen sonuçlara göre bu model kuraklık tahmininde oldukça başarılı olmuştur. Ayrıca bu yaklaşımın iklim faktörlerine bağlı meydana gelen meteorolojik olayların tahmininde de rahatlıkla kullanılabileceği belirtilmiştir [60].

Dikshit ve ark. (2020), şiddetli kuraklıkların yaşandığı Avustralya'nın New South Wales bölgesinde SYİ kuraklık değerlerini tahmin etmek için yığınlı Uzun-Kısa Süreli Bellek (Y-UKSB) adı verilen yeni bir yaklaşım önermişlerdir. 1901–2018 yılları arası için hesaplanan SYİ kuraklık değerleri, eğitime ve test verisi şeklinde tahmin modelinde giriş verisi olarak kullanılmıştır. Y-UKSB tahmin modeli, kapasitesinin anlaşılabilmesi için Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA) gibi diğer makine öğrenmesi yöntemleri ile kıyaslanmıştır. Model sonuçlarına göre derin öğrenme yöntemi olan Y-UKSB diğer yöntemlere göre özellikle uzun zaman dilimlerinde kuraklık tahmininde daha başarılı sonuçlar vermiştir [61].

Kaur ve Sood (2020), yaygın olarak kullanılan kuraklık indekslerinin bölgesel olması nedeniyle küresel olarak kullanılabilecek bir indekse ihtiyaç olduğunu belirtmişlerdir. Bundan dolayı, mevcut kuraklık koşullarının ve kuraklık olasılıklarının daha güvenilir bir şekilde ele alınacağı çerçeve bir model önermişlerdir. Bu çerçeve model için Yapay Sinir Ağları (YSA), Genetik Algoritma ile optimize edilmiş YSA ve Derin Sinir Ağları (DSA) yeteneklerinden faydalanılmıştır. Ayrıca üç farklı iklim bölgesi ve üç farklı zaman ölçeğindeki kuraklık koşullarını öngörebilmek adına Destek Vektör Regresyonu (DVR) yöntemi kullanılmıştır. DSA modelinin kuraklık analizlerinde daha doğru, daha güvenilir ve daha özgün bir performans gösterdiği sonucuna ulaşılmıştır [62].

Kermani ve Hesaroeeyeh (2020), İran'ın güneydoğusunda bulunan Kerman şehrindeki kuraklık koşullarını izleyebilmek amacıyla Standartlaştırılmış Yağış İndeksi (SYİ) verilerini kullanarak Bulanık Mantık (BM)-k-En Yakın Komşu (KEYK) algoritmasına dayalı yeni bir yaklaşım önermişlerdir. Önerilen bu model sonucuna göre bölgede son yıllarda ciddi oranda kuraklık artışları ve yağış açığının olduğu görülmüştür [63].

Mokhtar ve ark. (2021), Çin'in Tibet Platosunda 1980–2019 yılları arasındaki Standartlaştırılmış Yağış Evapotranspirasyon İndisi (SYEI) kullanarak kuraklık analizini gerçekleştirmek için makine öğrenmesi yöntemlerinden oluşan bir kombine modeli önermişlerdir. 3 ve 6 aylık SYEI kuraklık değerlerini tahmin edebilmek için Evrişimli Sinir Ağları (ESA), Uzun-Kısa Süreli Bellek (UKSB), Rastgele Orman (RO) ve Aşırı Gradyan Artırma (AGA) derin öğrenme yöntemlerini kullanmışlardır. Tahmin modellerinde farklı meteorolojik koşullara göre değişen 7 farklı senaryo giriş verisi olarak alınmış olup bu senaryolardan 4. senaryoda UKSB en başarılı tahmin sonuçlarını vermiştir [64].

Maity ve ark. (2021), Hindistan'ın farklı iklim koşullarına sahip iki nehir havzasında, çeşitli hidrometeorolojik öncü değişkenlerini kullanarak kuraklık değerlendirmesi yapmak için derin öğrenme tabanlı bir Evrişimli Sinir Ağı (ESA) tahmin modelini önermişlerdir. Bu modelin performansını, Destek Vektör Makinesi (DVM) makine öğrenmesi yöntemi ile karşılaştırdıklarında önerilen modelin, DVM'e göre daha iyi bir genelleme yeteneği olduğu ve daha üstün tahmin performansı gösterdiği görülmüştür [65].

Salimi ve ark. (2021), İran'da 3 farklı iklim rejimine sahip Lighvan, Navroud ve Seqez havzalarındaki meteorolojik ve hidrolojik kuraklığı izlemek amacıyla bir çalışma yapmışlardır. 1992–2016 yıllarına ait akım, yağış ve buharlaşma verileri bu çalışmada kullanılan kuraklık parametreleridir. Meteorolojik kuraklık için SYİ ve SYEI, hidrolojik kuraklık için ise Standartlaştırılmış Akış İndisi (SAİ) kullanılmıştır. Bu indisler aracılığı ile havzalardaki kuraklığın şiddetleri, süreleri ve periyotları analiz edilmiştir. Analiz sonuçları, her üç havzada da meteorolojik ve hidrolojik kuraklık arasındaki ilişkinin %99 düzeyinde anlamlı olduğunu göstermektedir [66].

Wu ve ark. (2021), Çin'in kuzeydoğusunda üç farklı iklim rejimini temsil eden üç farklı bölgede 1967–2017 yılları arasında aylık ve yıllık yağış zaman serilerine dayalı yağış ve

kuraklık çalışmaları üzerine bir çalışma yürütmüşlerdir. Kuraklık indeksi olarak Çin-Z İndeksi (ÇZİ) kullanılmıştır. Dalgacık Dönüşümü (DD), Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) ve Uzun-Kısa Süreli Bellek (UKSB) yöntemleri kuraklık zaman serilerini tanımlamak için kullanılmış ve bu seriler için yeni bir hibrit model olan DD-ARIMA-UKSB yaklaşımı oluşturulmuştur. Farklı iklim türleri ile eğitme ve test seti oranlarına bağlı olarak önerilen bu hibrit model, yağış ve kuraklık tahminlerinin doğruluğu açısından ARIMA ve UKSB yöntemlerinden daha iyi performans göstermiştir [67].

Docheshmeh ve ark. (2022), İran'ın 4 farklı bölgesindeki yağış istasyonlarının aylık yağış verilerinden hesaplanan SYİ değerlerini kullanarak Uzun-Kısa Süreli Bellek (UKSB) yönteminin kuraklık tahmin kapasitesini araştırmışlardır. 3, 6, 9 ve 12 aylık zaman ölçekleri için SYİ kuraklık değerlerinin tahmininde UKSB yöntemi, Çok Değişkenli Uyarlanabilir Regresyon Eğrisi (ÇDURE), Ekstra Ağaç (EA) ve Vektör Otoregresif Yaklaşım (VOY) teknikleri ile kıyaslanmıştır. Tüm zaman ölçeklerinde UKSB derin öğrenme yöntemi diğer tekniklere göre kuraklık tahmininde daha üstün sonuçlar vermiştir [68].

Filipović ve ark. (2022), Sırbistan'da yer alan 28 adet istasyona ait 2011–2020 yılları arasındaki meteorolojik parametreleri kullanarak dört farklı toprak tipi için toprak nemi dolayısıyla tarımsal kuraklık tahminine yönelik Uzun-Kısa Süreli Bellek (UKSB) tahmin modelini geliştirmişlerdir. Copernicus İklim Değişikliği Servisi tarafından sağlanan ERA5 meteorolojik veri seti tahmin modelinin giriş parametreleri olarak seçilmiş olup; veri setinin 2011–2016 yılları arası eğitme, 2017–2018 yılları arası doğrulama ve Eylül 2019 ile Nisan 2020 dönemleri arası ise test verisi olarak seçilmiştir. UKSB tahmin modeli, Rastgele Orman (RO) ve ARIMA yöntemleri ile kıyaslanmış olup çok iyi bir genelleme başarısıyla daha üstün sonuçlar vermiştir [69].

Zhao ve ark. (2022), Çin'in Shandong Eyaletinde 2002–2020 dönemi yağış ve buharlaşma değerlerini kullanarak SYEİ kuraklık değerlerini yeniden üretmeye yönelik bir çalışma gerçekleştirmişlerdir. Uydu sensörlerinden, arazi modellerinden ve küresel yağış değerlerinden yararlanılan bu çalışmada, kuraklığa etki eden faktörler belirlenerek Önyargı Düzeltmeli Rastgele Orman (ÖDRO), Aşırı Gradyan Artırma (AGA) ve Destek Vektör Makinesi (DVM) makine öğrenmesi yöntemleri ile regresyon modelleri

oluşturulmuştur. Bu modeller içerisinde ÖDRO tahmin model en etkili sonuçları veren model olmuştur. Bu modelden elde edilen sonuçlarına göre de SYEI kuraklık değerlerine ait mekânsal kuraklık haritaları üretilmiştir [70].

1.4.2. Türkiye’de Yapılan Kuraklık Çalışmaları

Türkiye’de kuraklıkla ilgili yapılan ilk çalışmalar, 1940’lı yıllardan itibaren başlamıştır. Tanoğlu (1943), sıcaklık ve yağış değerlerini kullanarak De Martonne yöntemi ile Türkiye’nin geneli için bir kuraklık haritası oluşturmuştur [71]. Tümertekin (1955), yine De Martonne kuraklık izleme yöntemi ile 1930–1951 yılları arası için indisin Türkiye coğrafyasındaki dağılımı üzerine bir kuraklık çalışması gerçekleştirmiştir [72].

Erinç (1957), Türkiye’nin su ihtiyacı ve kuraklık problemi üzerine bir çalışma gerçekleştirmiştir. Kendisi tarafından geliştirilen ve yıllık toplam yağışların sıcaklığa oranlanması ile bulunan Erinç indisine göre çeşitli kuraklık sınıflandırmaları yapmıştır. Bu sınıflandırmalara göre de tüm Türkiye’nin kuraklık haritaları oluşturulmuştur [73].

Erdoğan (1989), Türkiye’nin altı büyük nehir havzasının 1938–1988 yılları arasındaki yıllık deşarj verilerini analiz etmiştir. Analiz sonuçlarına göre 1954–1955, 1960–1961 ve 1972–1973 zaman dilimlerinde kuraklığın etkili olduğu rejimler görülmüştür. Ancak bu kurak rejimler çok kısa sürelerde ortaya çıkmıştır. Sadece 1970–1974 döneminde tüm ülkeyi etkisi altına alan şiddetli ve uzun süreli bir kuraklık rejimi gözlenmiştir [74].

Türkeş (1996), Türkiye’deki 91 adet meteoroloji istasyonunun 1930–1993 yıllarına ait aylık toplam yağış verilerini kullanarak yıllık yağış değişimlerinin mekânsal ve zamansal analizini yapmış ve aynı dönemde görülen meteorolojik kuraklığı incelemiştir. Yıllık ve mevsimsel yağış verilerine Mann-Kendall Sıra Korelasyon Testi uygulanmış olup yıllık yağışlarda belirgin bir azalma ve birçok zaman diliminde kurak periyotlarda artış görülmüştür [75].

Kömüşçü (1999), Türkiye’deki 40 farklı yağış istasyonunun 1940–1997 yılları arasındaki yağış verilerine göre hesaplanan SYİ değerleri üzerinden bir kuraklık analizi yapmıştır. Her istasyon için kuraklık değerlendirmeleri yapılarak sonuçları ortaya konmuştur. Ayrıca farklı iklim rejimlerini barındıran istasyonlardan bazıları için kuraklık zaman serileri çizilmiştir [76].

Sırdaş ve Şen (2001), Türkiye'nin Marmara ve Trakya bölgelerindeki Edirne, İstanbul ve Kırklareli illerinin kuraklık özelliklerini belirlemek için 1931–1991 dönemindeki 60 yıllık yağış verilerine göre hesaplanan SYİ değerlerini kullanarak SYİ sınıflandırmasına göre illere ait kuraklık periyotlarını belirlemişlerdir. İstanbul ilinde $SYİ=0$ (normal kuraklık) değerinde 27,5 ay, $SYİ=-1$ (orta kuraklık) 6 ay, $SYİ=-1,5$ (şiddetli kuraklık) 4 ay, $SYİ=-2$ (aşırı kuraklık) 2 ay olarak bulunmuştur [77].

Türkiye’de kuraklıkla ilgili yapılan çalışmalar içerisinde en kapsamlısı ve en çok referans gösterileni Sırdaş (2002)’a ait doktora tez çalışmasıdır. Bu çalışmada; Türkiye’nin kuraklık analizi, hem alansal hem de zamansal boyutta ele alınmıştır. Türkiye’nin farklı iklim kuşaklarında yer alan 60 adet istasyonun 1930–1990 yılları arasındaki yağış, sıcaklık ve bağıl nem gibi hidrometeorolojik değişkenlerine ait veriler bu çalışmada dikkate alınmıştır. SYİ ile birlikte kuraklık oranı (KO) yaklaşımı ortaya atılmış olup Türkiye’nin farklı iklim bölgelerinde ocak, nisan, temmuz ve ekim ayları için kuraklık haritaları oluşturulmuştur. Bu kuraklık haritalarının yanı sıra hem istasyonlara ait yağışların istatistik değerlerine yönelik hem de nem ve sıcaklık değerlerine yönelik dağılım haritaları oluşturulmuştur [4].

Keskin ve ark. (2008), Isparta bölgesine ait istasyonlar için Meteoroloji Genel Müdürlüğünden (MGM) alınan yağış verilerini kullanarak SYİ yöntemi ile kuraklık analizi yapmışlardır. Kuraklık analizinden elde edilen değerlere bağlı olarak Göller bölgesi için yapay zekâ yöntemlerinden Yapay Sinir Ağları (YSA) ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS) kullanılarak kuraklık tahmin modelleri geliştirilmiştir. YSA ve USBÇS sonuçları kullanılarak oluşturulan veri tabanı ile bölgenin SYİ kuraklık haritaları elde edilmiştir [78].

Bacanli ve ark. (2009), Orta Anadolu’daki 10 adet yağış istasyonunun 1964–2006 yılları arasındaki aylık ortalama yağış verilerini kullanarak 1–12 aylık zaman ölçeklerinde SYİ kuraklık değerlerini tahmin etmeye çalışmışlardır. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS) tahmin modelinin SYİ için uygulanabilirliği araştırılmış olup İleri Beslemeli Sinir Ağları (İBSA) modelinde de SYİ değerleri eğitime ve teste tabi tutularak modeller karşılaştırılmıştır. Elde edilen sonuçlar, USBÇS’nin kuraklık tahminlerinde başarılı bir şekilde uygulanabileceğini ve yüksek doğruluk oranlarına sahip olduğunu göstermiştir [79].

Doğan (2013), Konya Kapalı Havzasının kuraklık karakteristiklerini belirlemek için havzada bulunan 12 adet istasyonun 1972–2009 yılları arasındaki yağış verilerini kullanarak kuraklık analizi üzerine bir çalışma gerçekleştirmiştir. Çalışmada; 18 farklı zaman ölçeği için 6 farklı kuraklık indisini (Normal Yağış Yüzdesi (NYY), Yağış Kuyrukları (YK), Z-Skoru, Çin Z İndeksi (ÇZİ), Standartlaştırılmış Yağış İndeksi (SYİ) ve Efektif Kuraklık İndeksi (EKİ)) birbirleri ile karşılaştırarak havzadaki kuraklığın kategorizasyonu, süreleri ve genlikleri belirlenmiştir [29].

Yetmen (2013), yarı kurak bir iklim kuşağında bulunan Türkiye'deki yağışların zamansal ve mekânsal değişimi üzerinde dominant bir etkisi olan Kuzey Atlantik Salınımın (KAS) meteorolojik kuraklık ve bununla bağlantılı hidrolojik ve tarımsal kuraklık olaylarını da aynı ölçüde kontrol ettiğini ispatlamak için istatistik yöntemlere dayalı bir çalışma yapmıştır. 1975–2008 yılları arasında meydana gelen kuraklık olaylarının Türkiye'deki zamansal ve mekânsal dağılımını yaparak kuraklığın farklı zaman ölçekleri için hangi bölgelerde kalıcı olduğu belirlenmiş ve farklı kuraklık seviyelerine göre kuraklık şiddetinin ve olasılığının mekânsal dağılımı yapılmıştır [22].

Biçkici ve Kahya (2017), Konya Kapalı Havzasının doğusunda yer alan Niğde istasyonunun 1970–2014 yılları arasındaki 3 ve 6 aylık kuraklık koşullarını tahmin edebilmek için Lineer Genetik Programlama (LGP) modeli üzerine çalışmışlardır. Kuraklık göstergeleri olarak Güney Salınım İndeksi (GSİ) ve Palmer Kuraklık Şiddet İndisi (PKŞİ) kullanılmış olup 3 ve 6 aylık LGP kuraklık tahmin modelinin GSİ ile daha uyumlu olduğu ve daha başarılı sonuçlar verdiği ortaya konulmuştur [80].

Katip (2018), Bursa'nın 3, 6, 9 ve 12 aylık zaman ölçeklerindeki meteorolojik kuraklığını analiz edebilmek için SYİ değerlerini kullanmıştır. Bursa ilindeki 16 adet istasyonun 1984–2013 yılları arasındaki yağış verileri kullanılarak bölgedeki kuraklık incelenmiştir. Ayrıca meteorolojik değişkenler ve 12 aylık SYİ değerleri Yapay Sinir Ağlarında (YSA) modellenmiştir. YSA modelleri ile yapılan kuraklık tahminlerinin başarılı sonuçlar verdiği ortaya konulmuş olup YSA kuraklık tahmin modellerinin su kaynaklarının planlanmasında ve kuraklık risk yönetiminde oldukça önemli olacağı sonucuna varılmıştır [81].

Hezarani (2018), Yeşilirmak Havzasında 1970–2014 yılları arasındaki kuraklık durumunun belirlenmesi amacıyla 9 farklı kuraklık indisini kullanarak bir çalışma

gerçekleştirmiştir. 1, 3, 6, 12, 24, 36 ve 48 aylık zaman ölçekleri için her bir kuraklık indisi hesaplanmış ve YSA tahmin modelinde analiz edilmiştir. Elde edilen en güvenilir sonuçlara göre kuraklık haritaları oluşturulmuştur. Ayrıca 3 farklı akım gözlem istasyonu (AGİ) verileri kullanılarak, hesaplanan Akım Kuraklık İndisi (AKİ) değerleri için Levenberg Marquardt algoritması baz alınarak bir tahmin modeli oluşturulmuştur. SYİ'nin YSA modelleri başarılı sonuçlar vermişken AKİ için önerilen model başarılı olamamıştır [82].

Başakın ve ark. (2019), Kayseri Bölgesinde 116 yıllık yağış verilerinden makine öğrenme algoritmalarını kullanarak gelecekteki PKŞİ kuraklık değerlerini tahmin etmeye çalışmışlardır. Çalışmalarında; 1, 3 ve 6 aylık zaman ölçeklerinin kuraklık değerleri tahmin edilmiştir. Destek Vektör Makineleri (DVM) ve k-En Yakın Komşu (KEYK) algoritmaları kullanılarak, oluşturulan tahminlerin başarı oranı istatistiksel olarak değerlendirilmiştir. Bu çalışma, makine öğrenimi yöntemlerinin hidrolojik problemlerin çözümüne ve tahminine önemli bir katkı sağladığını göstermiştir [83].

Başakın ve ark. (2020), Adana ilinin meteorolojik kuraklığını tahmin edebilmek amacıyla 1, 3 ve 6 aylık gecikme zamanlarında kendinden kalibreli Palmer Kuraklık Şiddet İndisi (kb-PKŞİ) kullanarak kuraklık çalışması yapmışlardır. Tahmin modeli olarak Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS) yöntemi ele alınmış olup ayrıca kb-PKŞİ kuraklık verileri Ampirik Mod Ayırıştırması (AMA) tekniği ile ön işlemeye tabi tutulmuştur. Bağımsız USBÇS tahmin modeli ile hibrit AMA-USBÇS tahmin modeli performans kriterlerine göre kıyaslanmış olup, hibrit AMA-USBÇS modeli çok daha üstün sonuçlar vermiştir [84].

Katipoğlu (2020), Fırat havzası ve çevresinde yer alan 16 adet Meteoroloji Gözlem İstasyonu (MGİ) ve 18 adet Akım Gözlem İstasyonu (AGİ) verilerini kullanarak meteorolojik ve hidrolojik kuraklıkların analizini yapmıştır. Bu çalışmada; çeşitli zaman periyotları için 5 farklı meteorolojik kuraklık indeksi ve 2 farklı hidrolojik kuraklık indeksi karşılaştırılmış ve ekstrem kuraklıklar belirlenmiştir. Kuraklıkların en yoğun görüldüğü yıllar için her bir kuraklık indeksine göre zamansal ve mekânsal kuraklık risk haritaları oluşturulmuştur [85].

Özger ve ark. (2020), Antalya ve Adana illerinin 1, 3 ve 6 aylık periyotları için kendinden kalibreli Palmer Kuraklık Şiddet İndisi (kb-PKŞİ) değerlerini tahmin etmek

için bir çalışma gerçekleştirmişlerdir. Bu çalışmada; Ampirik Mod Ayırıştırma (AMA) ve Dalgacık Dönüşümü (DD) ön işleme teknikleri ile birlikte bağımsız M5 model ağacı, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS) ve Destek Vektör Makine Regresyonu (DVMR) yöntemlerini kullanmışlardır. Modellerden elde edilen sonuçlara göre; DD tahminleri, AMA tahminlerinden daha doğru sonuçlar vermiştir ve uygun dalgacık tipinin seçilmesinin sonuçlar üzerinde önemli bir etkiye sahip olduğu görülmüştür [86].

Jalilzadnezamabad (2021), Türkiye’de Marmara Bölgesinde yer alan 10 adet istasyonun 1960–2016 yılları arasındaki yağış verilerinden elde edilen Palmer Kuraklık Şiddet İndisi (PKŞİ) değerleri ile geleceğe dönük kuraklık tahmininde bulunabilmek için çeşitli modeller geliştirmiştir. 1–12 ay arasında değişen gecikme zamanları için oluşturulan bu modeller; bağımsız Bulanık Mantık (BM), k-En Yakın Komşu (KEYK) algoritması ve Destek Vektör Makineleri (DVM) modelleri ve dalgacık dönüşümü ile oluşturulan hibrit D-BM, D-DVM ve D-KEYK modelleridir. Hibrit dalgacık dönüşümlü modellerin özellikle 6 gecikme zamanındaki kuraklık tahmin becerileri dalgacıksız modellere göre oldukça iyi performanslar göstermiştir [87].

Duvan ve ark. (2021), Sakarya havzasında görülen meteorolojik kuraklığın zamansal ve alansal özelliklerine iklim değişikliğinin etkisini araştırmışlardır. Yapılan bu çalışmada; havzada bulunan istasyonlara ait aylık toplam yağış verileri ile Hadley Merkezi Küresel Çevre Modeli sürüm 2 (HadGEM2-ES) küresel iklim modelinin temsili konsantrasyon yolları (Representative Concentration Pathways-RCP) 4,5 ve 8,5 senaryoları ile elde edilen yağış projeksiyonu verileri kullanılmıştır. Kuraklık şiddetini belirlemek için SYİ, kuraklığın alansal dağılımını belirlemek için de Ters Mesafe Ağırlıklı Enterpolasyon Yöntemi (Inverse Distance Weighting-IDW) ve Kriging Enterpolasyon Yöntemi kullanılmıştır. Noktasal SYİ kuraklık değerleri alansal değerlere dönüştürülerek havzanın kuraklık haritaları oluşturulmuştur. Bu kuraklık haritaları üzerinden havzanın zamansal ve alansal özellikleri incelenmiştir. Ayrıca gözlemlenmiş yağış verileri ile elde edilen kuraklık şiddeti değerlerinin projeksiyon verilerine göre elde edilen değerlerden daha büyük olduğu görülmüştür [88].

Mehr ve ark. (2021), Ankara’nın 3 ve 6 aylık kısa dönem meteorolojik kuraklığını tahmin edebilmek için iki adet meteoroloji istasyonunun 46 yıllık yağış verilerini

kullanarak SYEİ sınıflandırmasına göre bir kuraklık çalışması yapmışlardır. Kuraklık tahmini üzerine yapılan bu çalışmada; yeni bir yaklaşım olarak hibrit dalgacık paketi-genetik programlama modeli (DPGP) geliştirilmiştir. Modelin etkinliği otoregresif model (AR), Genetik Programlama (GP) ve Rastgele Orman (RO) modelleri ile çapraz doğrulanmış olup, önerilen bu hibrit modelin elde edilen sonuçlara göre oldukça gerçekçi bir tahmin modeli olduğu ortaya konmuştur. AR ve RO modellerinden oldukça üstün olan bu hibrit model, bağımsız GP'nın da tahmin performansını önemli ölçüde artırmıştır [89].

Sekendur (2022), Türkiye'nin 81 il merkezine ait meteoroloji istasyonlarının 1980–2019 yılları arasındaki gözlem verilerini kullanarak; SYİ ile SYEİ indislerine göre 1, 6 ve 12 aylık zaman ölçeklerinde kuraklık analizi üzerine bir çalışma yapmıştır. Bu çalışmada; SYİ yöntemi ile FAO-56 Penman-Monteith ve Hargreaves referans evapotranspirasyon metotlarıyla hesaplanan $SYEİ_{PM}$ ve $SYEİ_{HG}$ yöntemleri karşılaştırılmıştır. Modifiye Mann-Kendall testine göre kuraklık eğilimi ve Sen'in eğim metoduna göre eğim büyüklüğü analizleri, hem zamansal hem de mekânsal olarak yapılmıştır. Bu eğilim analizlerine göre Türkiye'nin farklı bölgelerinde hem artan hem de azalan kuraklık eğilimleri tespit edilmiştir. En fazla kurak periyot ise $SYEİ_{HG}$ zaman serilerinde ikinci olarak da $SYEİ_{PM}$ zaman serilerinde bulunmuştur [90].

Çıtakoğlu ve Coşkun (2022), mevcut tez çalışması kapsamında, Türkiye'nin kuzeybatısında yer alan Sakarya ilinin kısa dönem meteorolojik kuraklığını tahmin edebilmek amacıyla 1960–2020 yılları arasındaki aylık yağış verilerinden hesaplanan 1, 3 ve 6 aylık zaman ölçekleri için SYİ değerlerini kullanarak hibrit makine öğrenmesi yöntemlerinde tahmin modelleri oluşturmuşlardır. Bu çalışmada; Yapay Sinir Ağları (YSA), Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS), Gauss Süreç Regresyonu (GSR), Destek Vektör Makine Regresyonu (DVMR), k-En Yakın Komşu (KEYK) algoritması makine öğrenmesi yöntemleri kullanılmıştır. Orijinal SYİ kuraklık değerleri Ayrık Dalgacık Dönüşümü (ADD), Varyasyonel Mod Ayırıştırma (VMA) ve Ampirik Mod Ayırıştırma (AMA) ön işleme teknikleri ile alt serilerine ayrılarak makine öğrenmesi yöntemlerinde eğitime ve test verisi olarak dâhil edilip hibrit modeller elde edilmiştir. Bu şekilde oluşturulan hibrit modeller bağımsız makine öğrenmesi yöntemleri ile karşılaştırılmış olup, hibrit tahmin modelleri bağımsız modellere göre oldukça üstün sonuçlar vermiştir. Bundan dolayı ön işleme tekniklerinin tahmin

modellerinin başarısını artırmada çok önemli bir yaklaşım olduğu sonucuna ulaşılmıştır. Ayrıca VMA ön işleme tekniği ADD ve AMA yöntemlerine göre de daha başarılıdır [91].

Latifoğlu (2022), Türkiye’deki Konya, Rize ve Şanlıurfa illerinin 3, 6, 9 ve 12 aylık SYİ kuraklık değerlerini 1 ve 3 ileri zamanları için tahmin etmeye çalışmıştır. Kuraklık tahmin çalışması için Uzun-Kısa Süreli Bellek (UKSB) ve Çift Yönlü Uzun-Kısa Süreli Bellek (ÇY-UKSB) derin sinir ağları kullanılmıştır. Elde edilen model sonuçlarına göre ÇY-UKSB tahmin modelinin daha üstün olduğu ve yüksek korelasyonlu tahminler verdiği ortaya konulmuştur [92].

Alkan (2022), Seyhan ve Ceyhan Havzalarındaki 14 adet istasyonun 1989–2020 yılları arasındaki yağış verilerini kullanarak 3, 4, 6 ve 12 aylık zaman ölçeklerinde SYİ ve SYEİ kuraklık değerlerinin tahminleri üzerine bir çalışma yapmıştır. Bu çalışmada; Ayrık Dalgacık Dönüşümü (ADD) ve Kalman Smooth Filtreleme (KSF) ön işleme teknikleri kullanılarak Yapay Sinir Ağları (YSA), Aşırı Gradyan Artırma (AGA), Destek Vektör Makinesi (DVM), Rastgele Orman (RO) ve k-En Yakın Komşu (KEYK) algoritması ile beş farklı hibrit tahmin modeli oluşturulmuştur. DVM ve Aşırı Gradyan Artırma hibrit modellerinin sırasıyla, diğer ön işleme ve filtreleme teknikleriyle oluşturulan hibrit modellere göre daha iyi performans göstermiş oldukları tespit edilmiştir [93].

Mehr ve ark. (2022), Ankara’daki Beypazarı ve Nallıhan çalışma bölgelerinin 3 ve 6 aylık kısa dönem meteorolojik kuraklığını tahmin edebilmek amacıyla Evrişimli Sinir Ağları ve Uzun-Kısa Süreli Bellek (ESA-UKSB) olarak adlandırılan yeni bir akıllı derin öğrenme modelini önermişlerdir. Bu modelde istasyonların 1971–2016 yılları arasındaki yağış verilerinden hesaplanan SYEİ değerleri kullanılmıştır. Önerilen bu akıllı tahmin modelinin doğruluğu Yapay Sinir Ağları (YSA), Genetik Programlama (GP), Evrişimli Sinir Ağları (ESA) ve Uzun-Kısa Süreli Bellek (UKSB) modelleri ile karşılaştırılmıştır. ESA-UKSB tahmin modeli sonuçları, diğer tüm modellerden daha iyi performans göstermiştir [94].

Baykal ve ark. (2023), Isparta ilinin 1929–2021 yılları arasındaki aylık toplam yağışlarını kullanarak Uzun-Kısa Süreli Bellek (UKSB) yöntemi ile gelecek 10 yılda görülmesi muhtemel hem aylık yağışları hem de SYİ kuraklık değerlerini tahmin

etmeye çalışmışlardır. Gelecek 10 yılda görülmesi muhtemel yağışlarla SYİ değerlerinin eğilimleri, temsili konsantrasyon yolları (Representative Concentration Pathways-RCP) 4,5 senaryosuna göre belirlenen yağış projeksiyonları ile karşılaştırılmıştır. Yapılan meteorolojik kuraklık tahminlerine göre yağış ve SYİ kuraklık değerlerinin senaryolarla benzer bir şekilde azalma eğiliminde olduğu görülmüştür [95].

1.5. Problem Durumu

Önceki bölümlerde detaylı bir şekilde ele alındığı üzere iklim değişikliğine bağlı olarak son dönemlerde etkileri daha da artan kuraklık felaketi, dünyada ve ülkemizde en çok tartışılan konulardan biri haline gelmiştir. Doğu Akdeniz iklim kuşağında bulunan ülkemiz için yapılan birçok bilimsel çalışmada, 2030'lu yılların başından itibaren sıcaklıkların ciddi oranda artacağı, Doğu Karadeniz Bölgesi hariç yağışların önemli ölçüde azalacağı ve başta meteorolojik kuraklık olmak üzere ülkenin büyük bir kısmında kuraklığın bütün aşamalarının görüleceği öngörülmektedir. Çalışma alanımız olan Sakarya havzası, ülke nüfusunun yaklaşık %13'ünün yaşadığı ve büyük şehir merkezlerinin yer aldığı önemli bir havzadır. Farklı iklim koşullarının görüldüğü yarı kurak bir iklim rejimine sahiptir. Havzadaki kuraklık durumunu öngörebilmek adına kuraklığın ilk aşaması olan meteorolojik kuraklığın hangi aşamada olduğu henüz kapsamlı bir çalışma ile ortaya konulmamıştır. Meteorolojik kuraklığın doğru bir şekilde belirlenmesi ve gelecekteki durumunun öngörülmesi kuraklık felaketi ile mücadelenin de ilk aşaması olacağından oldukça önemlidir. Büyük bir nüfusa sahip olan ülkemizde şiddetli kuraklıkların görülmesi durumunda başta gıda olmak üzere birçok sektör olumsuz etkilenecek bu da ülke refahını düşürecektir. Bu nedenle kuraklığın tespiti, kategorize edilmesi, zamansal ve mekânsal analizi, geleceğe dönük tahminlerle birlikte çeşitli senaryo ve projeksiyonların oluşturulması, eylem planları hazırlanması ve erken uyarı sistemlerinin kurulması, ülkemiz için elzem bir konudur. Kuraklığın mevcut ve gelecekteki durumu iyi bir öngörü ve planlama ile değerlendirip bu doğal felaketin yıkıcı etkilerini azaltmak amacıyla gerçekçi politikalar üretmek hem araştırmacılar hem de kamu kurumları açısından oldukça önemlidir. Bu bağlamda kuraklığın hem bölgesel ölçekte hem de tüm ülke ölçeğinde kısa süreler içerisinde belirlenmesi ya da tahmin edilebilmesi için gelişen teknolojilerden yararlanmak gerekir.

Kuraklık koşullarının mevcut ya da gelecekte görülmesi muhtemel durumlarına yönelik birçok çalışma yapılmıştır. Kuraklıkla ilgili yapılan son dönem çalışmaları, klasik matematiksel denklemlerden yapay zekâ tekniklerine doğru kaymıştır. Son yirmi yıllık dönemde yapay zekânın alt kümesinde yer alan makine öğrenmesi (MÖ) yöntemleri ve son on yıllık dönemde ise yine yapay zekânın alt kümesinde yer alan derin öğrenme (DÖ) algoritmaları yaygın bir şekilde kullanılmaya başlanmıştır. Bilim ve teknoloji, ilerlemesine her geçen gün büyük bir hızla devam etmektedir. Kullanılan teknikler birbirinin eksiklerini tamamlayarak ya da birbiri ile bağlantılı çalışarak problemlerin çözümünde en iyi optimizasyonları sunmak için mücadele halindedir. En kısa zamanda, en az işlem yükü ile en doğru ve en güvenilir çözümleri sunan teknikler hem insanoğlunun işini kolaylaştırmakta hem de teknolojinin önünü açmaktadır. Bu bağlamda insanoğlu için hayati öneme sahip kuraklık gibi bir konuda kullanılan tekniklerin tahmin ve öngörü becerilerini daha da artırmak oldukça önemlidir.

1.6. Araştırmanın Amacı

Bu tez çalışmasında; Türkiye'nin kuzeybatısında yer alan ve önemli nehir havzalarından biri olan Sakarya havzasındaki kısa dönem meteorolojik kuraklık değerlerinin tahmin edilmesi amaçlanmıştır. Havzanın bütününi temsil edecek şekilde seçilen 10 adet meteoroloji istasyonunun uzun yıllara ait aylık yağış verilerinden hesaplanacak olan Standartlaştırılmış Yağış İndeksinin (SYİ) 1, 3, 6 ve 12 aylık zaman ölçeklerindeki değerleri tahmin modellerinde kullanılacaktır. SYİ kuraklık değerlerinin %75'i eğitime, %25'i ise test verisi olarak kuraklık tahmin modellerinde giriş verisi olarak kullanılacaktır. Kuraklık tahmin modellerinde bağımsız modeller olarak Yapay Sinir Ağı (YSA), Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS), Destek Vektör Makine Regresyonu (DVMR), Gauss Süreç Regresyonu (GSR) ve Uzun-Kısa Süreli Bellek (UKSB) makine öğrenmesi yöntemleri ele alınacaktır. Bu yöntemlere Ayrık Dalgacık Dönüşümü (ADD), Varyasyonel Mod Ayırıştırma (VMA) ve Ampirik Mod Ayırıştırma (AMA) ön işleme teknikleri dâhil edilerek hibrit modeller elde edilecektir. Oluşturulan tüm bu modellerin kuraklık tahminindeki başarılarının performans kriterlerine göre birbiri ile karşılaştırılması sonucu en doğru ve güvenilir yöntemin belirlenmesi amaçlanmaktadır.

1.7. Araştırmanın Önemi

Sakarya havzası farklı iklim özellikleri ve yağış rejimlerini bir arada bulunduran yarı kurak bir havzadır. Bu nedenle havzadaki mevcut yağış normallerinin ve kısa dönemlerde görülebilecek muhtemel meteorolojik kuraklıkların iyi analiz edilmesi, kuraklığın ileriki aşamalarında karşılaşılan etkileri önlemek adına oldukça önemlidir. Çalışma alanımız olan Sakarya havzasında daha önceden meteorolojik kuraklık analizi ve tahminleri üzerine kapsamlı bir çalışma yapılmamıştır. Havzada mevcut durum ile gelecekte görülmesi muhtemel kuraklık durumları için bütüncül bir kuraklık öngörüsü yapılabilmesi adına bu çalışma önemlidir. Kuraklık tahmini ile ilgili çalışmalarda genellikle bir ya da iki yöntem ele alınmıştır. Bu da yöntemlerin tahmin becerilerinin kıyaslanmasında bir eksiklik olarak görülmüştür. Bu çalışmada; daha önceden kuraklık tahminlerinde başarılı sonuçlar veren dört farklı makine öğrenmesi yöntemine ek olarak henüz yaygın bir kullanımı olmayan ve derin öğrenme yöntemlerinden biri olan Uzun-Kısa Süreli Bellek (UKSB) yöntemi de kullanılmıştır. Ayrıca hidrometeorolojik zaman serilerinin analizlerinde önemli yaklaşımlardan biri olan veri ön işleme uygulaması da üç farklı yöntemle ele alınarak çalışmanın kapsamı artırılmıştır. Literatürdeki çalışmaların birçoğunda Ayırık Dalgacık Dönüşümü (ADD) başta olmak üzere tek bir veri ön işleme tekniği kullanılmaktadır. Bu çalışmada ise ADD ile birlikte Varyasyonel Mod Ayırıştırma (VMA) ve Ampirik Mod Ayırıştırma (AMA) ön işleme teknikleri de kullanılmıştır. VMA ve AMA yöntemleri genellikle bilgisayar, haberleşme, elektronik, tıp ve biyomedikal gibi alanlarda daha sık kullanılmaktadır. Hidrometeorolojik tahmin çalışmalarında VMA ve AMA yöntemleri daha yeni yeni kullanılmaya başlanmıştır. Ayrıca bu üç ön işleme tekniği ile ilgili birçok farklı ve kapsamlı kombinasyonlar (dalgacık ailesi, bant seviyeleri, gecikme zamanları vb.) denenerek en optimum tahmin sonuçlarına ulaşılmaya çalışılmıştır. ADD, VMA ve AMA yöntemleri ile alt bantlarına ya da alt serilerine ayrılan orijinal veriler makine öğrenmesi ve derin öğrenme yöntemlerine entegre edilerek hibrit tahmin modelleri oluşturulmuştur. İstasyon sayısının çokluğu, uzun dönem verilerin kullanılması, dört farklı zaman ölçeği, beş farklı yöntemin ve üç farklı ön işleme tekniğinin ele alınması ve birçok farklı model kombinasyonları ve parametrelerinin dikkate alınması nedenleriyle, mevcut tez çalışması kuraklık tahmini ile ilgili literatürde önemli bir yere sahip olacaktır.


2. BÖLÜM

MATERYAL VE YÖNTEM

2.1. Materyal


2.1.1. Çalışma Alanı

Bu çalışmada ele alınan alan, Türkiye'nin 25 nehir havzasından biri olan Sakarya havzasıdır. Sakarya havzası, Türkiye'nin kuzeybatısında yer almakta olup 63.303 km²'lik bir yağış alanı ile Türkiye yüzölçümünün (779.450 km²) 1/8'ni oluşturmaktadır [96]. Marmara, Susurluk, Akarçay, Konya kapalı havzası, Kızılırmak ve Batı Karadeniz havzaları ile komşudur. Şekil 2.1'de Sakarya havzasının konumu gösterilmiştir.



Şekil 2.1. Sakarya havzasının Türkiye'deki konumu

Havzaya ismini de veren Sakarya nehri, Kızılırmak ve Fırat nehirlerinden sonra 720 km'lik uzunluğu ile Türkiye'nin üçüncü en uzun, Kuzeybatı Anadolu'nun ise en büyük akarsuyudur. Su potansiyeli olarak Türkiye'deki akarsuların %3,4'nü oluşturan Sakarya nehri, $6,4 \cdot 10^9$ m³/yıl ortalama yıllık akışa sahiptir [97]. Porsuk çayı, Ankara çayı, Karasu çayı, Göksu çayı, Porsuk çayı ve Mudurnu çayı Sakarya nehrinin önemli yan kollarındandır. Sakarya havzası; Göksu alt havzası, Ankara alt havzası, Porsuk alt havzası, Yukarı Sakarya alt havzası, Orta Sakarya alt havzası ve Aşağı Sakarya alt havzası olmak üzere 6 adet alt havzaya ayrılmıştır. Şekil 2.2'de Sakarya havzasının alt havzaları gösterilmiştir.



Şekil 2.2. Sakarya havzasının alt havzaları

Sakarya havzası sınırları içerisinde Eskişehir, Sakarya ve Bilecik il sınırlarının tamamı Kütahya, Ankara, Konya, Bursa, Afyonkarahisar, Bolu, Kocaeli, Uşak, Çankırı ve Düzce illerinin ise bir kısmı yer almaktadır. Görüldüğü gibi Türkiye'nin başkenti olan Ankara da dâhil olmak üzere gelişmiş ve gelişmekte olan şehirler havza içerisinde yer almaktadır. Türkiye İstatistik Kurumunun (TÜİK) 2020 yılı verilerine göre havzanın nüfusu 8.635.894 kişi olup bu sayı Türkiye nüfusunun %10,4'üdür [98].


Geniş bir alana sahip olan Sakarya havzasında, çok farklı iklim tipleri görülmektedir. Yükseltelerin fazla olduğu Yukarı Sakarya alt havzasının güney kesimlerinde, Orta Sakarya havzasının doğu kesimlerinde ve Ankara alt havzasının büyük bir kısmında İç Anadolu'nun tipik karasal iklimi görülmektedir. Bu kesimlerde yazlar sıcak ve kurak, kışlar ise soğuk ve özellikle kar yağışlı geçer. Ankara alt havzasının kuzey kesimlerinde, Orta Sakarya havzasının kuzey ve kuzeydoğu kesimlerinde ve Aşağı Sakarya alt havzasının Karadeniz'e komşu kesimlerinde Karadeniz iklimi görülmektedir. Bu kesimlerde yazlar sıcak, kışlar ise ılık ve bol yağışlı geçmekte olup genellikle kurak mevsimler görülmemektedir. Porsuk alt havzası; Marmara ve Ege Bölgelerinin ılımlı iklim koşullarından İç Anadolu'nun karasal iklim koşullarına geçiş bölgesindedir. Bu havzada yazlar sıcak ve kurak, kışlar ise soğuk ve yağışlıdır. Göksu alt havzası ise Porsuk alt havzasının tersine karasal İç Anadolu iklim koşullarından yağışlı Marmara iklim koşullarına geçiş bölgesindedir. Yağış ortalamaları tüm havzanın bütününden fazladır. Bu havzada yazlar sıcak ve az yağışlı, kışlar ise biraz soğuk ve bol yağışlıdır.

Farklı iklim tiplerinin görülmesinden dolayı Sakarya havzasındaki yağış rejimleri de farklılıklar göstermektedir. Karasal iklimin hâkim olduğu kesimlerde kış aylarında özellikle kar yağışları yoğun iken yaz aylarında az yağış görülmektedir. Düşük yüksekliklere sahip havzanın aşağı kesimlerinde özellikle Karadeniz ikliminin etkili olduğu yerlerde ise hemen hemen tüm mevsimlerde yağmur şeklinde yağışlar görülmektedir. Havzanın yıllık yağış yüksekliği ortalaması yaklaşık 552 mm (1991–2020 yılları arası Türkiye ortalaması 573,40 mm)'dir. Havzanın büyük bir kısmı karasal İç Anadolu ikliminin etkisinde olduğundan dolayı görüldüğü üzere yağış ortalaması Türkiye ortalamasının altındadır. Uzun yıllar ölçümleri maksimum yağış değerlerine göre en yüksek yağış 127,70 mm olarak haziran ayında Sakarya MGI'de, en düşük maksimum yağış değeri ise 6,20 mm ile ağustos ayında Gölbaşı MGI'de ölçülmüştür. Sakarya havzasının uzun yıllar sıcaklık değerleri, yüksek rakımlı kesimlerden düşük rakımlı özellikle Sakarya ili civarına inildikçe artış göstermektedir. Uzun yıllar ortalama sıcaklık değerlerine göre, en soğuk ay ocak dönemi olurken, temmuz ayı en yüksek sıcaklıkların ölçüldüğü dönemdir. Uzun yıllar minimum sıcaklık değeri, Eskişehir'de ocak ayında -28°C olarak ölçülürken, uzun yıllar maksimum sıcaklık değeri ise Sakarya'da temmuz ayında 44°C olarak ölçülmüştür.

Sakarya havzasının ortalama yükseltisi 965 m’dir. Havzanın yükseltileri Aşağı Sakarya alt havzasının Karadeniz kıyılarında sıfır kotlarından başlar ve Göksu alt havzasında yer alan Uludağ’da 2.543 m’lik yükseltiye kadar ulaşmaktadır. Uludağ (2.543 m), Sultan dağları (2.400 m), Emir dağları (2.280 m), Türkmen Dağı (2.181 m), Köroğlu Dağı (2.378 m) ve Domaniç dağları (1.794 m) havzadaki önemli dağlardır. Ayrıca havzada eğimler yüksek olmadığından geniş düzlükler ve ovalar görülür.

2.1.2. Veri Temini ve Seçimi

Çalışmada kullanılacak olan yağış verileri, Meteoroloji Genel Müdürlüğünden (MGM) temin edilmiştir. Havza sınırları içerisinde geçmişten günümüze kadar farklı kurumların işlettiği yaklaşık 90 kadar yağış ölçümü yapan istasyon açılmıştır. Bu istasyonların bir kısmı daimi olarak bir kısmı ise ihtiyaca binaen kısa süreli olarak açılmıştır. Mevcut durumda bu istasyonların büyük bir kısmı kapalı durumdadır. Çalışmada kullanılacak olan istasyonların seçiminde; özellikle havzayı temsil etmesi, uzun dönem ölçümlerinin olması, eksik verinin olmaması ve ölçümlerin güncel olmasına dikkat edilmiştir. Şekil 2.3'te çalışmada kullanılacak meteoroloji gözlem istasyonlarının (MGİ) havzadaki konumları gösterilmiştir.




Şekil 2.3. Meteoroloji gözlem istasyonlarının (MGİ) havzadaki konumları

Tez çalışmasında; havzada yer alan 10 adet meteoroloji gözlem istasyonuna (MGİ) ait uzun dönem aylık yağış verileri kullanılacak olup bu verilerden de 1, 3, 6 ve 12 aylık zaman ölçekleri için SYİ kuraklık değerleri hesaplanacaktır. Veri setinin uzun olması makine öğrenmesi ve derin öğrenme yöntemlerinin geçmiş verileri daha iyi öğrenme ve genelleme yetenekleri açısından oldukça önemlidir. Bu yüzden olabildiğince gözlem aralığı büyük olan istasyonlar seçilmiştir. Çalışmaya dâhil edilen istasyonlara ait başlıca karakteristik bilgiler Tablo 2.1’de verilmiştir.


Tablo 2.1. Meteoroloji gözlem istasyonları (MGİ) karakteristik bilgileri

Kurum	İstasyon No	İstasyon Adı	Rakım (m)	Gözlem Aralığı	Enlem	Boylam	Yıllık Ort. Yağış Yük. (mm)
MGM	17069	Sakarya	30	1960–2021	40°76'	30°39'	847,40
MGM	17130	Ankara	887	1960–2021	39°97'	32°86'	411,50
MGM	17155	Kütahya	969	1960–2021	39°41'	29°98'	567,02
MGM	17070	Bolu	743	1960–2017	40°44'	31°36'	552,25
MGM	17752	Emirdağ	983	1964–2012	39°00'	31°14'	410,20
MGM	17728	Polatlı	886	1964–2012	39°58'	32°16'	363,47
MGM	17662	Geyve	100	1960–2012	40°52'	30°29'	644,06
MGM	17832	İlgın	1036	1968–2012	38°27'	31°89'	420,00
MGM	17726	Sivrihisar	1070	1960–2012	39°44'	31°53'	412,60
MGM	17798	Yunak	1148	1971–2012	38°82'	31°72'	450,17


Tablo 2.1’den görüleceği üzere seçilen istasyonların yükseltileri 30 m ile 1148 m arasında değişmektedir. İstasyonlar arasında yağış potansiyelinin en yüksek olduğu istasyon 847,40 mm yıllık ortalama yağış yüksekliği ile Sakarya MGİ’dir. En düşük yağış yüksekliği ise 363,47 mm ile Polatlı MGİ’dir. Çalışmada seçilen bu 10 adet MGİ’nin yıllık ortalama yağış yüksekliği ise 507,87 mm’dir. Sakarya, Ankara, Kütahya ve Bolu il merkezlerinde yer alan MGİ’lerin gözlem aralığı oldukça uzun ve günceldir. Diğer istasyonlar da hem havzayı temsil özelliği hem de gözlem aralıklarının uzun olması nedeniyle seçilmiştir. Şekil 2.4–2.7’de Sakarya, Ankara, Kütahya ve Bolu MGİ gibi büyük istasyonların yıllık toplam yağış grafikleri verilmiştir. Diğer istasyonların yıllık toplam yağış grafikleri ise eklerde verilmiştir.




Şekil 2.4. Sakarya MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği



Şekil 2.5. Ankara MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği



Şekil 2.6. Kütahya MGİ 1960–2021 dönemi yıllık toplam yağışlar grafiği



Şekil 2.7. Bolu MGİ 1960–2017 dönemi yıllık toplam yağışlar grafiği

2.2. Yöntem

2.2.1. Homojenlik ve Durağanlık Analizleri

Bir rastgele değişkenin belli bir gözlem periyodu içerisinde zamana bağlı ardışık olarak kaydedilmesi ile elde edilen ve sayısal büyüklükleri temsil eden serilere zaman serileri denilmektedir [99, 100]. Yağış, sıcaklık, buharlaşma, nem, rüzgâr gibi iklim değişkenleri ve bu değişkenlerden etkilenerek meydana gelen taşkın ya da kuraklık gibi olaylara ait seriler ise iklimsel zaman serilerini oluşturur. Bu tarz serilerin farklı amaçlarda kullanılmak üzere kurum-kuruluşlar ya da araştırmacılar tarafından kayıtları tutulur. Veri tabanında uzun dönemler boyunca kayıtları tutulan bu serilerin dağılımlarında görülen ekstrem sapmalar ya da değişimler yalnızca iklim değişkenlerine bağlı olursa yani doğal yollarla meydana gelirse bu serilere homojen iklim serileri denilmektedir. Serilerin homojenliği istatistiksel kriterlerle (standart sapma, varyans, medyan, çarpıklık ya da basıklık katsayıları vb.) yakından ilgilidir. Bu kriterler zaman serisi boyunca gözlenen trendleri, sapmaları ya da değişimleri gösterdiklerinden dolayı oldukça önemlidir. Ölçümlere bilerek ya da bilmeyerek yapılan müdahaleler, kayıt hataları, istasyon yerinin değiştirilmesi, ölçüm yönteminin değiştirilmesi, ölçüm aletlerindeki hatalar ya da kalibrasyon eksikliği ve çevresel etkiler gibi etmenler serilerin homojenliğini bozmaktadır. İklimsel zaman serilerinin homojenliği her tür analiz ve test sonucunun doğruluğunu ve güvenilirliğini artırmaktadır. Homojen olmayan serilerin varlığı analiz ve test sonuçları üzerinde kuşku bırakır. Eğer veri setinde homojen olmayan serilerin varlığı tespit edilirse analizlerde bu verilerin kullanılması doğru değildir. Böyle bir durumda homojen olmayan veriler ya homojen hale getirilmeli ya da veri setinden çıkartılmalıdır [101].

Homojenlik gibi durağanlık da iklimsel zaman serilerinin analizinde önemli bir göstergedir. Seriyi oluşturan temel etmenlerin ve sürecin zamanla değişmediği varsayımına dayanır. Durağanlık süreci, bir serinin ortalamasının ve varyansının zamanla değişmeyerek sabit kaldığı ve iki dönem arasındaki kovaryansının da zamandan bağımsız olarak sadece dönemler arasındaki gecikmeye bağlı olduğu bir süreçtir. Durağan özelliğindeki bir zaman serisi kendi ortalaması çevresinde ve sabit genişlikte salınımlar göstermektedir [102]. Durağanlık özelliği göstermeyen iklimsel

zaman serilerinin analizleri güvenilir olmayacağından bu seriler durağan hale getirilmeli ya da analizlerde kullanılmamalıdır.

Zaman serileri ile ilgili analizler, serilerin geçmiş dönem kayıtlarını kullanarak hem istatistiksel özelliklerini hem de seriyi oluşturan süreci ortaya koyar ve böylece serinin gelecekteki muhtemel durumlarının öngörülebilmesini ya da tahmin edilebilmesini sağlar. Bu tez çalışmasında ele alınan kuraklık analizinde de yağış değişkenine bağlı iklimsel zaman serileri kullanılacağından dolayı homojenlik, durağanlık ve bağımsızlık analizleri üzerinde durulmuştur.

2.2.1.1. Homojenlik, Durağanlık ve Bağımsızlık Testleri

Homojenlik testleri doğrudan ve dolaylı olmak üzere iki ana başlıkta toplanır. Verilerin elde edilmesi ve kayda alınması aşamalarında bilinen bir sebebe (istasyon yerinin değiştirilmesi, ölçüm tekniğinin değişmesi gibi) dayalı olarak veri setindeki sapmalara ya da değişikliklere yönelik yapılan düzeltmeler için doğrudan homojenlik kontrolü yapılabilir. Bilinmeyen sebeplerden dolayı veri setinin homojenliğinin kaybolması durumunda ise dolaylı homojenlik kontrolleri yapılmaktadır. Dolaylı homojenlik testleri mutlak ve göreceli testler diye ikiye ayrılır. Göreceli homojenlik testlerinde, iklimsel zaman serilerinin analizleri yapılırken ana istasyona komşu durumunda bulunan ve homojen olduğu bilinen başka bir istasyonun verileri kullanılmaktadır. Mutlak homojenlik testlerinde ise sadece ele alınan istasyonun verileri kullanılmaktadır [103]. Komşu istasyonlar arasında yüksek bir korelasyon varsa göreceli homojenlik testleri kullanılmasında sakınca yoktur. Ancak birbirine yakın olmayan, benzer fiziksel özellikleri taşımayan ve komşu istasyonun homojenliği ile ilgili tereddütler bulunan durumlarda göreceli testler homojenliği tespit etmekte başarısız olabilmektedir. Bu nedenle analizlerin daha doğru ve güvenilir olması amacıyla mutlak homojenlik testlerini kullanmak gerekir [104]. Literatürde yaygın bir şekilde kullanılan ve güvenilirliğini kanıtlamış mutlak homojenlik testleri ise şunlardır: Standart Normal Homojenlik (SNHT), Von Neumann Testi (VNT), Pettitt Testi, Mann-Whitney u Testi (MWT), Buishand Aralık Testi ve Çift Toplam Eğri Yöntemi. Bu testlerden SNHT, Pettitt Testi, MWT ve Buishand Aralık Testi hesaplanan istatistiklerin veri sayısına göre belirlenen kritik seviyelerin üstünde olması durumunda seride bir kırılma (değişim) noktasının olduğunu ve homojenlik durumunun bulunmadığını gösterir. Çift Toplam

Eğri Yöntemi, zaman serisindeki birbirinden farklı ve tutarsız dönemleri tespit ederek kırılma olmamasını sağlayan bir yöntemdir. Ayrıca bu yöntemle homojen olmayan zaman serilerindeki hatalar düzeltilerek homojen hale getirilebilmektedir. VNT ise sadece homojen olmama durumunu gösterir [105].

Durağanlık durumunun kontrolü için kullanılan en yaygın testler; birim kök analizinin geliştirilmiş hali olan Genişletilmiş Dickey-Fuller Testi (GDFT), Phillips-Perron Testi ve KPSS testidir. Ayrıca bazı durağanlık analizlerinde grafik yöntem, korelogram ve otokorelasyon fonksiyonları da kullanılmaktadır. Bahsedilen testlerden KPSS (Kwiatkowski-Phillips-Schmidt-Shin testi) testinde serilerin durağanlığı trende göre değerlendirilmekte olup tez çalışması kapsamında trend analizlerinin bulunmaması nedeniyle bu teste yer verilmemiştir. Phillips-Perron Testi de GDFT ile çok benzer olduğundan çalışmada kullanılmamıştır. Otokorelasyon fonksiyonu ise kuraklık zaman serilerindeki otokorelasyon varlığının araştırılması ve gecikme zamanlarının belirlenmesi aşamasında ayrıca ele alınacaktır.

Bu tez çalışmasında; homojenlik analizi için Standart Normal Homojenlik Testi (SNHT), Von Neumann Testi (VNT), Mann-Whitney u Testi (MWT) ve durağanlık analizi için ise Genişletilmiş Dickey-Fuller Testi (GDFT) kullanılmıştır. Bu yöntemler literatürde çok yaygın bir şekilde kullanılmaktadır [106, 107, 108, 109]. Belirtilen bu testler meteorolojik kuraklık tahmini ile ilgili bu tez çalışmasının tek parametresi olan aylık ortalama yağış verilerine uygulanmıştır.

2.2.1.1.1. Standart Normal Homojenlik Testi (SNHT)

İklimsel zaman serilerinin ele alındığı birçok çalışmada kullanılan ve güvenilirliği kanıtlanan SNHT, Alexandersson (1986) tarafından geliştirilmiştir. n yıllık zaman serisi içerisinde bir “ k ” noktası referans noktası olarak alınır ve seri ikiye bölünür. Zaman serisinin ilk “ k ” yılının ortalaması ile son “ $n-k$ ” yılının ortalamasının karşılaştırması yapılır ve test istatistiği olan $T(k)$ değeri hesaplanır.

$$T(k) = k\bar{z}_1^2 + (n - k)\bar{z}_2^2 \quad k = 1, 2, 3, \dots, n \quad (2.1)$$

Bu denklemde yer alan $\bar{z}_1$ ve $\bar{z}_2$ ifadeleri aşağıda yer alan eşitliklerle hesaplanır.

$$\bar{z}_1 = \frac{1}{k} \sum_{i=1}^k (Y_i - \bar{Y}) / s \quad (2.2)$$

$$\bar{z}_2 = \frac{1}{n-k} \sum_{i=k+1}^n (Y_i - \bar{Y}) / s \quad (2.3)$$

Eşitlik 2.1’de verilen $\bar{z}_1$ ve $\bar{z}_2$ ifadeleri sırasıyla ilk k ve son n-k yılları boyunca z_i ’nin ortalama değerleridir. Eşitlik 2.2 ve 2.3’te yer alan $\bar{Y}$ gözlem değerlerinin ortalamasını, Y_i her bir yıl için gözlem değerlerini ve s ise standart sapmayı temsil etmektedir. Seride k yılında bir kırılma (değişim) meydana gelirse bu k yılında test istatistiği olan $T(k)$ en büyük değerine ulaşır. Bu durumda nihai test istatistiği olan T_0 aşağıda verilen eşitlik ile bulunur.

$$T_0 = \max_{1 \leq k \leq n} T_k \quad (2.4)$$

Seride yer alan bütün $\bar{Y}_t$ değerlerinin benzer bir dağılımdan geldiği kabulü ile yapılan sıfır hipotezi T_0 değerinin belirli bir limit değeri aşması halinde reddedilir ve zaman serisinin homojen olmadığı sonucuna varılır (H_0 =veriler homojendir). SNHT’nin T_0 test istatistiği ile ilgili kritik limit değerleri Wijngaard ve ark. (2003) tarafından %99 ve %95 güven aralıklarında değerlendirilerek tablo haline getirilmiştir [103, 110]. Tablo 2.2’de SNHT kritik limit değerleri verilmektedir.

Tablo 2.2. SNHT %99 ve %95 güven aralıklarına göre belirlenen T_0 limit değerleri

n	20	30	40	50	70	100
%99	9,11	10,15	10,77	11,19	11,73	12,22
%95	6,95	7,65	8,10	8,45	8,80	9,15

2.2.1.1.2. Von Neumann Testi (VNT)

Von Neumann (1941) tarafından geliştirilen bu homojenlik testi, zaman serisindeki kırılma (değişim) noktasını tespit etmek yerine serinin homojen olup olmaması durumuna bakar. H_0 hipotezi veri setinin dağılımının homojen olduğunu gösterir. N yıllık bir seride ardışık farkların kareleri toplamının varyansa oranını kullanır. N_{VN} test istatistiği değeri aşağıdaki eşitlik ile bulunur.

$$N_{VN} = \sum_{i=1}^{n-1} (Y_i - Y_{i+1})^2 / \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (2.5)$$

Eşitlik 2.5’teki Y_i ifadesi n. yıla kadarki serideki gözlem değerlerini, $\bar{Y}$ ifadesi ise serinin ortalamasını temsil eder. Eğer $N_{VN}=2$ ise bu teste tabi tutulan zaman serisinin homojen

olduğunu gösterir. Eğer N_{VN} değeri 2'nin üzerinde değerler aldıysa bu serinin hızlı kırılma, salınım ya da değişime sahip olduğunu gösterir.

VNT homojenlik kontrolünde; N_{VN} değeri, kritik limit değerini aşarsa H_0 hipotezi kabul edilir. VNT'nin kritik limit değerleri ile ilgili Buishand (1981) bir çalışma gerçekleştirmiş ve bu limit değerlerini tablo haline getirmiştir [21, 103, 111]. Tablo 2.3'te VNT kritik limit değerleri verilmektedir.

Tablo 2.3. VNT %99 ve %95 güven aralıklarına göre belirlenen N_{VN} limit değerleri

n	20	30	40	50	70	100
%99	1,04	1,20	1,29	1,36	1,45	1,54
%95	1,30	1,42	1,49	1,54	1,61	1,67

2.2.1.1.3. Mann-Whitney u Testi (MWT)

Zaman serisinin aynı olasılık dağılımından gelip gelmediğini nicel olarak belirlemek amacıyla kullanılan parametrik olmayan bir homojenlik testidir. Mann ve Whitney (1947) tarafından geliştirilen bu testte temel koşul, serilerin hem kendi içinde hem de alt seri grupları arasında bağımsızlık koşulunu yerine getirmesidir [112]. İlk olarak n adet elemana sahip orijinal zaman serisi, yaklaşık aynı uzunlukta p ve q adet alt serilere ayrılır. Daha sonra orijinal zaman serisi, küçükten büyüğe doğru dizilerek elemanlara sıra numarası verilir. Değerleri eşit olan elemanlar gözlendiği takdirde, bunların her birinin sıra numarası, sıra numaralarının ortalaması olarak alınır. p adet elemana sahip ilk grup serisindeki elemanların orijinal serideki sıra numaralarının toplamı R_{MW1} , q adet elemana sahip ikinci grup serisindeki elemanların orijinal serideki sıra numaralarının toplamı ise R_{MW2} olarak ifade edildiğinde V ve W test istatistik değerleri aşağıdaki eşitlikler ile bulunur.

$$V = R_{MW1} - [p.(p + 1)]/2 \quad (2.6)$$

$$W = R_{MW2} - [q.(q + 1)]/2 \quad (2.7)$$

Eşitlik 2.6 ile 2.7'den elde edilen V ve W test istatistik değerlerinden minimum olanı nihai Mann-Whitney u test istatistiği olarak kabul edilmektedir. Serideki eleman sayısı 20'den fazla olduğunda u test istatistiği, klasik normal dağılıma uyan bir rastgele

değişken olarak kabul edilmektedir. Normal dağılımla hesaplanan u test istatistiğinin Z mutlak değeri, $\alpha/2$ aşılma olasılığına karşılık gelen Z_{kr} değerinden küçük ise seri homojen olup diğer testlerde olduğu gibi H_0 hipotezi kabul edilmektedir [107, 113].

2.2.1.1.4. Genişletilmiş Dickey-Fuller Testi (GDFT)

Genişletilmiş Dickey-Fuller Testi (GDFT), zaman serilerinin durağanlığını değerlendirmek amacıyla yaygın olarak kullanılan bir test yöntemidir. Zaman serilerindeki durağanlık, serinin karakteristik özelliklerini temsil eden denklemin köklerine bağlı olarak değişir. Karakteristik denklemin kökleri mutlak değer olarak 1'den küçükse zaman serisi durağandır. Denklemin köklerinin mutlak değer olarak 1 olması durumuna ise Birim Köklü Zaman Serisi denir ve zaman serisinin durağanlığı açısından istenilen bir durum değildir. Birim köklü zaman serileri üzerine ilk çalışmalar, Dickey ve Fuller (1979) tarafından önerilmiş olup sonraki dönemlerde geliştirilmiştir. Dickey ve Fuller (1979), birim kök üzerine yaptıkları ilk çalışmada otokorelasyon varlığını gözardı etmişlerdir. Daha sonra geliştirdikleri Genişletilmiş Dickey-Fuller Testinde (GDFT), otokorelasyon varlığını ortadan kaldırabilmek için bağımlı değişkenin gecikmeli terimleri modele eklenmiştir. Dickey ve Fuller (1979) ilk geliştirdikleri birim kök testinde önerdikleri kritik limit değerleri ve hipotezleri bu testte de kullanmaya devam etmişlerdir. Test istatistiklerini kullanırken genişletme yaklaşımındaki uygun gecikme terim sayısına karar vermek için Akaike gibi bilgi kriterleri kullanılmaktadır.

GDFT ile birim kökün varlığını araştırmak için en temel birim kök testlerinden itibaren çeşitli AR modellerinde iyileştirmeler yapılmıştır. Daha önceki testlerde belirtildiği üzere H_0 hipotezi ve karşı hipotez (H_1) kurulduktan sonra t test istatistiği, δ parametresi için hesaplanarak Dickey ve Fuller kritik limit değerleri ile kıyaslanır. GDFT için en genelleştirilmiş eşitlik aşağıda verilmiştir.

$$Y_t = \mu + \delta Y_{t-1} + \sum_{j=1}^p \beta_j \Delta Y_{t-j} + \varepsilon_t \quad (2.8)$$

Eşitlik 2.8'deki, ε_t ifadesi hata kriterini, β_j ifadesi eğim parametresini, Δ ifadesi genişletme katsayısını, μ ifadesi ise birim köke bağlı hesaplanan katsayıyı temsil etmektedir. GDFT için kabul edilen hipotezler başlıca şöyledir:

$H_0: \delta=0$ ele alınan zaman serisi durağan değildir.

$H_1: \delta < 0$ ele alınan zaman serisi durağandır [21, 100, 114].

2.2.2. Otokorelasyon Fonksiyonu

Bir değişken ile başka bir değişken arasındaki ilişki ya da bağımlılık regresyon terimi ile ifade edilmektedir. Değişken sayısı ile bağlantılı olarak basit doğrusal regresyon ve çoklu doğrusal regresyon çeşitleri bulunmaktadır. Çoklu doğrusal regresyon modelleri; normal dağılım, doğrusallık, hata terimlerinin ortalamasının sıfır olması, sabit varyans, bağımsız değişkenler arasında çoklu bağlantı olmaması ve otokorelasyon (öz ilinti) olmaması gibi varsayımlar üzerine kurulmuştur. Regresyonda değişkenlere ait hata terimleri arasında ilişki olması istenmeyen bir durum olduğundan otokorelasyon varlığı da serideki hataları artırmaktadır [115].

Otokorelasyon (öz ilinti) fonksiyonları, zaman serileri ile ilgili analizlerde hem hata terimleri üzerinden durağanlığın tespiti hem de serideki gecikme zamanlarının belirlenmesi amacıyla kullanılmaktadır. Bir serinin herhangi bir dönemdeki değeri ile bir önceki veya bir sonraki dönem değeri arasında birlikte hareket etme ilişkisi otokorelasyon olarak açıklanmaktadır. Yani zamana bağlı olarak değişen bir değişkenin t döneminde almış olduğu değerin gecikmeli $t-1$, $t-2$, $t-3$, ... , $t-n$ dönemlerindeki değerlerinden etkilenme durumudur. Gecikmeli olan bu dönemler arasındaki ilişki otokorelasyon katsayısı ile belirlenmektedir. k cinsinden tüm bu gecikmelere ait otokorelasyon katsayısı değerleri otokorelasyon fonksiyonunu meydana getirmektedir. Bir zaman serisindeki otokorelasyon katsayısı aşağıdaki eşitlik ile hesaplanmaktadır.

$$r_k = \frac{\sum_{t=1}^{T-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^T (z_t - \bar{z})^2} \quad (2.9)$$

Eşitlik 2.9'da verilen ifadelerden r_k k 'ıncı gecikmeye bağlı otokorelasyon katsayısını, z_t orijinal zaman serisini, $\bar{z}$ zaman serisinin ortalamasını, z_{t+k} ise k dönem erken zaman serisini temsil etmektedir. r_k birimsiz olup -1 ile 1 aralığında değerler alır. Durağanlık gösteren bir zaman serisinde otokorelasyonun 0'a yakın olması istenilen bir durumdur. Eğer bir zaman serisinde otokorelasyon varlığı söz konusu ise ya otokorelasyon sorunu giderilmeli ya da o zaman serisi analizlerde kullanılmamalıdır. Bir zaman serisinin gecikmeli dönemleri arasında ya da hata terimleri arasında otokorelasyon olup olmadığı çeşitli yöntemler ile tespit edilebilmektedir. Bu yöntemler özetle şunlardır:

otokorelasyon fonksiyonu, grafik yöntem, sıra testi, Durbin-Watson Testi (DWT), Von Neumann Testi (VNT)'dir [116, 117].

2.2.3. Kuraklık Analizi

2.2.3.1. Standartlaştırılmış Yağış İndeksi (SYİ)

Standartlaştırılmış Yağış İndeksi (SYİ), McKee ve ark. (1993) tarafından geliştirilmiş bir meteorolojik kuraklık indisi [34]. Kuraklık analizlerinde çok yaygın bir kullanımı vardır. SYİ'nin yaygın olarak kullanılmasının en önemli nedeni bu indisin bölgesel değil küresel olması ve bütün zaman ölçeklerinde kullanılabilmesidir. Tüm topografyalarda ve tüm iklim kuşaklarında kolaylıkla uygulanabilmektedir. Dünya'nın herhangi bir yerinde, herhangi bir zaman ölçeğinde aylık yağışlara bağlı olarak kurak veya nemli koşullar SYİ ile belirlenebilmektedir. Ayrıca SYİ, kuraklık felaketinin ilk aşaması olan meteorolojik kuraklığın izlenmesi ve değerlendirmesinde sadece yağış değişkenine bağlı olarak hesaplanmasından dolayı diğer indislere göre pratiklik sağlamaktadır.

SYİ kuraklık değerinin hesabı ile ilgili en genelleştirilmiş ifade şu şekildedir:

$$SYİ = \frac{x_i - \bar{x}_i}{\sigma_i} \quad (2.10)$$

Burada; x_i , i'nci zamandaki yağış değerini; $\bar{x}_i$, i'nci zamandaki yağışların ortalamasını ve σ_i ise standart sapmayı temsil etmektedir.

Thom (1958), yağış başta olmak üzere iklim verilerine en uygun olasılık dağılımının Gama dağılımı olduğunu kanıtlamıştır [118]. McKee ve ark. (1993) ise kuraklık üzerine yaptıkları çalışmada; meteoroloji istasyonlarında gözlemlenen yağış değerlerine ait dağılımları normal dağılıma dönüştürerek sonrasında standartlaştırma ile SYİ'nin son halini daha da geliştirmişlerdir [34]. Normal dağılıma uyan SYİ'nin istatistiksel gelişim süreci sırasıyla aşağıda özetlenmektedir.

Gamma dağılımı olasılık yoğunluk fonksiyonu şu şekilde ifade edilir:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad x > 0 \text{ için} \quad (2.11)$$

Burada; $\alpha > 0$ için α şekil parametresi, $\beta > 0$ için β ölçek parametresi, $x > 0$ için yağış değeri ve $\Gamma(\alpha)$ Gamma fonksiyonudur. Gamma fonksiyonu ise;

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy \quad (2.12)$$

eşitliği ile bulunur. Gamma dağılımı olasılık yoğunluk fonksiyonu parametreleri olan α ve β parametreleri aşağıdaki eşitlik yardımıyla bulunur.

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \text{ ve } \beta = \frac{\bar{x}}{\alpha} \quad (2.13)$$

Eşitlik 2.13'te verilen A değeri ise şu şekilde bulunur;

$$A = \ln(\bar{x}) - \frac{\sum \sqrt{\ln(x)}}{n} \quad (2.14)$$

Burada; n ifadesi yağış gözlemlerinin sayısıdır.

Ele alınan yağış serisindeki verilere ait dağılımın tahmin edilmesi gerekir. Belli bir zaman ölçeği için gözlemlenen yağış miktarının kümülatif olasılık dağılımı;

$$G(x) = \int_0^x g(x) dx = \frac{1}{\beta^{\alpha} \Gamma(\alpha)} \int_0^x x^{\alpha} e^{-x/\beta} dx \quad (2.15)$$

eşitliği ile bulunur. Eşitlik 2.15'te; $t = \frac{x}{\beta}$ ifadesi uygun yere konulduğunda;

$$G(x) = \frac{1}{\Gamma(\alpha)} \int_0^x t^{\alpha-1} e^{-t} dt \quad (2.16)$$

eşitliği elde edilir. Bu eşitlik, eksik kalan bir Gamma dağılımı fonksiyonunu göstermektedir. $x = 0$ ve $q = P(x = 0) > 0$ için Gamma dağılımı belirsizdir. $P(x = 0)$ yağış olmama olasılığıdır ve kümülatif olasılık artar. Son durumda kümülatif olasılık dağılımı aşağıdaki eşitlik ile bulunmaktadır.

$$H(x) = q + (1 - q)G(x) \quad (2.17)$$

Eşitlik 2.17'de verilen q , sıfır olma olasılığını temsil etmektedir. Yağışsız gözlem sayısını temsil eden m değerinin, n toplam gözlem sayısına bölünmesi ile q değeri hesaplanmaktadır ($q = m/n$).

$H(x)$ kümülatif olasılık değerleri, daha sonra aşağıda verilen eşitlikler ile standart normal dağılıma dönüştürülerek ortalaması 0 ve varyansı 1 olan SYİ kuraklık değerleri hesaplanmaktadır [34].

$$t = \sqrt{\ln \frac{1}{(H(x))^2}} \quad 0 < H(x) \leq 0.5 \quad (2.18)$$

$$t = \sqrt{\ln \frac{1}{(1-H(x))^2}} \quad 0.5 < H(x) \leq 1 \quad (2.19)$$

$$SYİ(t) = - \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 + d_2 t^2 + d_3 t^3} \right) \quad 0 < H(x) \leq 0.5 \quad (2.20)$$

$$SYİ(t) = + \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 + d_2 t^2 + d_3 t^3} \right) \quad 0.5 < H(x) \leq 1 \quad (2.21)$$

Eşitlik 2.20 ve 2.21’de verilen sabit değerlerden $c_0=2,51557$, $c_1=0,802853$, $c_2=0,010328$, $d_1=1,432788$, $d_2=0,189269$ ve $d_3=0,001308$ ’dir.

Gamma dağılımından standart normal dağılıma dönüştürülen SYİ, son durumda Z istatistik skorunu göstermektedir. SYİ özetle belli bir zaman ölçeğindeki yağış değerinden yağış ortalamasının çıkarılıp standart sapmaya bölünmesi ile elde edilmektedir. Ortalamaların altında ya da üstünde pozitif ya da negatif değerler olabilmektedir. Pozitif SYİ değerleri ortalamalara göre daha fazla yağışı, negatif SYİ değerleri ise ortalamadan daha az yağışı ifade etmektedir. McKee ve ark. (1993), “kurak olay” kriterini tanımlayarak SYİ değerlerinin negatif olduğu dönem boyunca kurak olayın devam ettiğini ve şiddetinin -1 ya da daha küçük olduğunu belirtmişlerdir. Kurak olay, SYİ değerleri pozitifte döndüğünde ise son bulmaktadır. McKee ve ark. (1993), ortalaması 0 ve standart sapması 1 olan standart normal dağılımlı SYİ kuraklık değerlerini daha bilimsel bir sınıflandırma ile nemli ve kurak kategorilere ayırmışlardır [34]. Tablo 2.4’te SYİ kuraklık sınıflandırması verilmektedir.

Tablo 2.4. SYİ kuraklık sınıflandırması

SYİ değerleri	Kuraklık kategorisi
2.00 ve daha büyük	Aşırı nemli
1.50 – 1.99	Çok nemli
1.00 – 1.49	Orta şiddette nemli
-0.99 – 0.99	Normale yakın
-1.00 – -1.49	Orta şiddette kurak
-1.50 – -1.99	Şiddetli kurak
-2.00 ve daha küçük	Aşırı kurak

2.2.3.2. SYİ'nin avantajları


Karmaşık bir süreç olan kuraklığın izlenmesi ve öngörülebilmesi açısından oldukça kullanışlı bir yöntemdir. Sadece aylık yağışlara bağlı hesaplanabilen ve meteorolojik kuraklığı tespit edebilen bir kuraklık indisi. Hesaplanması oldukça kolaydır. Başta PKŞİ olmak üzere diğer kuraklık indislerine göre daha az karmaşıktır. Birçok kuraklık indisi, bölgesel ihtiyaçlara göre geliştirilmiş olduğundan SYİ bu anlamda daha küreseldir. Her bir zaman ölçeği için SYİ rahatlıkla kullanılabilir. Yağış verileri özellikle kısa dönemlerde normal dağılıma uymaz iken SYİ kuraklık değerleri normal dağılıma uygun hale getirilmiştir. Bu sayede sadece kurak dönemler değil nemli dönemler de izlenebilmektedir. SYİ'nin hem hesaplanması hem de sınıflandırılması sadece olasılık ile ilgilidir [4].

2.2.4. Drought Indices Calculator (DrinC) Yazılımı

Daha önceki bölümlerde belirtildiği üzere kuraklığın tespiti, izlenmesi ve değerlendirmelerinin yapılması kuraklık olayını anlamada oldukça önemlidir. Kuraklığın şiddeti ya da büyüklüğü indisler ya da göstergelerle belirlenebilmektedir. Farklı tür ve amaçları olan kuraklık indisleri, ilk dönemlerinde genellikle ilgili denklemleri üzerinden manuel olarak hesaplanmaktaydı. Teknolojinin çok hızlı bir şekilde ilerleme kaydettiği günümüzde bu indislerin hesabına yönelik de hem bireysel araştırmacılar hem de kamu kurum-kuruluşlarınca çeşitli çalışmalar yapılmaktadır. Kuraklık indisi hesaplama yazılımlarına The SPI_SL_6, The SPATSIM, The SPEI Package, The CDI ve R Studio çalışmaları örnek verilebilir. Bu yazılımların kullanıcılarının yüksek bilgisayar ve yazılım bilgisinin yanı sıra kuraklık indisleri hesaplamalarına da hâkim olması gerekir. Tigkas ve ark. (2015), kullanıcılara kolaylık

ve pratiklik ile kuraklık hesaplamalarında işlem yükünden ve zamandan tasarruf sağlayacak Drought Indices Calculator (DrinC) adında yeni bir kuraklık hesaplama yazılımı geliştirmişlerdir [119]. DrinC, Atina Ulusal Teknik Üniversitesi'nin Doğal Afetler ve Proaktif Planlama Değerlendirme Merkezi ile Islah İşleri ve Su Kaynakları Yönetimi Laboratuvarında geliştirilmiştir. DrinC yazılımı ile Standartlaştırılmış Yağış İndeksi (SYİ), Kuraklık Keşif İndisi (KKİ), Akım Kuraklık İndisi (AKİ) ve Yağış Onlukları (YO) indislerinin değerleri yağış verilerine bağlı olarak hesaplanabilmektedir. Sadece KKİ yönteminde potansiyel evapotranspirasyon parametresi de değişken olarak kullanılmaktadır. DrinC, potansiyel evapotranspirasyonun da sıcaklık parametresine bağlı olarak hesaplanmasını sağlamaktadır.

DrinC yazılımı, kuraklık indislerinin hesaplanması konusunda oldukça kolay, kapsayıcı ve kullanıcı dostu bir yapıdadır. Ayrıca bu yazılım ücretsiz olup tüm araştırmacılara, kamu kurum ve kuruluşlarına da açıktır. Ana menü penceresinde yer alan veri yönetimi ve işlem sekmelerinden opsiyonel olarak hesap yöntemlerine yönelik çeşitli ayarlamalar yapılabilmektedir. Hesaplamalar aylık, dönemlik ya da yıllık bazda yapılabilir ayrıca veri aralığı su yılı ya da takvim yılına göre çeşitlendirilebilir. DrinC yazılımı, kendi içerisinde Gamma ya da Log-Normal olasılık dağılımlarını kullanmaktadır. Yazılım, hesaplamaları yaptıktan sonra da kullanıcılara çeşitli kolaylıklar sağlamaktadır. Hesap adımları sonrasında elde edilen sonuçlar hem Microsoft Excel formatında hem de grafiksel olarak hazır bir şekilde oluşturulabilmektedir. Şekil 2.8'de örnek olması açısından DrinC yazılımının ana menü penceresi ile veri yönetimi ve işlem sekmelerine ait ekran görüntüsü verilmektedir.



Şekil 2.8. DrinC yazılımı ana menü, veri yönetimi ve işlem sekmesi

2.2.5. Veri Ön İşleme Teknikleri

İstatistiksel çalışmaların, olasılık hesaplarının, tahmin ve sınıflandırma çalışmalarının, geçmiş ve geleceğe yönelik projeksiyonların, modellemelerin ve türlü analizin başlangıcı her zaman veridir ve bu çalışmalar farklı türde çeşitli verilere ihtiyaç duyar. Çalışmalarda ihtiyaç duyulan bu veriler yazı, görüntü, ses ya da sayısal biçimlerde elde edilmektedir. Bu veri türleri analizler ya da modeller için altlık oluşturacak olup kullanılacak olan yöntemleri de yönlendirirler. Analiz ya da modellemelerin başarıları sadece yöntemlerin performanslarına ya da tasarımlarına göre değil, aynı zamanda verilerin kalite ve uygunluğuna da bağlıdır. Kullanılan veri setinde; gürültü, tekrarlar, eksik değerler, tutarsız ve gereksiz veriler, çok büyük boyut gibi olumsuz birçok faktör bulunabilir. Bunun gibi faktörlerden dolayı kalitesiz veri, kalitesiz bilgiye ve kalitesiz bir sonuca sebep olur [120]. Veriler üzerinden daha doğru ve daha güvenilir bir model kurulabilmesi için eldeki veri setinin bir takım işlemlerden geçirilmesi gerekir. Çünkü yeryüzünde insanlar ya da makineler tarafından doğrudan işlenemeyen çok büyük bir miktarda ham veri bulunmaktadır. Ayrıca veri tabanında yönetilmek için hazır bulunan ya da mevcutta yönetilen veri hacmi eldeki sistemlerin işleme kapasitesini aşmaktadır [121]. Tüm bu sebeplerden dolayı verilerin kullanımına başlanmadan önce bazı

teknikler uygulayarak daha uygun hale getirilmesi, veri ön işlemeyi zorunlu kılmaktadır. Veri ön işleme teknikleri; ayrıştırma, normalleştirme, boyut azaltma, örnek azaltma, veri temizleme, veri birleştirme, eksik tamamlama, özellik çıkarma, öznitelik seçimi, veri dönüştürme, sinyal ayrıştırma ve sinyal işleme, gürültü sorunu giderme gibi birçok işlemi yerine getiren tekniklerdir.


Bu tez çalışmasında; hidrometeorolojik zaman serilerinin analizleri yapıldığından dolayı veri dönüştürme ve ayrıştırma, özellik çıkarma, öznitelik seçimi, boyut azaltma gibi veri ön işlemlerini yerine getiren Ayırık Dalgacık Dönüşümü (ADD), Ampirik Mod Ayrıştırma (AMA) ve Varyasyonel Mod Ayrıştırma (VMA) teknikleri ele alınacaktır.

2.2.5.1. Dalgacık Dönüşümü (DD)

Karmaşık yapıdaki zaman serilerinin ya da fonksiyonların ilk bakışta görülemeyen özelliklerini ya da gizli kalmış bilgilerini ortaya çıkartarak daha işlevsel hale getirmek matematiksel dönüşümlerle sağlanır. Bu sayede ele alınan zaman serisi ya da bir fonksiyon basit yapı taşları ile de temsil edilebilmektedir [122]. Hidrometeorolojik değişkenlerde olduğu gibi birçok veri seti zaman serisi şeklindedir. Zaman serileri ise sinyal ve gürültü olmak üzere iki unsurdan oluşur. Sinyal, orijinal seriyi (gözlemlenen) temsil ederken gürültü ise periyodik düzensiz verileri temsil etmektedir. Bu kısımda zaman serisi ifadesi yerine orijinal seriyi temsil eden sinyal ifadesi kullanılacaktır.

Dalgacık Dönüşümü (DD) (Wavelet Transform-WT) tekniğinden bahsetmeden önce dalgacık yaklaşımını açıklamak gerekir. Sinyallerdeki en önemli parametreler hem yerel ölçekte hem de genel ölçekte zaman, süre, genlik ve frekans (sıklık) bilgileridir. Sinyallerde özellikle frekans bilgisinin doğru bir şekilde elde edilmesi yani sinyal işleme veriye dayalı yapılacak analizlerde oldukça önemlidir. Dalgacık yaklaşımının temeli, bir frekans analiz yöntemi olan Fourier Dönüşümüne (FD) dayanmaktadır [83]. FD, Fransız matematikçi ve fizikçi Jean-Baptiste Joseph Fourier'in 1882'de yazdığı "Isının Analitik Teorisi" isimli kitapta ortaya atılmıştır. FD, farklı disiplinler ve farklı değişkenlere ait tüm sinyalleri dalga formu şeklinde tanımlayan bir tekniktir. Düzensiz sinyallere ait bu dalga formları farklı frekanslara sahip birbirini izleyen ve düzenli dalgalardan oluşan sinüs ya da kosinüs fonksiyonlarının toplamı şeklinde matematiksel olarak ifade edilir. Öncesinde sinyaller doğal olarak zaman ve uzayın bir fonksiyonu olarak gösterilmekte iken, FD ile sinyaller zaman ortamından frekans ortamına


dönüştürülmektedir. Bu sayede sürekli sinüs ve kosinüs dalgaları ile temsil edilen bir sinyalin tüm frekans bilgilerine hızlı bir şekilde ulaşılabilir. Ancak matematiksel sinüs ve kosinüs fonksiyonlarından dolayı da zaman bilgisi kaybolur. Durağanlık gösteren sinyallerde FD yöntemi tek başına yeterlidir. Ancak ani değişimler ya da kırılmalar gösteren ve durağan olmayan bir sinyali analiz etmek için zaman-frekans gösterimi gerektiğinden bu hususta FD yetersiz kalmaktadır. Yani herhangi bir anda meydana gelen fiziksel olayları gözlemlemek ve bilgilerine ulaşabilmek mümkün olmamaktadır. Bu nedenle zamana bağlı değişimler gösteren sinyalleri analiz edebilmek amacıyla, Gabor (1946) Kısa Süreli Fourier Dönüşümünü (KSFD) geliştirmiştir. KSFD yöntemi, yine FD'de olduğu gibi sinyalleri frekans ortamında ele alırken frekans bileşenlerinin ne zaman gerçekleştiğini inceleyerek zaman ortamında da analiz yapabilmektedir. Ancak sinyali tüm zaman ortamında değil de küçük zaman aralıklarına bölerek bu işlemi gerçekleştirir. Bu zaman aralıkları sinyalin durağanlık özelliği gösterdiği aralıklara göre belirlenerek küçük zaman pencereleri fonksiyonları oluşturulur. KSFD'nin bu yaklaşımından dolayı bu yöntem Pencerelemiş Fourier Dönüşümü de denilmektedir. KSFD ile zaman aralıkları bölünüp daraltıldığından daha iyi zaman bilgisi ve daha kötü frekans bilgisi elde edilmektedir. Zaman aralıkları büyütüldüğünde ise daha kötü zaman bilgisi ve daha iyi frekans bilgisine ulaşılabilir. Yani KSFD'nin zaman bilgisi belirlenen zaman penceresinin genişliğine göre değişmektedir. Sadece hangi zaman penceresi içerisinde hangi frekansın gerçekleştiği bilgisini verir. Şekil 2.9'da KSFD pencere fonksiyonunun bir zaman serisine uygulanması gösterilmiştir.



Şekil 2.9. KSFD pencere fonksiyonunun uygulanması

Hem FD hem de KSFD yöntemleri tam anlamıyla zamana bağlı analizleri yapamamaktadır. Sinyalin yüksek ve düşük frekanslı bileşenleri hem zaman hem de

frekans ekseninde aynı netlikte elde edilemediğinden dolayı çözünürlük problemi oluşur. Şekil 2.10’da hem FD’nin hem de KSFD’nin temsili çözünürlükleri verilmiştir.



Şekil 2.10. FD (solda) ve KSFD (sağda) temsili çözünürlükleri


Bununla birlikte sinyallerle ilgili analizlerde ortaya çıkan bu çözünürlük problemi, temel fonksiyon olarak belirli bir uzunluğa ve değişken frekanslara sahip dalgacıkların kullanıldığı dalgacık yaklaşımı ile çözülebilmektedir [123, 124].

Hidrometeorolojiden tıpa, iktisat-ekonomiden elektronik ve haberleşmeye, bilgisayar bilimlerinden astronomiye birçok farklı alanda kullanımı olan Dalgacık Dönüşümü (DD), sinyalleri hem zaman hem de frekans ölçeğinde analiz ederek sinyallerin periyodik ve karakteristik yapılarını ortaya çıkaran bir sinyal işleme yöntemidir. DD’nin temelini, KSFD yönteminde kullanılan pencere fonksiyonlarına benzer bir işlevi olan dalgacıklar oluşturur. Bir fonksiyonun dalgacık olabilmesi için süresinin sınırlı ve ortalamasının sıfır olması gerekir. Dalgacıklar, sinyalleri farklı frekans bileşenlerine bölen ve sonrasında her bileşeni kendi ölçeğine uygun bir çözünürlükle inceleyen ve bu sinyalleri matematiksel olarak temsil eden işlevlerdir. Bu açıklama şöyle ifade edilebilir: DD ile matematiksel bir mikroskop görevi gören dalgacıklar, sinyalleri kısa zaman aralıklarında düşük ölçekte ve yüksek çözünürlükte en ince detaylarına kadar incelerken, daha uzun zaman aralıklarında ve düşük çözünürlükte daha kaba (yüzeysel) bir incelemeyi sağlamaktadır [125]. Özetle; DD ile büyük bir pencereden bir noktaya bakıldığında belli başlı özellikler fark edilirken, küçük bir pencereden bakıldığında ise küçük özellikler fark edilmektedir. [126].

DD’nin en önemli parametresi olan ve küçük dalga anlamındaki dalgacık ifadesini ilk kez 1900’lü yılların başında Alfred Haar kullanmıştır. Alfred Haar’ın aynı zamanda kendi adını taşıyan bir dalgacık fonksiyonu da bulunmaktadır. Haar dalgacığı, belirli bir

aralık dışında sıfır olduğundan sürekli değildir. Daha sonraki dönemlerde özellikle 1930'lerden sonra dalgacıklar üzerine çalışmalar yapılmıştır. 1980'lerden sonra ise dalgacıklar ve dalgacık yaklaşımı büyük bir gelişim göstermiştir. Morlet ve Grossman (1984), kuantum fiziği alanında dalgacıkları (wavelets) ilk kez tanımlamışlardır. Ancak tanımladıkları dalgacık tabiri fiziksel sezgilere dayanan bir yaklaşım biçimindeydi. Mallat (1985), dijital işaretleri işleme konusunda dalgacıklara yönelik çalışmalar yapmış olup bu çalışmalar dalgacıkların gelişimini sağlamıştır. Daubechies (1988, 1990), ayrık dalgacık teorisinin temelinin atmış ve dalgacık yaklaşımı üzerine birçok çalışma yapmıştır. Ayrıca dalgacıklar üzerine çalışmaları da olan Ronald Coifman'ın önerileri ile Coiflets dalgacıklarını yine kendisi geliştirmiştir. Yves Meyer (1993), kendi adını verdiği sürekli türeve sahip dalgacığı geliştirmiştir. Ancak bu dalgacığın da $-\infty$ 'dan $+\infty$ 'a ortalaması sıfır değildir. 1990'lerden sonra özellikle ayrık dalgacık dönüşümü üzerine çalışmalar yapılmış ve büyük gelişimler sağlanmıştır [127, 128, 129].

Fourier Dönüşümü (FD) ile Kısa Süreli Fourier Dönüşümü (KSFD) zaman-frekans ilişkisini tam olarak kuramadıklarından çözünürlük problemleri ile karşı karşıya kalırken sinyalleri zaman-ölçek bölgesinde inceleyen Dalgacık Dönüşümü (DD) daha doğru frekans bilgilerine ulaşabilmektedir. DD'nin en önemli avantajlarından biri de sinyali yerel ölçeklerde analiz edebilmesidir. FD yöntemindeki sinüs ve kosinüs fonksiyonları da $-\infty$ 'dan $+\infty$ 'a kadar sonsuz aralıkta sürekli ve yumuşak geçişli iken DD'deki dalgacıklar sınırlı zaman diliminde, düzensiz ve asimetric davranış göstermektedir. Şekil 2.11'de FD'nin sinüs fonksiyonu ile DD'nin dalgacık fonksiyonu gösterilmektedir.



Şekil 2.11. FD sinüs fonksiyonu ve DD dalgacık fonksiyonu

Dalgacık analizinin temelinde ana dalgacık şeklinde isimlendirilen özel bir dalgacık fonksiyonu bulunmaktadır. Aynı zamanda ϕ ölçekleme fonksiyonunun (baba dalgacı temsil eder) ve ψ dalgacık fonksiyonunun (ana dalgacı temsil eder) ötelenmesi ve ölçeklendirilmesiyle oluşturulan fonksiyonlar kümesi de dalgacık ailesini oluşturmaktadır [130].

Herhangi bir fonksiyonun ana dalgacık olabilmesi için şu koşulları sağlaması gerekmektedir:

1. $(-\infty +\infty)$ aralığında dalgacık fonksiyonunun integrali sıfırdır. Yani bu aralıkta dalgacık fonksiyonunun ortalaması 0'dır.

$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \quad (2.22)$$

2. $(-\infty +\infty)$ aralığında dalgacık fonksiyonunun karesinin integrali 1'e eşittir. Bu durum dalgacık fonksiyonunun birim enerjiye eşit olduğunu göstermekte olup ayrıca enerjinin korunumu ilkesini de sağladığını gösterir.

$$\int_{-\infty}^{+\infty} \psi^2(t)dt = 1 \quad (2.23)$$

3. Dalgacık fonksiyonu sinüs fonksiyonlarından farklı olarak sınırlı olmalıdır. Ayrıca sınırlı bir dalgacık fonksiyonun mutlak değerine ait integralin de sınırlı olması gerekir.

$$\int_{-\infty}^{+\infty} |\psi(t)|dt < \infty \quad (2.24)$$

$$\int_{-\infty}^{+\infty} |\sin t|dt = +\infty \quad (2.25)$$

4. Frekans değeri olan f sıfıra yaklaştığında, dalgacık fonksiyonu $\psi(t)$ 'nin FD'yi temsil eden $\psi(f)$ frekans fonksiyonu da sıfıra yaklaşmalıdır. Bu durum kabul edilebilirlik (admissibility) koşulu olarak bilinen eşitsizliği ortaya çıkarmaktadır.

$$\int_{-\infty}^{+\infty} \frac{|\psi(f)|^2}{|f|} df < \infty \quad (2.26)$$

Bir ana dalgacık fonksiyonunun bu özellikleri sağlaması, ölçeklenebilme ve dönüşüm kabiliyetleri açısından oldukça önemlidir. Buna karşın ana dalgacık fonksiyonunun

tersine φ ölçekleme fonksiyonunun (baba dalgacık) integrali 1'e eşit olup matematiksel gösterimi aşağıda verilmektedir.


$$\int_{-\infty}^{+\infty} \varphi(t) dt = 1 \quad (2.27)$$

φ ölçekleme fonksiyonu (baba dalgacık), sinyalin alçak frekansa sahip genel eğilimlerini temsil ederken; ψ dalgacık fonksiyonu (ana dalgacık), yüksek frekansa sahip sinyalin detay özelliklerini temsil etmektedir [124, 131, 132].

$\psi(t)$ ana dalgacık fonksiyonunun b ile ötelenmesi ve α ile ölçeklendirilmesi ile elde edilen $\psi_{a,b}(t)$ fonksiyonu dalgacık olarak adlandırılmaktadır ve aşağıdaki eşitlikte matematiksel gösterimi verilmektedir:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|\alpha|}} \psi\left(\frac{t-b}{\alpha}\right), \quad \alpha \neq 0, \alpha, b \in R \quad (2.28)$$

Eşitlik 2.28'de verilen α ana dalgacığın ne kadar sıkıştırıldığını gösteren ölçek parametresini, b ise yine ana dalgacığın ne kadar ötelendiğini gösteren öteleme parametresini ifade etmektedir. Bir dalgacığın ölçeklendirilmesinden kasıt dalgacığın sıkıştırılması ya da gerilmesidir. α ölçek parametresi küçüldükçe daha sıkıştırılmış bir dalgacık, büyütüldüğünde ise daha çok gerilmiş bir dalgacık anlaşılır. Sıkıştırılmış bir dalgacık küçük ölçekte yüksek frekanslar yakalarken, gerilen bir dalgacık büyük bir ölçekte daha düşük frekansları yakalamaktadır. Ölçek parametresi olan a , FD'deki 1/frekans ifadesine eşittir. Bu eşitliğe göre; küçük ölçekli bir dalgacık, yüksek frekans bilgisinden dolayı sinyalin detay bileşenlerinin belirlenmesinde, büyük ölçekli dalgacık ise sinyalin eğilim karakterinin belirlenmesinde fayda sağlar [133]. a ölçek parametresinin farklı değerlerinde dalgacık frekansının nasıl değiştiğini gösteren grafikler Şekil 2.12'de verilmiştir. Ayrıca bu grafikler üzerinde hem FD sinüs fonksiyonlarının hem de DD dalgacık fonksiyonlarının birbirlerine göre değişimleri de görülebilmektedir.



Şekil 2.12. a ölçek parametresine göre sinüs fonksiyonu ve dalgacık fonksiyonu [134]

Dalgacık Dönüşümü (DD), literatürde başlıca iki çeşide ayrılmaktadır. Bunlar; Sürekli Dalgacık Dönüşümü (SDD) ve Ayırık Dalgacık Dönüşümü (ADD)'dür.

2.2.5.1.1. Sürekli Dalgacık Dönüşümü (SDD)

Sürekli Dalgacık Dönüşümü (SDD) (Continuous Wavelet Transform-CWT), zaman ve ölçek değişkenlerine bağlı olarak sinyallerin özelliklerini belirlemeye yönelik önemli bir yaklaşımdır. SDD, analiz edilen sinyal ile dalgacık fonksiyonunun ölçeklendirilmiş ve ötelenmiş durumlarının tüm zaman değerlerinde çarpılarak toplanması sonucu elde edilir. KSFD'deki pencere fonksiyonunun gerçekleştirdiği işleve benzer şekilde burada da sinyaller farklı büyüklükteki pencerelere ayrılarak dalgacık fonksiyonu ile çarpılır. KSFD yönteminde zamana bağlı pencere uzunluğu sabit olduğundan sinyalin sadece o aralıktaki özellikleri belirlenebilirken SDD yöntemindeki zaman pencereleri değişken olduğundan her bir zaman için sürekli analizler yapılabilmektedir. Ana dalgacıktan elde edilen dalgacık fonksiyonu daha önce Eşitlik 2.28'de verilerek açıklanmıştı. Son durumda SDD'nin matematiksel gösterimi şu şekildedir;

$$C(\alpha, b) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{|\alpha|}} \psi\left(\frac{t-b}{\alpha}\right) dt, \quad \alpha > 0 \text{ için} \quad (2.29)$$

Burada; C ; dalgacık dönüşümü sonucunda elde edilen sürekli dalgacık katsayısını ifade etmekte olup α ve b 'nin birer fonksiyonudur. $x(t)$ ise analiz edilecek olan sinyali temsil etmekte olup her bir zaman için ölçek ve öteleme parametrelerine bağlı olarak değerler almaktadır. ψ dalgacık fonksiyonunun pencere fonksiyonu olması ve $x(t)$

fonksiyonunun ters dalgacık dönüşümü ile elde edilebilmesi için çift katlı integral kullanılarak;

$$x(t) = \iint C(\alpha, b) \psi\left(\frac{t-b}{\alpha}\right) d\alpha db \quad (2.30)$$

eşitliği elde edilir. Eşitlik 2.29 ve 2.30'daki hesaplamalar kullanılarak sinyal ile dalgacık fonksiyonunun ölçeklendirilmiş ve ötelenmiş durumlarının çarpılması sonucu sürekli dalgacık katsayıları, devamında da sinyal fonksiyonuna ulaşılabilir. C sürekli dalgacık dönüşüm katsayıları, dalgacık ile sinyal arasındaki ilişkiyi ortaya koyma hususunda oldukça önemlidir. SDD yöntemi ile ana dalgacık gerildiğinde (ötelendiğinde), dalgacık penceresinin aralığı arttırılmakta olup sinyaldeki düşük frekanslar yakalanır. Bu sayede sinyalin kaba (yüzeysel) özellikleri belirlenir. Tam tersi ana dalgacığın sıkıştırılması (ötelenmesi) durumunda yani dalgacık penceresinin aralığının azaltıldığı durumda ise yüksek frekanslar yakalanır. Bunun faydası ise sinyaldeki daha detay bilgilere ulaşılabilmesidir [123, 135].

2.2.5.1.2. Ayrık Dalgacık Dönüşümü (ADD)

SDD'de uygun olan her bir α ölçek değeri ve b öteleme değerine göre analiz yapıldığından dalgacık dönüşüm katsayılarının hesaplama adımları uzamaktadır bu da hem zaman hem de işlem yükünü artırmaktadır. Ayrıca sinyalin neredeyse bütününün analizi yapıldığından, gereksiz birçok bilgi elde edilmektedir. Bu sorunların çözülebilmesi ve sinyallerin daha pratik bir şekilde analiz edilebilmesi amacıyla, Ayrık Dalgacık Dönüşümü (ADD) (Discrete Wavelet Transform-DWT) tekniği geliştirilmiştir. ADD, SDD gibi her bir ölçek ve öteleme değerinde işlem yapmak yerine, bunların alt kümesinde yer alan belli başlı ölçek ve öteleme gruplarını ele alarak sinyalleri analiz etmektedir. Sinyalin bütününde dalgacık dönüşüm katsayılarını hesaplamak yerine, sadece ele alınan belli başlı yerlerde katsayılar hesaplanmaktadır. Böylece sinyallerdeki kötü ve gereksiz bilgiler ortadan kaldırılarak, sadece işe yarayacak olan esas bilgiler elde edilmektedir. Bu sayede dalgacıkların veri setindeki gürültüleri ortadan kaldırma ve veri sıkıştırma kapasiteleri artırılmaktadır. Ayrıca zamandan ve işlem yükünden de tasarruf sağlanmaktadır. ADD'de yapılan dönüşüm işlemlerinin tersi de yapılarak orijinal sinyal fonksiyonundaki gereksiz bilgiler çıkartılır, gürültüler arındırılır ve sinyal tekrardan bir dalgacık dönüşümü ile analiz edilir [136]. ADD'nin bu pratik ve gerçekçi

yaklaşımı nedeniyle birçok farklı disiplindeki Dalgacık Dönüşümü (DD) ile ilgili çalışmalarda genellikle ADD kullanılmaktadır. Bu tez çalışmasında da ele alınan kuraklık zaman serilerinin analizinde ADD yöntemi kullanılacaktır.

ADD, birden fazla seviyede uygulanabilen ve ölçek değerleri ile öteleme değerlerini 2'nin kuvvetlerine bağlı çeşitli katsayılarla alt kümelerine ayıran bir dönüşüm tekniğidir. SDD'nin Eşitlik 2.29'da verilen genel ifadesinde;

$$\alpha = \alpha_0^m \quad (2.31)$$

$$b = nb_0\alpha_0^m \quad (2.32)$$

m ve n birer tamsayı olmak üzere, eşitlikleri yerine yazılırsa yeni elde edilen dalgacık fonksiyonu şu şekilde olmaktadır:

$$\psi_{m,n}(t) = \alpha_0^{\frac{-m}{2}} \psi(\alpha_0^{-m}t - nb_0) \quad m, n \in Z \quad (2.33)$$

Bu eşitlikte, ADD'nin ikili ölçekleme ve öteleme işlemi yapılarak $\alpha_0 = 2$ ve $b_0 = 1$ ifadeleri Eşitlik 2.31 ve 2.32'de yerine konulduğunda; $\alpha = 2^m$ ve $b = n2^m$ olmaktadır. Elde edilen bu eşitlikler, Eşitlik 2.33'te yerine yazılırsa;

$$\psi_{m,n}(t) = 2^{\frac{-m}{2}} \psi(2^{-m}t - n) \quad (2.34)$$

eşitliği elde edilmektedir. Bu şekilde yapılan ikili ölçekleme ve öteleme işlemi daha sonra bahsedilecek olan filtreleme işleminin de temelini oluşturmaktadır.

En son durumda $\alpha = 2^m$ ve $b = n2^m$ ifadeleri ile Eşitlik 2.34, SDD'nin genel eşitliğinde yerine konulursa ADD dalgacık katsayısına ait matematiksel gösterim şu şekilde olmaktadır:

$$A_{m,n} = 2^{\frac{-m}{2}} \int_{-\infty}^{+\infty} x(t) \psi(2^{-m}t - n) dt \quad (2.35)$$

Eşitlik 2.35'te verilen $A_{m,n}$ ifadesi, ADD ile hesaplanan dalgacık dönüşüm katsayısını göstermektedir. Dalgacık dönüşüm katsayılarının büyük olması sinyalle DD arasındaki ilişkinin iyi olduğunu göstermektedir [122, 137].

ADD ile sinyal işleme çalışmalarının en önemli aşamalarından biri de ayrıştırma işlemidir. Ayrıştırma, bir sinyali ardı ardına yüksek ve alçak geçiren filtrelerden geçirerek ikiye bölme işlemidir. Bu şekilde yapılan filtreleme işlemi ile sinyal farklı frekans bantlarına ayrılabilir. Sinyal fonksiyonu olan $x(t)$, ilk olarak yüksek geçiren filtre ($g(k)$) ve daha sonra ise alçak geçiren filtre ($h(k)$)'den geçirilir. Sinyalin filtrelerle ayrıştırılması sonrasında $g(k)$ ve $h(k)$ için dalgacık dönüşüm katsayıları elde edilir. Filtrelere ait matematiksel gösterimler aşağıda verilmiştir.

$$g(k) = \sum_n x(t)g(2k - t) \quad (2.36)$$

$$h(k) = \sum_n x(t)h(2k - t) \quad (2.37)$$


ADD'de uygulanan filtreleme işleminde, yüksek geçiren ve alçak geçiren filtreler birbirinden bağımsız olmayıp aralarındaki ilişki aşağıdaki eşitlikte verilmiştir.

$$g(L - 1 - k) = (-1)^k h(k) \quad (2.38)$$

Burada; L ifadesi filtre uzunluğunu temsil eder ve çift sayı olmalıdır.

Daha önce de bahsedildiği gibi küçük ölçekli bir dalgacık, yüksek frekans bilgisinden dolayı sinyalin detay (detail) bileşenlerinin belirlenmesinde, büyük ölçekli dalgacık ise sinyalin yaklaşım (approximation) karakterlerinin belirlenmesinde fayda sağlamaktadır. ADD kullanılarak, alt bantlardan yaklaşım (A) ve detay katsayıları (D) elde edilebilmektedir. Yaklaşım katsayıları (A), alçak frekans bileşenlerini temsil ederken detay katsayıları (D) ise yüksek frekans bileşenlerini temsil eder. Bir sinyalde özellikle aranan ya da istenilen bilgiler genellikle alçak frekans bileşenlerinden elde edilir [138].

ADD yöntemi ile bir sinyale birden fazla ayrıştırma işlemi uygulanabilmektedir. Bu nedenle ADD ile ayrıştırma işlemi çoklu çözünürlük analizine uygundur. Çoklu çözünürlük analizi; bir sinyalin ayrıştırma işleminin filtreleme yapılarak ardı ardına olacak şekilde devam etmesi ve her ayrıştırma seviyesinde sinyalin yaklaşım bileşeninin (A) tekrar ayrıştırılmasıdır. Şekil 2.13'te ADD ile yapılan örnek bir ardışık ayrıştırma işlemi verilmektedir.



Şekil 2.13. ADD ile yapılan n. dereceden ardışık ayrıştırma işlemi

Şekil 2.13'te verilen ardışık ayrıştırma işleminin matematiksel gösterimleri şu şekildedir:

$$x(t) = A_1 + D_1 \quad (2.39)$$

$$x(t) = A_2 + D_2 + D_1 \quad (2.40)$$

$$x(t) = A_3 + D_3 + D_2 + D_1 \quad (2.41)$$

$$x(t) = A_n + D_n + \dots + D_1 \quad (2.42)$$

ADD ile yapılan ardışık ayrıştırma işleminin önemli hususlarından biri ayrıştırma seviyesinin (bant seviyesi) belirlenmesidir. Çoklu çözünürlük analizine uyan bu işlem teorik olarak sonsuza kadar götürülebilir. Bununla ilgili olarak literatürde;

$$2^L = N \quad (2.43)$$

eşitliği verilmiştir. N veri adedini, L ise yapılacak maksimum ayrıştırma seviyesini (bant seviyesi) göstermektedir. Ancak yine zaman ve işlem yükü düşünüldüğünde ayrıştırma seviyesinin uygun bir değerde tutulması ve analizin bu seviyeye göre yapılması gerekmektedir. Deneme yanılma ya da analiz yapanın tecrübelerine göre bu değer belirlenebilmektedir [122].

2.2.5.1.3. Dalgacık Aileleri

Dalgacık Dönüşümünün (DD) en önemli hususlarından biri de dalgacık analizinde kullanılacak olan dalgacık ailesinin belirlenmesidir. Ana dalgacık fonksiyonu ve baba dalgacık fonksiyonun bir araya gelerek oluşturduğu fonksiyon, dalgacık ailesi fonksiyonunu meydana getirmektedir. Dalgacık analizlerinde kullanılmak üzere günümüze kadar birçok dalgacık ailesi önerilmiştir. Dalgacık ailelerinin birbirlerinden farklı özellikleri bulunmakta olup farklı sinyallerle uyum içerisinde bulunabilirler. Sinyalin durumuna ve alanına göre deneme yanılma yoluyla en uygun olabilecek dalgacık ailesi belirlenmelidir.

Dalgacık ailelerine ait farklı ölçek ve ötelenme parametreleri, dalgacık katsayıları, birleşme noktaları, fonksiyon özellikleri, süreklilik ya da ayırık olma özellikleri, ortogonalite ya da biortogonalite gibi birçok kriter söz konusudur. Literatürde en çok tercih edilen dalgacık aileleri şunlardır: Haar, Daubechies, Symlets, Coiflets, Biortogonal, Ters Biortogonal, Meyer, Meyer'in Ayırık Yaklaşımı (Discrete Approximation of Meyer), Gauss, Karmaşık Gauss, Meksika Şapkası (Mexican Hat), Morlet, Karmaşık Morlet, Shannon, Frekans B-Spline (Frequency B-Spline) ve Fejer-Korovkin. Bu dalgacık ailelerinin kendi içerisinde de farklı format ve versiyonları bulunmaktadır [139]. Dalgacık aileleri birçok kritere göre sınıflandırılabilir ancak en temelde sürekli ya da ayırık olma durumuna göre ikiye ayrılır. Haar, Daubechies, Symlets, Coiflets, Biortogonal, Gauss, Meksika Şapkası, Morlet, Meyer ve Shannon dalgacıkları, SDD'ye uygun; Haar, Daubechies, Symlets, Coiflets, Biortogonal dalgacıkları ise ADD'ye uygun dalgacıklardır. Görüldüğü gibi iki dönüşüm yönteminde de kullanılabilen dalgacık aileleri bulunmaktadır. Bir diğer önemli dalgacık ailesi özelliği de birleşme noktalarının sayısıdır. Birleşme noktaları, dalgacıkların sinyale yakınsama mertebelerini göstermektedir. Daha önce bahsedildiği üzere DD sonrasında elde edilen dalgacık katsayılarının oluşturduğu polinomun derecesi, dalgacığın sahip olduğu birleşme noktası sayısından en fazla 1 eksik ise analiz edilen sinyal tek bir dalgacık katsayısı ile temsil edilebilmektedir. Yani özetle; bir dalgacık ailesinin sahip olduğu birleşme noktası ne kadar çok olursa, o kadar az dalgacık katsayısı ile sinyal temsil edilebilir [124].

Bu tez çalışmasında ele alınan DD analizlerinde; Haar, Daubechies, Symlets, Coiflets, Biortogonal, Ters Biortogonal, Fejer-Korovkin ve Meyer'in Ayrık Yaklaşımı (Discrete Approximation of Meyer) dalgacık aileleri kullanılmış olup bu dalgacık aileleri ile ilgili belli başlı özellikler sırasıyla verilmiştir.

Sayılan dalgacık aileleri içerisinde en eski ve en basit olanı Haar dalgacığdır. Alfred Haar tarafından 1910'da bulunmuş olmasına rağmen, o dönem dalgacık olarak tanımlanmamaktaydı. En az birleşme noktasına sahip olan, simetrik ve ortogonal bir dalgacıktır. Haar dalgacığının sıfıra yaklaşan moment sayısı birdir. Sinyal üzerinde sabit bir dalgacık aralığında analizlerini yapar. Hızlı ve basit olması, hem SDD'de hem de ADD'de kullanılabilmesi, iyi bir hafızasının olması ve tersine dönüşüm yapabilmesi avantajları olarak sayılabilir [140].

Daubechies dalgacığ, Ingrid Daubechies (1990) tarafından önerilmiş olup Haar dalgacığının daha karışık ve daha gelişmiş bir halidir. Daha karışık bir yapıda olmasından dolayı uzun hesaplamalar ve işlem yükü fazladır. Farklı alanlarda çok yaygın bir kullanımı olan önemli bir dalgacıktır. Simetrik olmayan ve ortogonal özelliklerine sahiptir. Sıfıra yaklaşan bu momentlerin sayısı filtre uzunluğunun (L) yarısına eşit olmaktadır. Daubechies dalgacığında sıfıra yaklaşan momentlerin sayısı 8'dir. Bundan dolayı daha uzun dalgacık filtreleri ile yüksek mertebeli durağan olmayan stokastik süreçlerden, durağan dalgacık katsayı vektörleri elde edebilmektedir. Hem SDD'de hem de ADD'de kullanılabilir [141].

Symlets dalgacığ; Daubechies tarafından geliştirilmiş olup Daubechies dalgacıklarına benzer özellikler taşımaktadır. Simetrik, ortogonallik, biortogonallik ve kompakt desteğe sahip olma özellikleri vardır. N derece olmak üzere, simetrik dalgacığın uzunluğu $2N-1$ kadardır. Sıfır moment sayısı ölçek fonksiyonu için N 'dir. Hem SDD'de hem de ADD'de yöntemlerinde kullanılır.

Coiflets dalgacığ; simetriye yakın özellik gösterirler ve ortogonal analiz yaparlar. Sıfır moment sayısı ölçek fonksiyonu için $2N$, dalgacık fonksiyonu için $2N-1$ 'dir. Hem SDD'de hem de ADD'de yöntemlerinde kullanılmaktadır.

Biortogonal dalgacıkları, simetrik ve biortogonal özelliktedirler. Biortogonal dalgacığının uzunluğu $2N+1$ kadardır. N_a analiz derecesi olmak üzere sıfır momentlerin

sayısı ölçek fonksiyonu için N_a-1 'dir. Yine hem SDD'de hem de ADD'de kullanılabilir. kullanılabilmektedir.

Ters Biortogonal dalgacık, Biortogonal dalgacığındaki işlemlerin tam tersi uygulanır. Hem SDD'de hem de ADD'de yöntemlerinde kullanılmaktadır.

Fejer-Korovkin dalgacığı; dalgacık dönüşümünde, alçak geçiren filtrenin sürekli olmaması nedeniyle yavaş azalan bir katsayılı frekans çözünürlüğünün ortaya çıktığı durumlarda, Fejer-Korovkin çekirdekleri aracılığı ile optimum çözünürlüğe sahip bir dizi filtreleme seçeneği sunabilen bir dalgacık ailesidir. Bu yapısı ile diğer dalgacıklardan daha farklı bir yaklaşımı söz konusu olup yine ortogonal özelliğindedir [142].

Meyer dalgacıkları, Yves Meyer tarafından geliştirilmiş olup simetrik ve ortogonal özelliğindedir. Frekans uzayına sahip olup sonsuz türevlenebilir. Süreklilik özelliğinden dolayı, SDD yönteminde kullanılması daha uygundur. Meyer'in Ayrık Yaklaşımı (Discrete Approximation of Meyer) dalgacığı ise Meyer dalgacığının Sonlu Darbe Tepkisi (SDT) (Finite Impulse Response-FIR) tabanlı bir yaklaşımıdır. ADD'de kullanıldığında, hızlı bir şekilde dalgacık katsayılarının elde edilmesini sağlar. [122, 123, 124, 129].

2.2.5.2. Ampirik Mod Ayrıştırma (AMA)

Hem doğrusal olmayan hem de durağan olmayan sinyalleri ayırtmak amacıyla Huang ve ark. (1998) tarafından geliştirilmiş bir sinyal ayrıştırma tekniğidir. Karmaşık sinyalleri çok çeşitli ve yüksek zaman-frekans ölçeğinde ayırtması nedeniyle elektronik ve haberleşme, tıp, biyomedikal, finans ve hidrometeoroloji gibi alanlarda yaygın bir şekilde kullanılmaktadır. AMA yöntemi, ele alınan sinyali tamamen ampirik, veri uyarlamalı ve yinelemeli bir şekilde belirli periyodiklikte farklı modlarına (alt sinyallerine) ayırtmaktadır. Modlar, yerel minimum ve maksimum değerleri birbirinden farklı olan alt sinyallerdir. AMA yaklaşımı ile modlar yani bir sinyaldeki yerel minimumlar ve maksimumlar yinelemeli olarak saptanabilmektedir. AMA ile ilgili ilk tanımlamalarda modlar, yerel ekstrem sayısı ve sıfır geçiş sayısı en fazla bir farklılık gösteren alt sinyal olarak ifade edilmişken daha sonraki çalışmalarda, modülasyon kriterlerine dayalı olarak İçsel Mod Fonksiyonu (İMF) (Intrinsic Mode Function-IMF)

olarak değiştirilmiştir. AMA'nın kendine özgü en önemli özelliği olan eleme (sifting) işlemi sayesinde ele alınan bir sinyal, İMF ve artık (residual) mod bileşenlerine ayrılabilir. Ayrıştırma sonucu elde edilen bu mod bileşenleri uzunluk ve zaman ölçeği bakımından orijinal sinyale benzemektedir. İMF bileşenleri, Hilbert-Huang Dönüşümü ile bulunmaktadır [143].

Bir sinyalin İMF bileşeni olarak kabul edilebilmesi için aşağıda verilen şu iki koşulu sağlaması gerekmektedir:

- 1) Yerel maksimum ve minimum uç nokta sayıları ve sıfır geçiş sayısı aynı ya da en fazla bir farklı olmalıdır.
- 2) Yerel maksimum noktalarıyla belirlenen üst zarf ile yerel minimum noktalarıyla belirlenen alt zarfın aritmetik ortalaması sıfır olmalıdır.

AMA sinyal işleme tekniğinin eleme yaklaşımı ile İMF ve artık mod bileşenlerinin elde edilmesi şu işlem adımları sonucu gerçekleşir:

- ❖ Orijinal sinyal $f(t)$ olmak üzere bu sinyalin içindeki tüm yerel maksimum ve minimum noktalar belirlenir.

$$M_i, i = 1, 2, 3, \dots, n \text{ ve } M_k, k = 1, 2, 3, \dots, n \quad (2.44)$$

- ❖ Sinyale ait yerel maksimum noktalarla üst zarf olan $M_{üst}(n)$ ve yerel minimum noktalarla alt zarf olan $M_{alt}(n)$ kübik spline enterpolasyonu ile oluşturulur.

- ❖ Oluşturulan bu alt ve üst zarflara ait aritmetik ortalama bulunur.

$$h(n) = \frac{(M_{üst}(n) + M_{alt}(n))}{2} \quad (2.45)$$

- ❖ Daha sonra bulunan bu ortalama değer giriş sinyalinden çıkartılır.

$$x(n) = f(t) - h(n) \quad (2.46)$$

- ❖ Eğer $x(n)$, İMF'nin iki koşulunu sağlıyorsa; $\varphi(n) = x(n)$ olarak İMF belirlenmiş olur. Ayrıca; $r(n) = h(n)$ kabul edilerek artık mod bileşeni de belirlenir.

- ❖ Eğer $x(n)$, İMF'nin koşullarını sağlamazsa ilk adıma geri dönülür ve işlemler tekrarlanır. Giriş sinyali maksimum ve minimum uç nokta barındırmadığı zaman İMF ve artık mod bileşenleri elde edilmiş olur ve eleme işlemine son verilir [144, 145].

AMA'nın ele alınan bir sinyali ayrıştırma ve eleme işlemleri sonucunda belirlenen İMF ve artık mod bileşenlerinin toplamı orijinal sinyali vermektedir. $f(t)$ orijinal sinyal olarak kabul edildiğinde n. dereceden bir ayrıştırma ile;

$$f(t) = \sum_{i=1}^n \text{İMF}_i + \text{Artık} \quad (2.47)$$

eşitliği elde edilmiş olur.

AMA sinyal işleme tekniğinde, her ne kadar matematiksel teoriden yoksunluk ve geçici algoritmik yapılar bulunsa da zaman serileri başta olmak üzere birçok farklı sinyalin ayrıştırma işlemlerinde kullanılmaktadır.

2.2.5.3. Varyasyonel Mod Ayrıştırma (VMA)

Huang ve ark. (1998) tarafından geliştirilen Ampirik Mod Ayrıştırma (AMA), yinelemeli bir sinyal ayrıştırma tekniği olarak daha önceki başlıkta tanıtılmıştı. AMA yönteminin gürültüye duyarlılık, örnekleme, serbestlik dereceleri ve matematiksel teori eksikliği gibi hususlarda, bıraktığı boşlukları tamamlayabilmek amacıyla yine sinyal ayrıştırma işlemlerinden biri olan Varyasyonel Mod Ayrıştırma (VMA), Dragomiretskiy ve Zosso (2014) tarafından geliştirilmiştir. VMA, sinyali alt bantlarına ayrıştırarak sinyaldeki kararsızlıkları azaltmaya ve sinyaldeki özneliliklerin belirlenmesine yarayan varyasyonel (değişken-çeşitli) bir dönüşüm tekniğidir. AMA'nın aksine özyinelemesiz yaklaşımı kabul etmiş, modların (alt sinyaller) eş zamanlı olarak çıkarıldığı, uyarlamalı bir zaman-frekans analiz yöntemidir. Modlardan kasıt yerel minimum ve maksimum değerleri birbirinden farklı olan alt sinyallerdir [146]. AMA tekniğine göre daha yeni ve daha az bilinen bir yöntem olmasına rağmen son dönemde elektronik ve haberleşme başta olmak üzere tıp, biyoloji ve diğer mühendislik alanlarında popüler bir yöntem olmuştur. Özellikle hibrit yöntemlerle oluşturulan tahmin modellerinde tahmin performanslarının iyileştirilmesi amacıyla yaygın olarak kullanılmaya başlanmıştır.

Mevcutta yaygın bir şekilde kullanılan Fourier Dönüşümü, Hilbert Dönüşümü, Dalgacık Dönüşümü, Ampirik Mod Ayırıştırma gibi ayırıştırma yöntemlerinde bazı sınırlamalar söz konusudur. Bunlara örnek vermek gerekirse; matematiksel teori eksikliği, serbestlik derecesinin sayısı, özyinelemeli ayırıştırma kaynaklı geriye doğru hata düzeltmesinin zorluğu, gürültü fonksiyonları ile baş edememe, dalgacıklarda olduğu gibi sabit ayırıştırma (bant) sınırları ve önceden tanımlanmış filtre yaklaşımıdır. VMA yönteminde ise ayırıştırma (bant) sınırları uyarlamalı olarak belirlenmekte ve karşılık gelen modlar eşzamanlı olarak tahmin edilerek bunlar arasındaki hatalar uygun bir şekilde dengelenebilmektedir. AMA yönteminde olduğu gibi İçsel Mod Fonksiyonu (İMF) (Intrinsic Mode Function-IMF) bileşenleri ile dar bant özelliklerinden yararlanarak giriş sinyali en optimum şekilde ayrıştırılıp yeniden yapılandırılır. Giriş sinyalindeki gürültü fonksiyonlarının varlığı ele alınarak bunları sinyalden ayırştırmak amaçlanır. Bu özelliği, orijinal Wiener filtresine benzemekte olup çoklu uyarlanabilir yapısı nedeniyle daha gelişmiş bir yapıdadır. Wiener filtresi, 1940'larda Norbert Wiener tarafından önerilen ve 1949'da yayınlanan bir filtredir. Sinyallerdeki gürültü miktarını azaltmayı amaçlayan bir filtreleme tekniğidir. Wiener filtresi, sinyalleri durağan olarak kabul ettiğinden uyarlanabilir özelliği bulunmamaktadır [147].

VMA yaklaşımı ile tek boyutlu bir giriş sinyalinin tanımlanmış sayıda moda ayrıştırılması sonucu elde edilen bu modlar bir optimizasyon yapısı ile tekrardan ele alınmaktadır. VMA'nın optimizasyon yapısı oldukça basit ve hızlıdır. AMA yönteminde olduğu gibi VMA'da da sinyal temelde iki ana bileşene ayrılır. Bunlar; İçsel Mod Fonksiyonu (İMF) (Intrinsic Mode Function-IMF) ve artık (residual) bileşenleridir. VMA'nın teorik yapısı kısaca aşağıda özetlenmiştir.

VMA'nın amacı, gerçek değerli bir giriş sinyali olarak alınan f değerini, girişi yeniden üretirken belirli seyreklik özelliklerine sahip dar bant genişliklerinde farklı ayırık modlara (u_k) ayırştırmaktır. Burada, spektral alandaki her modun seyrekliği, bant genişliği olarak seçilir. Başka bir deyişle, her bir k modunun, ayırıştırma ile belirlenecek olan bir merkezi frekans olarak tabir edilen ω_k etrafında çoğunlukla kompakt olduğu varsayılır. Ayrıca tüm modlara ait bant genişlikleri toplamının minimize edilmesi gerekir. Her bir u_k değeri, tek taraflı bir frekans spektrumu elde etmek için ilişkili sinyali Hilbert dönüşümü aracılığıyla hesaplamaktadır. Her bir mod için ilgili merkez frekansı ayarlanmış bir üstel ile çarpılarak modun tek taraflı frekans spektrumu

harmonik ortamda temel banda kaydırılır. Her bir moda ait bant genişliği, yeniden üretilmiş olan sinyalin Gauss yumuşaklığı aracılığı ile gradyanın karesi normunda (L^2) yani en küçük kareler yöntemiyle tahmin edilmektedir. Bahsedilen bu kısıtlanmış varyasyonel optimizasyon probleminin matematiksel gösterimi aşağıda verilmektedir.

$$\min_{\{u_k\}\{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}; \quad f(t) = \sum_{k=1}^K u_k(t) \text{ için} \quad (2.48)$$

Eşitlik 2.48’de; K toplam mod sayısını, u_k ifadesi tüm K mod sayısı kümesini, ω_k ifadesi ise merkezi frekansı temsil etmektedir. ∂_t ifadesi ise zamana bağlı kısmi türevi göstermektedir.

Yeniden sinyal üretme ile ilgili varyasyonel kısıtlamaları gösteren Eşitlik 2.48’deki problem farklı şekillerde çözülebilmektedir. Bu problemi kısıtsız hale getirmek için hem ikinci dereceden bir ceza terimi hem de Lagrange çarpanları (λ) kullanılmaktadır. Genişletilmiş Lagrange fonksiyonu aşağıda verilmektedir.

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (2.49)$$

Eşitlik 2.48’deki varyasyonel optimizasyon problemi, Eşitlik 2.49’da genişletilmiş Lagrange’ın eyer noktası olarak artık çözülebilmektedir. Eşitlik 2.49, VMA’da Çarpanların Alternatif Yön Yöntemi (The Alternating Direction Method of Multipliers-ADMM) kullanılarak tam optimizasyon problemi, yinelemeli alt optimizasyon problemlerinin bir dizisi olarak çözülmektedir [148].

VMA’da; ayrıştırılan modun merkezi frekansı, mevcut tahminlere karşılık gelen dar bantlı Wiener filtresi ile diğer tüm modların sinyal tahmin kalıntı bileşenine uygulanır. Daha sonra ise merkezi frekans, modun güç spektrumunun ağırlık merkezi olarak yeniden tahmin edilir. Bu işleme frekans karıştırma denir. En düşük frekanslı modlar yeniden üretilirken, orta güçteki frekansa sahip modlar kabul edilebilir kalitede olarak görülmektedir. En yüksek frekanslı modların ise tekrar üretilmesi zordur. Ancak VMA algoritması bu modu yeniden üretmeyi başarırorsa modun ilk ayrıştırılan halinden daha kaliteli olabilmesi de mümkündür. Merkezi frekanslar (ω_k) ile ilgili alt optimizasyon

probleminin matematiksel gösterimi, sonrasında ise Fourier alanındaki matematiksel gösterimi ve problemin çözümü sırasıyla aşağıda verilmiştir.

$$\omega_k^{n+1} = \arg_{\omega_k} \min \left\{ \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2.50)$$

$$\omega_k^{n+1} = \arg_{\omega_k} \min \left\{ \int_0^\infty (\omega - \omega_k)^2 |\hat{u}_k(\omega)|^2 d\omega \right\} \quad (2.51)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{|\hat{u}_k(\omega)|^2 d\omega} \quad (2.52)$$

En son durumda; alt optimizasyonların çözümleri, Çarpanların Alternatif Yön Yöntemi algoritması kullanılarak 1'e yerleştirilir ve uygun olduğunda doğrudan Fourier alanında optimizasyon yapılarak, yukarıda özetlenen varyasyonel mod ayrışımı için tam algoritma elde edilir.

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau(f_\omega - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (2.53)$$

Eşitlik 2.53'te verilen τ sembolü Lagrange çarpanının güncelleme oranıdır. Değişkenler varyasyonel optimizasyonlara yakınsayana kadar güncellenmektedir.

Genlik modülasyonlu ve frekans modülasyonlu bir sinyalin İçsel Mod Fonksiyonu (İMF) bileşenine ait matematiksel gösterimi aşağıda verilmiştir.

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad A_k(t) \geq 0 \text{ ve } \phi_k(t) \geq 0 \quad (2.54)$$

Eşitlik 2.54'te verilen $A_k(t)$ ve $\phi_k(t)$ ifadeleri sırasıyla k .nci modun zamana bağlı zarf fonksiyonunu ve fazını (aşama) temsil etmektedirler. k .nci modun ilgili anlık frekansının faza göre yavaş değiştiği ve negatif olmadığı varsayılır. Anlık frekansın gösterimi ise aşağıdaki eşitlikte verilmiştir.

$$w_k(t) = \phi_k(t) \quad (2.55)$$

Tüm bu optimizasyon ve ayrıştırma işlemlerinden sonra ele alınan sinyale ait İMF ve artık bileşenler elde edilmiş olur. $f(t)$ orijinal sinyal olarak kabul edildiğinde n . dereceden ayrıştırma ile;

$$f(t) = \sum_{i=1}^n \text{İMF}_i + \text{Artık} \quad (2.56)$$

eşitliği elde edilir. İMF ve artık bileşenlerin toplanması sonucu orijinal sinyal bulunmuş olur [146, 149, 150].


2.2.6. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme

2.2.6.1. Yapay Zekâ

Bilim ve teknoloji hızını kaybetmeden gelişimini sürdürmeye devam ediyor. Geliştirilen her teknoloji insanlığın yalnızca refah seviyesini ve hayat standartlarını artırmakla kalmıyor, bir sonraki yeniliğin de başlangıç noktası olarak önünü açıyor. Teknolojiler arasındaki eşsiz rekabet ise gelişmeleri daha da hızlandırmakta ve sınırları zorlamaktadır. İnsanlığın çağlar boyunca kat ettiği ilerlemeye bakıldığında ise gelecekte hangi seviyelere ulaşabileceğini tahmin etmek oldukça güçtür. Kâinatın en muhteşem varlığı olan ve aklını kullanmayı başarabilen insan türü, bu özelliğini bilgisayarlar vasıtasıyla çeşitli robotlara, makinelere, algoritmalara ve yazılımlara aktarabilmiştir. Bu sayede insan gücünden, işlem yükünden ve zamandan çok büyük bir oranda tasarruf sağlanarak daha hızlı, daha pratik, daha doğru ve daha güvenilir işlemler yapılabilmiş ve ayrıca bu teknolojilerin tüm toplumların hizmetine sunulması ile toplumların konfor alanı ve hayat standartları daha da yükselmiştir [151].

İnsanın kendi türüne özgü düşünme ve öğrenme kabiliyetlerini bilgisayarlar üzerinden çeşitli algoritmalara aktarması ve tanıtması sonucu bilgisayarlar başta olmak üzere diğer makinelerin insanlar gibi düşünmesi, öğrenmesi ve davranışlarını taklit etmesi yapay zekâ ve yapay zekâyâ bağlı diğer yapay öğrenme teknolojilerini ortaya çıkarmıştır. Yapay zekâ ile ilgili ilk tartışmalar, 2. Dünya Savaşı sırasında Almanların Enigma adlı şifreleme makinesinin şifrelerini çözmesi ile meşhur olan İngiliz matematikçi ve kriptolog Alan Mathison Turing'e (1950) ait "Makineler Düşünebilir mi? (Can Machines Think?) adlı makalesine dayanmaktadır. Bu makaledeki ana tema akıllı makinelerin icat edilerek yapay bir formda bu makinelerin insanlar gibi düşünüp düşünemeyeceği üzerineydi. Yapay zekâ (Artificial Intelligence) tabiri ise ilk olarak 1956 yılında Amerikalı bir bilgisayar bilimcisi olan John McCarthy tarafından ortaya atılmıştır [152]. Ünlü Türk matematikçi Ord. Prof. Dr. Cahit Arf (1959) ise makinelerin insana özgü olan bu düşünebilme özelliğini nasıl gerçekleştireceği üzerine fikirlerini ortaya atmıştır [153].

Zaman içerisinde, bilgisayar bilimlerindeki gelişmelere paralel olarak yapay zekâ alanında ve uygulamalarında çok önemli aşamalar kat edilmiştir. Özellikle son yirmi yıllık dönemde yapay zekâ teknikleri ve bu tekniklere yönelik algoritmalar insan hayatında önemli bir yer edinmiştir. İnsanın aklını, zekâsını, tepki ve davranışlarını taklit edebilen bu algoritmalar, günümüzün en popüler konularından olan yapay zekâ tekniklerinin, makine öğrenmelerinin ve derin öğrenme yöntemlerinin temelini oluşturmaktadır. Genel olarak yapay zekâ teknikleri, bu alandaki en üst küme olarak kabul edilmekte olup makine öğrenmesi ve derin öğrenme ise bu kümenin alt elemanlarıdır. Yani makine öğrenmesi ve derin öğrenmeye ait yaklaşım ve algoritmalar aynı zamanda yapay zekâyı da oluşturmaktadır. Şekil 2.14'te yapay zekâ, makine öğrenmesi ve derin öğrenmenin kendi aralarındaki hiyerarşisi verilmektedir.



Şekil 2.14. Yapay zekâ, makine öğrenmesi ve derin öğrenme hiyerarşisi

Yapay zekâ tekniklerinin ilk örnekleri olarak; Yapay Sinir Ağları (YSA), Genetik Algoritmalar (GA), Bulanık Mantık (BM), Uzman Sistemler (US), Karınca ve Arı Kolonileri, Gauss Süreçleri ve Tavlama Benzetimleri sayılabilir.


2.2.6.2. Makine Öğrenmesi

Makine öğrenmesi, birçok veri türüne bağlı olarak insana özgü öğrenme ve çıkarım yapma gibi işlevleri olanaklı hale getiren bilgisayar algoritmalarının tasarım, geliştirme ve iyileştirme aşamalarını konu edinen bir yapay zekâ yaklaşımıdır. Makine öğrenmesi yaklaşımlarındaki ana hedef, bilgisayarlar üzerinden karmaşık verileri algılama ve öğrenme becerilerinin geliştirilmesi sonucu veriye dayalı çıkarımlar yapılabilmesidir. Verilerin analizinde, geleneksel klasik yöntemler hem işlem yükünü artırmakta hem de

hata payının yüksek olmasından dolayı tam olarak güvenilir çıkarımlara ulaşılamamaktadır. Bu nedenle büyük ve karmaşık veri setlerini irdeleyerek geçmişteki verileri kullanıp o verilerin gelecekteki durumları hakkında çıkarımlar yapılabilmesi için makine öğrenmesi geliştirilmiştir. Makine öğrenmesindeki en önemli aşama ele alınan veri ile ilgili olarak mevcut problemlerin tespit edilip bu probleme yönelik çözüm odaklı modellerin kurulmasıdır. Bu yapay zekâ yaklaşımında verinin önemi oldukça büyük olup öğrenme algoritmaları problemin ne olduğunu veriden öğrenmekte ve bu veri setinin en belirgin özelliklerine göre tahminler yapabilmektedir [154]. İyi bir makine öğrenmesi algoritması, hemen hemen hiç ya da çok az bir insan yardımı alarak otomatik öğrenme yoluyla verileri eğiterek, doğru tahminler yapabilmeli ve buna bağlı olarak akıllı kararlar alabilmeyi sağlamalıdır. Algoritma üzerinden gerçekleştirilen öğrenme verilerdeki gözlemlerin, tecrübelerin, alışkanlıkların ve ekstrem olayların meydana getirdiği deneyime ve eğitim sistemine göre yapılır [155].


Amerikalı bilim adamları mantıkçı Walter Pitts ve nörofizyolog Warren McCulloch, 1943'te insanın öğrenme ve düşünme sürecini taklit etmeyi amaçlayan ve insan beynindeki sinir yapısını matematiksel olarak modelleyen algoritmaları bilim dünyasına tanıtmışlardır [156]. Bu çalışma makine öğrenmesi ve derin öğrenmenin gelişimindeki en önemli adımdır. Daha sonraki yıllarda bu çalışmadan esinlenerek makine öğrenmesi algoritmalarına yönelik birçok çalışma gerçekleştirilmiş olup halen yeni gelişmeler devam etmektedir. Yapay zekâ dünyasında bugünlerde en çok konuşulan ve en çok ilgi gören konulardan biri ChatGPT (Chat Generative Pre-Trained Transformer) sohbet robotu, makine öğrenmesindeki gelişmelere en iyi örnektir. Tıp, haberleşme, ekonomi-finans, temel bilimler ve mühendisliğin birçok alanında makine öğrenmesi yaklaşımına dayalı yöntemler yaygın bir şekilde kullanılmaktadır.

Makine öğrenmesindeki en önemli adımın, problemin tespiti olduğu daha önce belirtilmişti. Problemin tespiti ile başlayan makine öğrenmesi süreci veri ve model üzerine birçok aşamadan geçilerek tamamlanmaktadır. Şekil 2.15'te makine öğrenmesi aşamaları verilmiştir.



Şekil 2.15. Makine öğrenmesi aşamaları

Makine öğrenmesi algoritmaları; Denetimli öğrenme (Supervised learning), denetimsiz öğrenme (Unsupervised learning) ve takviyeli (destekleyici) öğrenme (Reinforcement learning) olmak üzere 3 ana sürece göre işlevlerini yerine getirir. Şekil 2.16’da makine öğrenmelerine ait öğrenme türleri gösterilmiştir.



Şekil 2.16. Makine öğrenmesine ait öğrenme türleri

Denetimli öğrenme; ele alınan bir veri setinde giriş değişkenlerini baz alarak çıkış değişkenini tahmin etmeyi amaçlayan ve öğrenen sistemin öğrenmesi istenen olay ile o olayın sonuçları arasındaki ilişkiyi belirlemesi istenen bir öğrenme yaklaşımıdır. Sistemdeki giriş verisi ile çıkış verisi arasındaki bu ilişkinin belirlenmesi, bilgisayarın öğrenme algoritmasına yapılan dış müdahaleler ile gerçekleştiğinden dolayı bu öğrenme denetimli öğrenme olarak adlandırılmaktadır [157]. Bu öğrenme temelinde giriş verileri bağımsız değişkenler çıkış verileri ise bağımlı değişkenler olarak temsil edilmektedir. Denetimli öğrenme yaklaşımında, veri seti kendi içerisinde rastgele ya da belli bir kurala göre eğitime ve test verileri olarak ayrılır. Eğitim verileri olarak ayrılan sete uygun bir denetimli öğrenme algoritması uygulanarak model üzerinden o setin öğrenme kapasitesi ortaya konulur. Daha sonra ise denetimli öğrenme algoritması eğitmesi tamamlanan veri setini baz alarak test için ayrılan veri setini test eder. Test sonuçları ise belli başlı performans ölçütlerine göre değerlendirilir. Eğer çıkış verisi (tahmin) istenilen doğrulukta ise öğrenme süreci tamamlanır, ancak istenilmeyen bir sonuç modelden alındığında öğrenme algoritması üzerinden çeşitli varyasyonlar ile öğrenme işlemine devam edilir. Denetimli öğrenme algoritmaları temel olarak sınıflandırma ve regresyon uygulamalarını ele alır. Eğer bağımlı değişkenin kategorik bir durumu söz konusu ise bunlar sınıflandırma, bağımlı değişkenin sürekli olması durumu söz konusu ise regresyon uygulamalarında ele alınır. Sınıflandırma uygulamalarının amacı, eldeki veri setinde belirlenmiş bir sınıflandırmaya sahip olan verilerin denetimli öğrenme yaklaşımı ile henüz sınıfları belli olmayan verilerin sınıflarını yüksek bir doğrulukla tahmin edip sınıflarına ayırmaktır. Bu uygulamanın adı her ne kadar sınıflandırma olsa da aslında tahmin yaklaşımlarına dayanmaktadır. Çünkü sınıflandırılmış ya da gruplara ayrılmış bir veri setinin özelliklerini öğrenerek o verilerle ilgili yeni bir sınıf ya da grup belirleme işi, tahmin modelleri üzerinden yapılır. Sınıflandırma problemlerinde yaygın bir şekilde kullanılan makine öğrenmesi yöntemleri ise şunlardır: Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), k-En Yakın Komşu (KEYK) Algoritması, Lojistik Regresyon (LR), Rastgele Orman (RO), Basit Bayes Algoritması, Otomatik Ki-Kare Etkileşim Tekniği [155, 158]. Bilindiği üzere regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkileri ortaya koyan bir yöntemdir. Denetimli öğrenme algoritmalarında da yine aynı temel mantıkla regresyon uygulamaları yapılmaktadır. Destek Vektör Makineleri (DVM), Lojistik Regresyon

(LR) ve Rastgele Orman (RO) makine öğrenmesi yöntemleri denetimli öğrenmenin regresyon uygulamalarında sıklıkla kullanılan yöntemlerdendir.

Denetimsiz öğrenmede, ele alınan veri setindeki bağımsız değişken olan giriş verisi öğrenme algoritmasına öğretilir, ancak bağımlı değişken olan çıkış verisi öğretilmez. Çıkış verisi olmadan verilerin arasındaki ilişki belirlenmeye çalışılır. Aynı zamanda bu öğrenme yönteminde, denetimli öğrenmede olduğu gibi bir dış müdahale bulunmaz. Öğrenme algoritması verilerin arasındaki ilişkiyi kendi öğrenerek belirlemeye çalışır. Denetimli öğrenmede olduğu gibi veri setinin eğitme ve test olarak ayrılması söz konusu değildir, sadece eğitme verileri üzerinden öğrenme algoritması çıkış verilerini tahmin etmeye çalışmaktadır. Herhangi bir çıkış verisi öğrenme algoritmasına tanıtılmadığından çıkış verilerine ait sonuçların değerlendirmesi daha zordur. Elde edilen sonuçların doğru ya da güvenilir olması gibi çıkarımlardan ziyade sonuç verilerinin öznitelikleri üzerinde durularak bir bütünlük sağlanmaya çalışılır [155]. Bu öğrenme yönteminde genellikle kümeleme, boyut azaltma ve olasılık hesapları üzerine çalışmalar yapılmaktadır. Yaygın olarak kullanılan denetimsiz öğrenme algoritmaları ise şunlardır: Kümeleme, Hiyerarşik Kümeleme, K-Ortalamlar Yoğunluğa Dayalı Uzamsal Kümeleme, Yoğunluğa Dayalı Algoritmalar, Temel Bileşen Analizi (TBA), Çekirdek Temel Bileşen Analizleri.

Takviyeli (destekleyici) öğrenme yönteminin ana yaklaşımı ise öğrenme algoritmasına öğrenmesi için tanıtılan giriş verilerinden çıkış verilerini elde etmesi ve elde edilen model sonuçlarına göre daha önceden belirlenen hedeflere ulaşabilmesidir. İstenilen hedefe ulaşma sürecinde öğrenme algoritması hedefe nasıl ulaşacağına yönelik alacağı doğru kararları kendiliğinden öğrenir. Bunun yanı sıra bu doğru kararları belirleyebilmek amacıyla, istatistik ve dinamik programlama yaklaşımlarından da faydalanılır. Aynı zamanda bu yöntemde ödül ve ceza sistemi vardır. Yani öğrenme algoritması sonuca yönelik doğru kararlar alırsa ödül, yanlış kararlar alırsa bir cezayla karşılaşır. Bu öğrenme yöntemindeki temel yaklaşım, ödülü arttırmak için ne yapılması ve nasıl bir ilişkilendirmenin gerektiğinin öğrenme algoritmasına öğretilmesidir. Öğrenme algoritması, ödülünü arttırmak için daha önceden uygulanmış modellerde ödül almış olan algoritmaları bulmalıdır. Takviyeli (destekleyici) öğrenmede, veri setindeki eğitme ve test aşamaları beraber gerçekleştirilmekte olup modelden elde edilen sonuçlara göre öğrenme algoritmasının kendisini geliştirmesi ve bu sayede insan

beyninin çalışma şekline benzeyen algoritmaları üretmesi bu yöntemin geliştirilme amacıdır. Bu yöntemde kullanılan öğrenme algoritmalarının başında Q öğrenme gelmektedir [155, 159].

2.2.6.3. Derin Öğrenme

Yapay zekâ tekniklerinin ve makine öğrenmesinin alt kümesinde yer alan derin öğrenme yöntemleri, geleneksel yapay sinir ağlarının oldukça gelişmiş bir formudur. Son beş yıllık dönemde birçok alanda kullanılmaya başlanmış olup elde edilen sonuçlar ve geri dönüşümlerden dolayı araştırmacılar için oldukça popüler bir alan olmuştur. Pitts ve McCulloch (1943)'ın derin öğrenmenin temelini oluşturan çalışmalarından daha önce bahsedilmişti. İnsan beyni ile insanın düşünme ve öğrenme özelliğinin matematiksel olarak modellendiği bu çalışma, bilgisayarların insan davranışlarını taklit edebilmesi amacını taşıdığından önemli bir yer tutmaktadır. Günümüzde ve gelecekte de insan beyninin ve davranışlarının bilgisayarlar üzerinden makinelerle ya da robotlara uyarlanması hep popüler bir konu olmaya devam edecektir. Yaşadığımız bu dönemde veri ve verinin kullanımı oldukça önemli hale gelmiştir. İnsanların günlük aktiviteleri, alışkanlıkları ve davranışları ile ilgili verilerin birçok sektör tarafından çok kısa sürelerde işlenmesi neredeyse zorunluluk haline dönüşmüştür. Bilgisayarlar üzerinden sürekli bir sirkülasyon halinde bulunan verilerin analizi de hem veri büyüklüğü hem de işlem yükü açısından önem arz etmektedir. Geleneksel sinir ağları ya da diğer makine öğrenmesi yöntemleri bu büyük boyutlu verilerle uğraşmada mevcut bilgisayar işlemcilerinin kapasitelerinden dolayı da bazen yetersiz kalabilmektedir. Bu sebeplerden dolayı derin öğrenmenin geliştirilmesindeki en önemli etkenler olarak veri büyüklüğü ve işlem yükü problemleri sayılabilir [160].

Derin öğrenme, sinir ağlarındaki ardışık gizli katmanların sayısının artırılması sonucu karmaşık ve büyük boyutlu verilerin analizlerinde daha kapsamlı çözümler sunan bir makine öğrenmesi yöntemidir. Derin öğrenme ifadesindeki derin kavramı kurulan sinir ağı modelindeki katmansal derinliği ifade etmektedir. Geleneksel sinir ağları genellikle bir veya iki ara katmandan oluşmasından ötürü sığ öğrenme olarak tanımlanır. Ancak derin öğrenmede katmanların sayısı istenilen sayıda belirlenebilir. Derin öğrenmede, her bir işlem katmanı kendisinden önceki katmanda tutulan ve en iyi özelliklere sahip çıkış verisini giriş verisi olacak şekilde alarak öğrenmeye çalışır. Katman sayısının fazla

olmasından dolayı parametre sayısı da çoktur. Öğrenme algoritmaları denetimli ya da denetimsiz öğrenme şeklinde olabilir. Derin öğrenme algoritmalarında, ele alınan veri setinin birden çok özellik veya temsil durumunun kendiliğinden öğrenilmesine dayanan bir yaklaşım söz konusudur. Üst düzey özellik veya temsil, alt düzey özellik veya temsilden türetilerek hiyerarşik bir öğrenme algoritması oluşturulmaktadır. Veri setinden elde edilen bu en iyi temsiller aracılığı ile yapılan öğrenme, derin öğrenme yöntemindeki temel yaklaşımdır [161].

Derin öğrenme algoritmaları yine denetimli, denetimsiz ve takviyeli (destekleyici) öğrenme türlerinde ele alınmakta olup tahmin, sınıflandırma, görüntü ve sinyal işleme, regresyon gibi çeşitli görevlerde kullanılmaktadır. Birçok alanda yaygın kullanımları olan Çok Katmanlı Algılayıcı (ÇKA), Derin Sinir Ağları (DSA), Evrişimli Sinir Ağları (ESA), Tekrarlayan Sinir Ağları (TSA), Uzun-Kısa Süreli Bellek (UKSB), Kısıtlı Boltzmann Makineleri (KBM), Otomatik Kodlayıcılar (OK) ve Derin İnanç Ağları (DİA) ve bunların farklı versiyonları derin öğrenme yöntemlerine örnek gösterilebilir. Her bir yöntemin kendine özgü öğrenim mimarileri ve öğrenme yaklaşımları bulunmaktadır.

Yapay zekâ teknikleri de kendi içerisinde zamanla gelişmiş olup belli bir alanda çok iyi performanslar gösteren bir yöntem daha sonra geliştirilen başka bir yöntemin üstünlüklerinden dolayı ilkel kalmıştır. Sınırlı katman sayısı, veri büyüklüğü, problemin zorluğu, öğrenme algoritmaları, veri işleme, işlem hızı ve kapasitesi gibi etmenler yöntemlerin gelişiminde ve gösterdiği popülerlikte etkili olmaktadır. Makine öğrenmesi algoritmaları ile derin öğrenme algoritmaları arasında yaklaşıma dayalı önemli farklar bulunmaktadır. Derin öğrenme algoritmalarında, yüksek bir oranda hesaplama ve işlem gücüne sahip olan ve karmaşık büyük veri problemlerini çözebilmeyi amaçlayan sinir ağları kullanılmaktadır. Derin öğrenme algoritmaları, kendiliğinden öğrenebilen sinir ağlarına dayalı bir mimari yapı oluşturmaya dayanırken makine öğrenmesi algoritmaları, veriler üzerinden öğrenme sağlayan ve probleme özgü olarak çözümler geliştiren algoritmalar olarak kabul edilmektedir. Derin öğrenme algoritmalarının diğer yöntemlere göre daha üstün bir genelleme özelliği bulunmakta olup bu nedenle daha önce hiç karşılaşılmamış bir test verisi de kolaylıkla öğrenilebilmektedir. Ayrıca veri sayısı ya da büyüklüğü arttıkça da derin öğrenme diğer yöntemlere göre daha iyi performans göstermektedir [162].

2.2.7. Çalışmada Kullanılan Makine ve Derin Öğrenme Yöntemleri

Bu tez çalışmasında; makine öğrenmesi yöntemi olarak Yapay Sinir Ağları (YSA), Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS), Destek Vektör Makine Regresyonu (DVMR) ve Gauss Süreç Regresyonu (GSR), derin öğrenme yöntemi olarak ise Uzun-Kısa Süreli Bellek (UKSB) kullanılacaktır. Bu yöntemlerin seçilmesinin sebebi özellikle hidrometeorolojik zaman serilerinin tahminleri ile ilgili çalışmalarda başarılı sonuçlar alınmasıdır. UKSB yöntemi çoğunlukla elektronik ve haberleşme, biyomedikal, ses ve görüntü işleme gibi alanlarda yaygın bir şekilde kullanılmakta olup hidrometeorolojide yeni yeni ele alınmaktadır. Ayrıca derin öğrenmenin üstün öğrenme kapasitesinin kuraklık zaman serilerinde nasıl bir performans göstereceği merak edilmiştir.


2.2.7.1. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insanın merkezi sinir sisteminin bir elemanı olan beynin en küçük işlem birimleri olan sinir hücrelerini hem görevi hem de şekli itibari ile taklit ederek insana ait öğrenme, düşünme ve çıkarım yapma gibi kabiliyetlerin bilgisayarlar üzerinden gerçekleştirilmesini sağlayan bir makine öğrenimi teknolojisidir. YSA'lar bilgi işleme sistemleri olduğundan, insanın sinir hücreleri ile karşılaştırılabilir. Bu yöntemde sürekli karşımıza çıkan sinir ağlarından kasıt, belli bir ağırlık değeri ile temsil edilen ve yapay sinir hücrelerinden teşkil edilen, her birinin kendi belleği olan ve bilgileri taşıyan bağlantı elemanları ile birbirlerine bağlanarak oluşturulan matematiksel ağ modelidir. YSA'nın öğrenme becerisi algoritmasına sunulan verideki örnekler aracılığı ile gerçekleştirilir. Nasıl insan beyni daha önce karşılaştığı örneklerden elde ettiği tecrübelerle göre bazı bilgileri işliyorsa, YSA algoritması da eğitime aşamasında bu tarz tecrübeleri kazanabilmektedir. YSA'nın en önemli özelliği, eğitilmesi için algoritmasına sunulan bir giriş değişkenini belirli kurallar çerçevesinde kendi başına eğiterek bazı genellemeler yapması ve bu yapılan genelleme işlemi sonrasında giriş değişkenlerine karşılık gelen çıkış değişkenlerini elde etmesidir. YSA'lar bulundukları ortama uyum sağlayabilen, adaptif, eksik bilgi ile de çalışabilen, belirsiz durumlara göre karar alabilen ve hatalara karşı toleransları olan farklı bir hesaplama yöntemi yaklaşımına dayanmaktadır [163].

YSA öğrenme algoritmalarının temeli, Kanadalı psikolog Donald Hebb tarafından 1949 yılında önerilen ve Hebb öğrenme kuralı olarak literatüre giren öğrenme algoritmasına dayanmaktadır. Bağlantıların farklı ağırlık değerlerine göre öğrenme kuralına dayanan bu algoritma birçok makine öğrenmesinin de öğrenme kurallarının esasını oluşturmaktadır. Yapay zekâ alanında çalışmalar yapan Amerikalı nörobiyolog Frank Rosenblatt 1957 yılında basit algılayıcı model yapısını geliştirmiş olup Çok Katmanlı Algılayıcıları (ÇKA) önermiştir. Özellikle bu iki çalışma YSA'nın gelişiminde önemli bir yer tutmaktadır. Daha sonraki yıllarda ise YSA'nın farklı algoritmalarına yönelik çalışmalar yapılmış ve gelişimi devam etmiştir. YSA algoritmaları ile tahmin ve sınıflandırma başta olmak üzere öğrenme, bağlantı kurma, genelleme ve optimizasyon işlemleri gibi çalışmalar gerçekleştirilmektedir [164].


2.2.7.1.1. Yapay Sinir Ağının Yapısı

YSA'nın taklit ettiği insan beynine ait biyolojik sinir hücreleri 4 ana elemandan oluşmakta olup bunlar: sinaps, çekirdek, akson ve dentrittir. Bu elemanlar arasında sürekli bir bilgi ve işlem akışı vardır. Sinaps, sinir hücreleri arasındaki bağlantıyı sağlayarak iletişim kurulmasını sağlayan elemandır. Çekirdek, sinapstan gelen bilgiyi işleyerek elde edilen çıktı bilgisini akson aracılığı ile dentrite aktaran merkezi birimdir. Akson, sinir hücrelerinde işlenen bir bilgiyi diğer bir sinir hücresinde giriş bilgisi olarak oluşturulması için sinapsa aktaran elemandır. Dentrit ise diğer hücrelerden gelen bilgileri çekirdeğe ileten sinir hücresinin en uç kısmında bulunan elemandır. Biyolojik sinir hücrelerindeki elemanlar ve bu elemanların arasında görülen bilgi ve işlem akışı yapay sinir hücreleri ile taklit edilerek YSA öğrenme algoritmaları oluşturulmuştur. Yapay sinir hücreleri nöronlar vasıtasıyla birbirleri ile bağlantı kurarak yapay sinir ağını oluşturmaktadır. Yapay bir sinir ağı temelde 3 ana katmandan ve yapay sinir hücresi ise 5 farklı bölümden oluşmaktadır. Katmanlar; girdi katmanı, ara (gizli) katman ve çıktı katmanı olarak ayrılır. Şekil 2.17'de YSA'nın genel bir ağ yapısı gösterilmektedir.



Şekil 2.17. YSA katman yapısı

Şekil 2.17’de gösterilen katmanlardan girdi katmanı, yapay sinir ağına gelen bilgilerin alındığı ve ara (gizli) katmana iletildiği başlangıç katmanıdır. Ara (gizli) katman, girdi katmanından gelen bilgilerin işlendiği katmandır. Çıktı katmanında ise girdi katmanından ağı giriş yapan veriler için üretilmesi gereken çıktı, ara (gizli) katmandan gelen bilgiler işlenerek üretilir. YSA’nın temel katman yapısı yukarıda kısaca özetlenmiş olup YSA’nın asıl öğrenme süreci ile ilgili işlemlerin gerçekleştirildiği yapay sinir hücresinin bölümleri Şekil 2.18’de gösterilmiştir.



Şekil 2.18. Yapay sinir hücresinin bölümleri

Şekil 2.18’de gösterilen yapay sinir hücresinin bölümlerinden girdi değerleri, hücreye dışardan ya da diğer nöronlardan gelen bilgileri temsil etmektedir. Bu girdi bilgileri, girdi katmanında toplanarak bağlantılar aracılığı ile çekirdeğe iletilmektedir. Yapay bir sinir hücresinde tek bir çıktı değeri elde edilirken istenilen sayıda girdi değeri olabilmektedir. Ağırlık değerleri, girdi değerlerinin çekirdeğe iletilmesi aşamasında

geldikleri bağlantıların hücreye etkisini belirleyen değerlerdir. Bu değerler sıfır, pozitif ya da negatif şeklinde sabit ya da değişken değerler alabilmektedir. Girdi bilgileri, bağlantıların ağırlıkları ile çarpılarak çekirdeğe iletilmektedir. Toplama fonksiyonu, yapay sinir hücresine girdi olarak gelen ve bağlantıların ağırlıkları ile çarpılarak elde edilen tüm bilgilerin toplandığı ve net girdi değerlerinin hesaplandığı fonksiyonlardır. Bu fonksiyonlar toplam, çarpım, minimum, maksimum, çoğunluk ve kümülatif toplam olarak belirlenebilmekte olup fonksiyon seçimi ise yapay sinir ağının mimarisine uygun olacak şekilde isteğe bağlıdır. Literatürde en çok kullanılan fonksiyon ise toplam fonksiyonudur [163]. Toplama fonksiyonunda hesaplanan net girdi değeri şu eşitlik aracılığı ile bulunmaktadır:

$$NET = \sum_{i=1}^n G_i W_i \quad (2.57)$$

Eşitlik 2.57’de verilen n hücreye gelen toplam eleman sayısını, G_i girdi değerini, W_i ise ağırlık değerlerini temsil etmektedir.

Şekil 2.18’de gösterilen yapay sinir hücresindeki aktivasyon fonksiyonu ise hücreye gelerek hesaplanan net girdi değerlerini işleyen yani bilginin işlendiği aşamadır. Burada toplama fonksiyonundan sonra bir eşik seviyesine göre girdi değerlerine karşılık çıktı değerleri belirlenir ve bir sonraki aşama olan çıktı katmanına aktarılır. Aktivasyon fonksiyonunda belirlenen eşik seviyesi aşağıda verilen şu eşitlik ile gösterilmektedir:


$$y = f(GxW) = f(NET) \quad (2.58)$$

Eşitlik 2.58’de gösterilen y eşik değerini, f fonksiyonu ise aktivasyon fonksiyonunu temsil etmektedir. Bu fonksiyonun doğrusal ya da doğrusal olmayan çeşitleri bulunmaktadır. Doğrusal (lineer), sigmoid, adım (step), hiperbolik tanjant, sinüs, ReLU (Doğrultulmuş Doğrusal Birim-Rectified Linear Unit) yaygın olarak kullanılan aktivasyon fonksiyonlarıdır.

Yapay sinir hücresinin son aşaması olan çıktı değeri ise aktivasyon fonksiyonunda elde edilen sonuç değeridir. Yapay sinir hücresinden tek bir çıktı değeri elde edilmekte olup bu değer kendi hücre ortamına, başka bir sinir hücresine ya da farklı bir ortama gönderilebilmektedir. Aynı çıktı değeri birden fazla yapay sinir hücresinde girdi değeri olarak da kullanılabilir.

2.2.7.1.2. Yapay Sinir Ağlarının Sınıflandırması

YSA'lar; ağıın bağlantı yönlerine, öğrenme algoritmalarına ve katman sayısına göre genel olarak üç ana grupta sınıflandırılmaktadır. Şekil 2.19'da YSA sınıflandırması gösterilmiştir.



Şekil 2.19. Yapay sinir ağlarının sınıflandırması

YSA'nın bağlantı yönlerine göre sınıflandırılmasından kasıt aslında ağıın mimari yapısını ve bilginin ilerleme (akış) istikametini gösteren bir ayrımdır. İleri beslemeli ağlarda yapay sinir hücresindeki bilgi akışı girişten çıkışa doğru düzenli katmanlar aracılığı ile sağlanmaktadır. Yapay sinir hücresinden elde edilen çıktının bir önceki katmandaki hücrenin girdi değerini oluşturmadığı ağ yapısıdır. Yani bu ağ yapısında bir katmandan sadece kendisinden sonraki katmana bir bağ bulunmaktadır. Geri beslemeli ağlarda ise bir yapay sinir hücresinde elde edilen çıktı değeri kendinden önceki katmanda veya kendi ortamında bulunan herhangi bir yapay sinir hücresinde girdi değeri olarak bağlanabilme durumu söz konusudur. Yapay sinir hücresindeki bilgi akışı hem ileriye doğru hem de geriye doğru sağlanmaktadır. Geri beslemeli ağ yapısının bu özelliğinden dolayı eğitim süreci ileri beslemeli ağ yapısına göre daha uzun olabilmektedir.

Öğrenme algoritması türleri olan denetimli, denetimsiz ve takviyeli öğrenme daha önce derin öğrenme başlığında anlatılan öğrenme türlerinin aynısı olduğundan tekrar üzerinde durulmayacaktır. Bir diğer YSA sınıflandırma ölçütü olan katman sayısı ise tek katmanlı ve çok katmanlı olmak üzere iki türdür. Bazı çalışmalarda katman ifadesinin

yanına algılayıcı (perceptron) ifadesi de eklenerek tek katmanlı algılayıcı ya da çok katmanlı algılayıcı gibi bir kullanım da söz konusu olmaktadır. Tek katmanlı YSA'larda sadece girdi ve çıktı katmanı bulunurken, çok katmanlı YSA'larda girdi katmanı, ara katman ya da katmanlar ve çıktı katmanı yer almaktadır. Tek katmanlı ağlarda ağı sunulan girdi değerleri girdi katmanı nöronları ile çıktı katmanı nöronu arasındaki ağırlıkların hesaplanması sonucu belirlenen aktivasyon fonksiyonunda işlemden geçirilerek tek bir çıktı verisi elde edilmektedir. Aktivasyon fonksiyonu özellikle çıktı değeri için belirlenir ve belirlenen bu aktivasyon fonksiyonu doğrusaldır. Bu nedenle doğrusal olmayan problemlerin ele alındığı durumlarda bu ağ yapısı yetersiz kalmaktadır. Ayrıca basit tek katmanlı algılayıcı YSA modeli bu ağ yapısı baz alınarak oluşturulmuştur. Çok katmanlı ağların tek katmanlı ağlardan farkı ara katman ya da katmanların bulunmasıdır. Yapay sinir hücresine gelen bilgiler ara katmanda ya da katmanlarda işlenmektedir. Doğrusal olmayan aktivasyon fonksiyonları kullanılarak ağın doğrusal olan yapısı doğrusal olmayan şekle dönüştürülür. Özellikle bu ağın yapısı baz alınarak geliştirilen ve ağın öğrenmesini kolaylaştırarak hataların da mümkün olduğunca minimumda tutulmasını sağlayan geri yayılım algoritması oluşturulmuştur. Çok katmanlı YSA'nın eğitme aşamasında ağı hem girdi hem de çıktı değerleri sunularak bilgi işlendiğinden ayrıca denetimli öğrenme de sağlanmış olur [164, 165].

2.2.7.1.3. Geri Yayılım Algoritması

Çok katmanlı YSA'lar, doğrusal olmayan problemleri çözebilmesi için geliştirilmiş bir ağ modeliydi. Bu modelde geri yayılım öğrenme algoritmaları kullanılarak girdi değerlerine karşılık gelen çıktı değerleri elde edilmektedir. Geri yayılım algoritması, en küçük kareler yöntemini esas alan delta öğrenme kuralına dayanarak ağın eğitme aşamasında elde edilen çıktı ile gerçek çıktı arasındaki hatanın minimize edilmesi amacıyla ağırlık değerlerini dereceli azaltma ve eğim inişi yöntemleri ile optimize etmektedir. Ağırlık değerlerinin optimize edilerek hataların da en aza indirilmesindeki amaç ağın performansını artırabilmektir. Bu algoritmada hem ileri beslemeli hem de geri beslemeli bağlantı yönleri dikkate alınarak öğrenme akışı sağlanmaktadır. İlk aşamada çıktının elde edilebilmesi için ileri beslemeli akış kullanılırken, daha sonra ağdaki ağırlık değerlerinin uygun hale getirilebilmesi için geri beslemeli akış kullanılmaktadır. Geri yayılım algoritması sadece çok katmanlı YSA modellerinde kullanılır.

2.2.7.1.4. Levenberg-Marquardt Algoritması

Geri yayılım algoritması, ağıdaki ağırlık değerlerini ayarlarken yakınsama etkinliği ile ilgili bazı eksiklikleri bulunmaktadır. Bu algoritmanın optimizasyon kapasitesini artırabilmek amacıyla momentum kapasitesi, esnek yayılım, gradyan azaltma, Gauss Newton ve Levenberg-Marquardt algoritması gibi bazı yöntemler geliştirilmiştir. Tez çalışmasında kullanılacak olan YSA modellerinde öğrenme algoritması olarak Levenberg-Marquardt algoritması ele alınacağından bu algoritma üzerinde durulmuştur. Levenberg-Marquardt algoritması, standart sayısal optimizasyon tekniklerinden biri olup YSA modellerinde son dönemde yaygın bir şekilde kullanılmaktadır. Bu öğrenme algoritması, gradyan azaltma ve Gauss Newton yöntemlerinin iyi yönlerinin alındığı, eksik yönlerinin ise geliştirildiği daha karmaşık bir yapıya sahiptir. Tek katmanlı ağırlar kullanılabildiği gibi çoğunlukla çok katmanlı ağlardan oluşmaktadır. Ayrıca genellikle ileri beslemeli ağlarda ve denetimli öğrenme modellerinde kullanılmaktadır. Levenberg-Marquardt algoritması, geri yayılım algoritmasındaki yakınsama eksikliğini gidermek ve ağıın öğrenme kapasitesini artırabilmek adına, doğrusal olmayan problemlerde kullanılan ve en küçük kareler yöntemine dayanan bir algoritmadır. Geri yayılım algoritmasını iyileştirebilmek için bu yönteme dâhil edilebilen ikinci dereceden bir gradyan yaklaşımına dayanmaktadır [166]. Ele alınan ağıdaki hata değeri bulunduktan sonra ağı oluşturan her bir nöron, kendi ağırlık değerini optimize ederek hata oranını en aza indirmeye çalışır. Ele alınan ağıdaki performans değerini belirleyebilmek amacıyla aşağıdaki eşitlikte verilen karesel hata fonksiyonu kullanılmaktadır.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} \left(d_j(k) - Y_j^{(3)}(k) \right)^2 \quad (2.59)$$

Eşitlik 2.59'da verilen $E(k)$ ifadesi karesel hata fonksiyonunu, $Y_j^{(3)}(k)$ ifadesi öğrenme örneği için ağıın j 'nci çıkış nöronu tarafından üretilen değeri, $d_j(k)$ ifadesi ise istenilen değere karşılık gelen değeri temsil etmektedir. Hata fonksiyonunun belirlenmesinden sonra performans değerini elde etmek için ağırlık değerlerine bağlı olarak Hessian matrisinin (ikinci dereceden türevlerin matrisi) türevi kullanılmaktadır. Bu aşamanın ardından ağırlıkların bulunmasına yönelik çeşitli matris işlemleri yapılarak hata oranlarını en aza indirmek amacıyla çeşitli optimizasyonlar yapılmaktadır. Levenberg-

Marquardt algoritmasında, ağda elde edilen performans değerlerine yakınsama hızı yüksektir ancak daha fazla bellek ve işlem yükü gerekmektedir [167].


2.2.7.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇŞ)

Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇŞ), YSA ile bulanık mantığın kombine edilerek oluşturulduğu ve uyarlamalı bir ağ yaklaşımına dayalı makine öğrenmesi yöntemidir. Jang tarafından 1993 yılında geliştirilmiştir [168]. Literatürde kullanılan adı ANFIS (Adaptive Neuro-Fuzzy Inference System) olup tez çalışmasında Türkçe kısaltması olan USBÇS olarak adlandırılacaktır. USBÇS, YSA'nın öğrenme algoritmalarını kullanarak girdi ve çıktı değerleri arasında bulanık mantığa dayalı çeşitli kurallar oluşturmaktadır. Bu yöntemde düşünme ve çıkarım yapma gibi yetenekler bulanık mantık kullanılarak yapılmaktadır.

Mantık, akıl yürüterek bazı önermeler sunmaya dayalı bir düşünce faaliyetidir. Mantık biliminin kurucusu kabul edilen ve M.Ö. 384–322 yılları arasında yaşamış olan filozof Aristo'nun kendi adını da taşıyan Aristo mantığı (klasik mantık, ikili mantık ya da düz mantık olarak da bilinmektedir), belirsizlik durumunu içermeyen iki farklı sonuca dayanmıştır. Örneğin kesin hükümler çerçevesinde bakılarak bir bilgi ya doğrudur ya da yanlış, bir maddenin rengi ya siyahtır ya da beyaz, doktora eğitimi ya kolaydır ya da zor. Bununla birlikte daha sonraki dönemlerde bilimin gelişmesine paralel olarak belirsizlik durumunun fayda sağlayan bir kavram olarak algılanması ile mantık hükümlerinde üçüncü bir sonuç olarak belirsizlik durumu da sayılmıştır. Bunun en önemli nedeni bilimle uğraşan insanların şüpheci ve sorgulayıcı olma özellikleridir. İşte bu belirsizlik durumundan dolayı bulanık mantık kavramı ortaya çıkmıştır. Lotfy A. Zadeh, 1965 yılında mantık değerleri kümesini $[0,1]$ aralığında tanımlayarak Bulanık Mantık Teorisini geliştirmiştir. Bu teoride; küme içerisinde yer alan mantık değerleri 0 ile 1 arasında değişken üyelik derecelerine sahiptir. Üyelik derecesi, sistemde ele alınan bir girdinin dilsel değişkeninin bir terime hangi derecede ait olduğunu belirleyen değerdir. Bulanık mantıkta, dilsel değişken değerlerin tümü ise üyelik fonksiyonu olarak adlandırılmaktadır. Bulanık mantık yaklaşımında, kesin hükümlerden ziyade örnek olarak çok, çok büyük, büyük, küçük, daha küçük gibi belirsiz hükümler bulunmaktadır [169]. Aristo mantığında örnek gösterilen bir rengin ya siyah ya da beyaz olması gibi kesin hükümlerine ek olarak bu iki rengin arasındaki birçok farklı tonu içerisinde

barındıran gri rengin de bir hüküm olabileceği bulanık mantığın temelini oluşturmaktadır. Bulanık mantığın sınırları Aristo mantığına göre daha esnek olup kurulan mantık çerçevesinde yer alan elemanların nitelikleri de daha belirsiz hükümleri içermektedir [170].

Bulanık mantıkta kabul edilen belirsizlik durumundan dolayı ele alınan bir problemde yaklaşık sonuçlara ulaşılmaya çalışılmakta olup bulanık mantık esnek bir hesaplama tekniği olarak yaygın bir şekilde kullanılmaktadır. Bulanık mantık; giriş, bulanıklaştırma birimi, veri tabanı, kural tabanı, bulanık çıkarım mekanizması, durulaştırma (berraklaştırma) birimi ve çıkış bölümlerinden meydana gelmektedir [171]. Şekil 2.20’de bulanık mantık bölümleri gösterilmiştir.



Şekil 2.20. Bulanık mantık bölümleri

Şekil 2.20’de gösterilen bulanık mantık bölümlerinden bulanıklaştırma birimi, bir sisteme gelen ve kesin olarak tanımlanan bir girdi değerinin çeşitli üyelik fonksiyonları kullanılarak 0 ile 1 arasında derecelendirilmesi ile girdi değerinin bulanık bir değere dönüştürüldüğü birimdir. Bu aşamada ele alınan üyelik fonksiyonları genellikle üçgen, sabit, trapez, sigmoid ve Gauss üyelik fonksiyonlarıdır. Bilgi tabanı, sistemde ele alınan girdiye ait tüm sayısal ya da sözel bilgilerin ve verilerin tutulduğu birimdir. Kural tabanı, girdi değerlerini çıktı değerleri ile ilişkilendiren ve tüm mantıksal kuralların birlikte ele alındığı birimdir. Kurallar belirlenirken bulanıklaştırma biriminden gelen tüm girdi ve çıktı değerlerinin arasındaki bulanık değerler dikkate alınmaktadır. Kural tabanında girdi ve çıktı değerlerini ilişkilendiren tüm bulanık küme elemanları

toplanarak sistemden tek bir çıktı elde edilmesi bulanık çıkarım mekanizmasında sağlanmaktadır. Durulaştırma (berraklaştırma) birimi ise tüm bu işlemler sonucunda elde edilen bulanık çıktı sonucunu kesin bir sayısal değere dönüştürmektedir [172].

YSA ve bulanık mantığın kombine edilmesi ile oluşturulan USBÇS, özellikle doğrusal olmayan problemlerin çözümünde kullanılmaktadır. Bulanık çıkarım sistemlerinde başlıca iki farklı yaklaşım bulunmakta olup bunlar Mamdani ve Takagi-Sugeno yöntemleridir. Mamdani bulanık çıkarımı ilk olarak, deneyimli insan operatörlerden elde edilen bir dizi dilsel kontrol kuralının sentezlenmesiyle bir kontrol sistemi oluşturmak için tanıtılmıştır [173]. Bu yaklaşımda her kuralın bir çıktısı bulunmaktadır. Bulanıklaştırma biriminden gelen fonksiyon üyelik seviyeleri, her bir kural için maksimum ya da minimum ilişkilendirme operatörü sayesinde çıkış üyelik fonksiyonu ile ilişkilendirilmektedir [174]. Her kurala ait çıktı, çıkış üyelik fonksiyonundan ve bulanık çıkarım sisteminden türetilen bir bulanık kümedir. Bu çıktı bulanık kümeleri, bulanık çıkarım sistemindeki toplama yöntemi kullanılarak tek bir bulanık kümede birleştirilmektedir. Daha sonra ise nihai net çıktı değerinin hesaplanması için birleşik çıktı bulanık kümesi, durulaştırma (berraklaştırma) işlemi için önerilen yöntemlerden biri kullanılarak bulanıklaştırılmaktadır. Mamdani bulanık çıkarımı daha sezgisel olmakla birlikte anlaşılması ve yorumlanması daha kolay kural tabanlarına sahiptir [175]. Bir diğer bulanık çıkarım yaklaşımı olan Takagi-Sugeno'da, girdi değerlerinin sabit veya doğrusal bir fonksiyonu olan tekil çıkış üyelik fonksiyonları kullanılmaktadır. Bu yaklaşımda; bulanıklaştırma biriminden gelen fonksiyon üyelik seviyeleri polinom çıkış üyelik fonksiyonları ile ilişkilendirilmektedir. Durulaştırma (berraklaştırma) işlemi ise iki boyutlu bir alanın merkezini hesaplamak yerine birkaç veri noktasının ağırlıklı ortalamasını veya ağırlıklı toplamını kullanmakta olup bu yönüyle Mamdani yaklaşımına kıyasla hesaplama kolaylığı sağlamaktadır. Ayrıca Takagi-Sugeno bulanık çıkarım sistemi, optimizasyon ve uyarlanabilir tekniklerle iyi çalışmakta olup matematiksel analizler için çok uygundur [176].

2.2.7.2.1. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (USBÇS) Yapısı

Uyarlanabilir bir ağ sistemine girdi ve çıktı değerleri verilerek, USBÇS modelinde geriye yayma metodu ile en küçük kareler metodu kullanılarak bulanık bir çıkarım sonucu elde edilmeye çalışılmaktadır. Bu işlemler esnasında üyelik fonksiyonları ile

birlikte “eğer-ise” şeklinde oluşturulan bulanık kurallar dikkate alınmaktadır. x ve y girdi değerleri ile f çıktı değeri, Gauss üyelik fonksiyonuna sahip, “eğer-ise” bulanık kurallı birinci mertebeden Takagi-Sugeno yaklaşımına dayalı bir USBÇS’nin yapısı matematiksel olarak aşağıda verilmektedir:


$$\mu_A(x, c, s, m) = \exp \left[-\frac{1}{2} \left| \frac{x-c}{s} \right|^m \right] \quad (2.60)$$

Eşitlik 2.60’da verilen μ_A ifadesi A bulanık kümesinin üyelik fonksiyonunu, x, c, s, m ifadeleri ise kümenin destek ve genişlik parametrelerini temsil etmektedir.

$$\text{Kural 1: Eğer } \mu(x), A_1 \text{ ve } \mu(y), B_1 \text{ ise } f_1 = p_1x + q_1y + r_1 \quad (2.61)$$

$$\text{Kural 2: Eğer } \mu(x), A_2 \text{ ve } \mu(y), B_2 \text{ ise } f_2 = p_2x + q_2y + r_2 \quad (2.62)$$

Eşitlik 2.61 ve 2.62’de verilen ifadelerden A_1, B_1, A_2, B_2 ifadeleri x ve y girdi değerlerinden üyelik fonksiyonları ile elde edilen bulanık kümeleri; $p_1, q_1, r_1, p_2, q_2, r_2$ ifadeleri ise f çıktı değerine ait çıkış fonksiyonlarını temsil etmektedir. USBÇS’nin Takagi-Sugeno bulanık çıkarım yaklaşımına dayalı iki girişli katman yapısı Şekil 2.21’de gösterilmiştir.



Şekil 2.21. İki girişli USBÇS genel yapısı

Şekil 2.21’de gösterilen USBÇS genel yapısında girdi değerleri düğümler aracılığı ile ilk katman olan bulanıklaştırma katmanına iletilmektedir. Bu katmanda girdi değerleri A_i ve B_i şeklinde bulanık kümelere ayrılarak Gauss üyelik fonksiyonu ile üyelik dereceleri belirlenmektedir. 2. katman olan kural katmanında, bulanıklaştırma katmanından gelen üyelik derecelerinin çarpılmasıyla “eğer-ise” bulanık kuralına dayalı

olarak her bir kuralın ağırlığı w_i hesaplanmaktadır. Bu w_i değerleri, katmandaki her bir düğümün çıkışıdır. 3. katmana normalleştirme katmanı da denilmekte olup i 'nci kuralın tüm kurallara oranı hesaplanarak normalleştirme seviyesi belirlenir. Arındırma katmanı olarak adlandırılan 4. katmanda, i 'nci kuralın model çıktılarına olan etkisi hesaplanmaktadır. Son katman olan 5. katman ise toplam katmanıdır. Arındırma katmanından gelen tüm düğümlere ait çıkışların toplandığı ve sonuç olarak tek bir f çıktısının elde edildiği katmandır.

2.2.7.3. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM) (Support Vector Machines-SVMs), 1995 yılında Cortes ve Vapnik tarafından önerilmiş istatistiksel öğrenme teorisi ile yapısal risk minimizasyonuna dayalı bir makine öğrenmesi yöntemidir [177]. Yüksek boyutlu ve küçük sayıdaki eğitim verilerinden başarılı bir şekilde öğrenmeyi gerçekleştiren yeni nesil bir öğrenme teknolojisine sahiptir. Sınıflandırma ve regresyon problemlerinin çözümünde yaygın bir şekilde kullanılmakta olup Destek Vektör Makine Sınıflandırması (DVMS) ve Destek Vektör Makine Regresyonu (DVMR) olmak üzere başlıca iki alt gruba ayrılır. DVM, özellikle sınıflandırma problemlerinde başarılı sonuçlar vermektedir. Ayrıca iyi bir genelleme yeteneğine sahip olmasından dolayı tahmin modellerinde de sıklıkla kullanılmaktadır.

YSA ve bulanık mantık gibi makine öğrenmesi yöntemlerinde çok fazla eğitim verisine ihtiyaç duyma, boyut problemi, yakınsama oranının düşüklüğü, yerel minimuma takılma, sisteme odaklanma ve uyum sağlayamama gibi eksiklikler görülebilmektedir [178]. Diğer yöntemlerde görülen bu eksikliklerin temel nedeni bu yöntemlerin deneysel risk minimizasyonuna bağlı olarak çalışmasıdır. DVM ise yapısal risk minimizasyonu prensibine bağlı olarak öğrenme işlemini gerçekleştirdiğinden yukarıda belirtilen problemleri çözmesi daha kolay olmuştur [179]. Kısaca özetlenecek olursa deneysel risk minimizasyonu, bir yönteme ait öğrenme algoritmasının deneysel riski minimum tutmayı amaç edinen tümevarımsal metotlar yaklaşımına dayanmaktadır. Bu yaklaşımda sadece eğitme verisinden elde edilen bilgiler baz alındığı için risklerle ilgili olarak genelleme yapılmaktadır. Bundan dolayı deneysel risk ile beklenen risk arasında yakınsama problemi ortaya çıkmaktadır. Yapısal risk minimizasyonu da deneysel risk minimizasyonu gibi tümevarımsal prensibe dayanmaktadır. Ancak farklı olarak yapısal


risk minimizasyonunda istatistiksel öğrenme teorisi ile küçük bir örnek uzayı ele alınmakta ve yakınsama fonksiyonları belirli sınırlarda tutularak beklenen risklerin ve genelleme hatalarının minimumda kalması sağlanmaktadır. Böylece eğitime verileri için en optimum öğrenme becerisi elde edilmektedir. İstatistiksel öğrenme teorisi, Vapnik ve Chervonenkis tarafından 1991 yılında geliştirilmiş küçük veri setlerinden öğrenmeyi sağlayan etkili bir öğrenme yöntemidir. Ancak bu öğrenme teorisinde, veri ile yakınsama fonksiyonları arasında eksik ya da fazla olabilen uyum problemleri ortaya çıkabilmektedir. Yani kullanılan öğrenme algoritması bir eğitim verisinden ya eksik öğrenme ya da fazla öğrenme kazanmıştır. Bu uyum problemini çözmek ve model karmaşıklığını azaltmak adına düzenleyici ya da kontrolü sağlayan bir parametre kullanmak gerekir. Bu parametre yardımıyla belirlenecek olan bir denge noktası uygun fonksiyonların seçimini kolaylaştırmaktadır. Yine Vapnik ve Chervonenkis (1971) tarafından geliştirilen ve Vapnik-Chervonenkis Teorisi (VC) olarak adlandırılan yaklaşımda VC boyutu ile en optimum uyum noktası belirlenerek eksik ya da fazla öğrenmeden kaçınılır, ayrıca model karmaşıklığı da düzenlenmektedir. VC boyutunun istatistiksel öğrenme teorisine dahil edilmesi ile birlikte modelden daha optimum sonuçlar elde edebilmek için ele alınan bu risk yaklaşımına da yapısal risk minimizasyonu denir. Her ne kadar sınıflandırma problemleri için geliştirilmiş olsa da riskin minimize edilmeye çalışıldığı herhangi bir problemde de bu yaklaşım kullanılabilir. Yapısal risk minimizasyonunda başlıca iki strateji vardır. Bunlar; VC boyutunu sabit tutarak deneysel riski minimize etmek ya da deneysel riski sabit tutup VC boyutunu minimize etmektir. Diğer makine öğrenmesi yöntemleri ve istatistiksel yöntemler genellikle ilk stratejiyi kullanırken, DVM ikinci stratejiyi kullanmaktadır [180]. VC boyutu aslında bir sınırlama parametresidir. VC boyutu sonlu bir değer almakta olup matematiksel ifadesi ise aşağıda verilmiştir:

$$R(\alpha) \leq R_{den}(\alpha) + \sqrt{\frac{h\left(\log\left(\frac{2n}{h}\right)+1\right)-\log\left(\frac{\eta}{4}\right)}{n}} \quad (2.63)$$

Eşitlik 2.63'te verilen $R(\alpha)$ gerçek riski, $R_{den}(\alpha)$ deneysel riski, h VC boyutunun değerini, n eğitim veri sayısını, η ise $[0,1]$ aralığında değer alabilen bir parametredir.

Daha önce DVM'nin sınıflandırma problemlerinde DVMS ve regresyon problemlerinde ise DVMR diye adlandırılan alt yöntemlerine ayrıldığı belirtilmişti. DVM daha çok

sınıflandırma problemlerinde ele alınan denetimli öğrenme yaklaşımına dayalı bir makine öğrenmesi yöntemidir. Sınıflandırmadaki amaç ele alınan verilerin doğru bir şekilde ayrıştırılmasını sağlamaktır. İki farklı sınıfın birbirinden ayrılması amacıyla doğrusal bir sınır çizgisi kullanılır. Sınır çizgisi ile birlikte marjin adı verilen bir aralık, en iyi ve en geniş (maksimum) sınır aralığını bulmak için kullanılır. Şekil 2.22’de DVM’nin gösterimi verilmiştir.



Şekil 2.22. DVM sınıflandırma durumu

Şekil 2.22’de gösterimi verilen DVM’nin sınıflandırma durumunun daha iyi anlaşılabilmesi için sınıflandırma elemanlarını açıklamak gerekir. DVMS ile n elemandan oluşan bir örnek uzaydaki eğitim verilerinin A ve B sınıflarına ayrılması aşağıda eşitliği verilen ayırıcı fonksiyon ile yapılmaktadır:

$$f(x) = w \cdot x + b = 0 \quad (2.64)$$

Eşitlik 2.64’te verilen w ifadesi ağırlık vektörünü, x düzlemde bulunan bir veri noktasını ve b ise bias (sapma ya da hata) değerini temsil etmektedir. Eşitlikte elde edilmek istenen $f(x)$ fonksiyonu ise optimum hiper düzlem yani en optimum doğrusal sınır çizgisidir. Optimum hiper düzlemin bulunabilmesi için sınıra en yakın veri noktalarını içeren $|w \cdot x_i + b| = 1$ eşitliğinin ölçeklendirilmesi gerekmektedir. Veri noktalarının bazıları bu eşitliği $w \cdot x + b = 1$ durumunda sağlarken bazıları da $w \cdot x + b = -1$ durumunda sağlamaktadır. Optimum hiper düzleme en yakın konumda bulunan vektörler, destek vektörleri olarak adlandırılmaktadır. Ayrıca optimum hiper düzlemin böldüğü sınırın yani marjinin toplam uzunluğu $2/\|w\|$ ’dir. Ağırlık vektörü olan w ’nin farklı değerlerine göre farklı ayırıcı fonksiyonlar elde edilebilmektedir. Bu noktada VC

boyutu devreye girerek sınırın yani marjinin genişliğini ayarlamaktadır. w değerinin küçük olması VC boyut değerinin de küçük olduğu anlamına gelir ve bu koşulda marjin genişliği maksimumdur. Marjin genişliğinin maksimum istenmesinin sebebi algoritmanın daha büyük bir marjinde daha iyi genellemeler yapabilecek olmasıdır. DVMS, marjin genişliğini maksimuma ulaştırarak yapısal risk minimizasyonuna olanak sağlamaktadır. $\|w\|$ değerinin (ağırlık vektörünün normu) minimize edilmesi $1/2\|w\|^2$ değerinin karesel programlama problemi ile minimize edilmesi ile mümkün olmaktadır. Maksimum marjin genişliği aşağıda verilen Lagrange optimizasyon fonksiyonu yardımıyla bulunur:

$$\text{Minimizasyon: } \min \frac{1}{2} \|w\|^2 \quad y_i(w \cdot x_i + b) \geq +1 \quad \forall i \quad (2.65)$$

Sınıflandırma problemlerinde görülen genelleme hataları ile model karmaşıklığı istatistiksel öğrenme teorisi temel alınarak CV boyutu ile çözülebilirken yine sıklıkla karşılaşılan doğrusal olmayan uyum sorunlarının çözümünde de çekirdek (kernel) fonksiyonları kullanılmaktadır. Çekirdek fonksiyonları, farklı sınıfların optimum bir hiper düzlemle ayrılamadığı durumlarda kullanılır. Ancak hem bu çalışma tahminler üzerine olduğundan hem de DVMR'de çekirdek fonksiyonlarından bahsedileceğinden dolayı burada çekirdek fonksiyonlarından bahsedilmemiştir. DVMS öğrenme algoritmaları, hem eğitme hatalarının bulunmadığı doğrusal sınıflandırma problemlerinde hem de eğitme hatalarının bulunduğu doğrusal olmayan sınıflandırma problemlerinde kullanılmaktadır. DVMS öğrenmesi, başlangıçta iki sınıflı sınıflandırma yapmaktayken daha sonraları oluşan ihtiyaçlara bağlı olarak çoklu sınıflandırmalarda da kullanılmıştır.

2.2.7.3.1. Destek Vektör Makine Regresyonu (DVMR)

DVM'nin regresyon problemlerini ele alan alt grubu, Destek Vektör Makine Regresyonu (DVMR) öğrenme yaklaşımıdır. DVM'lerin regresyon problemlerinin çözümünde kullanılması Smola ve Schölkopf (2004) tarafından önerilmiştir [181]. Burada bahsedilen regresyon problemlerinden kasıt tahmin problemleridir. Ele alınan bir veri setini meydana getiren rastgele değişkenin değerini, değişimini etkileyecek başka bir değişken değerine bağlı olarak doğru bir şekilde tahmin etmek için regresyon

denklemleri kullanılmaktadır [182]. Regresyon ile ilgili daha detaylı bilgiler ilerde Gauss Süreç Regresyonu (GSR) yöntemi tanıtılırken verilecektir.


Genel olarak DVMS’de kabul edilen prensipler DVMR’de de geçerli olmakla birlikte bu iki yaklaşım arasında küçük farklılıklar söz konusudur. Sınıflandırma problemlerinde verileri birbirinden ayıran optimum hiper düzlemde hiçbir veri kalmayacak şekilde marjin genişliği maksimize edilirken regresyon problemlerinde bahsedilen durumun tersi olarak optimum hiper düzlem sınırları içerisinde maksimum verinin kalmasına yönelik bir yaklaşım söz konusudur. Burada regresyondaki hataların belirli bir eşik değeri içerisinde kalması sağlanarak hatalar minimize edilmektedir [183]. DVMR, aynı zamanda genelleme hatalarını da maksimum bir seviyede tutarak azaltmayı amaçlamaktadır. DVMR’deki asıl amaç, ele alınan eğitime verilerinin benzer olan özniteliklerini en yakın ve doğru bir şekilde belirlemeye yarayan doğrusal fonksiyonun belirlenmesidir. DVMR’de hem doğrusal hem de doğrusal olmayan regresyon problemleri ele alınmaktadır. Ancak doğrusal olmayan regresyon problemlerinin çözülmesi oldukça zor olduğundan DVMR’nin detaylı öğrenme yaklaşımı daha çok doğrusal olmayan problemlere yöneliktir [184].

DVMR yönteminde; daha önce Eşitlik 2.64’te verilen $f(x) \rightarrow y = w \cdot x + b = 0$ doğrusal ayırım fonksiyonunun sağladığı $w \cdot x + b = 1$ ve $w \cdot x + b = -1$ noktalarından önceden belirlenen bir ε sapma değeri kadar bir mesafeye ve hata oranına müsaddele edilir. Yani; ele alınan eğitim verisinin elemanı olan gerçek x_i değerinden, önceden belirlenen bir değer olan ε ’dan büyük olmayan bir uzaklıktaki tahmin y_i değerini hesaplayabilecek bir $f(x)$ fonksiyonu elde etmek amaçlanmaktadır. Öğrenme algoritmasının elde ettiği hata değerinin, ε ’dan küçük olması önemsenmeyecek ancak bu değeri geçmesi model performansı açısından kabul edilmeyecektir [185]. Doğrusal ayırım fonksiyonun her iki noktasına ε sapma değerinin eklenmesi ile;

$$|y_i - (w \cdot x_i + b)| \leq \varepsilon \quad (2.66)$$

eşitliği elde edilmektedir. DVMR’nin doğrusal regresyondan en önemli farkı, doğrusal regresyon uygulamalarında veri setinin tamamı dikkate alınırken DVMR’de öznitelik bakımından belli bir düzlemde yer alan veriler ele alınır. İşte bu husustan dolayı Eşitlik 2.66 ile bulunmaya çalışılan $f(x)$ fonksiyonunun tüm veri seti için sağlanması çok

zordur. Bu problemi çözebilmek amacıyla ξ^+ ve ξ^- esneklik değişkenleri kullanılmaktadır. DVMR'nin sapma değerleri eklenmiş gösterimi Şekil 2.23'te verilmiştir.



Şekil 2.23. DVMR'nin sapma değeri gösterimi

$\xi^+ \geq 0$ ve $\xi^- \geq 0$ olmak üzere $y_i - (w \cdot x_i + b) \leq \varepsilon + \xi^+$ ve $(w \cdot x_i + b) - y_i \leq \varepsilon + \xi^-$ eşitliklerine bağlı olarak DVM'de de bahsedilen minimizasyon işleminin son durumu aşağıdaki eşitlikte verilmiştir.

$$\text{Minimizasyon: } \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L (\xi_i^+ + \xi_i^-) \quad (2.67)$$

Eşitlik 2.67'de verilen C parametresi, deneme-yanılma yoluyla önceden belirlenen ve hatalarla regresyon fonksiyonunun ilişkisini dengeleyen bir karmaşıklık katsayısıdır [186]. Bu parametreye bazı kaynaklarda ceza parametresi de denilmektedir. C parametresinin seçimi model performansı açısından oldukça önemlidir. Yüksek seçilen bir C değeri, yüksek hatalara sebep olabileceği gibi, düşük seçilen C değeri ise optimum hiper düzlemin yeri ile ilgili yanlışlara sebep olabilir.

Doğrusal olmayan regresyon problemleri, doğrusal olan regresyon problemlerine göre daha karmaşık yapıya sahiptir. Eşitlik 2.67'de verilen minimizasyon işleminde doğrusal bir fonksiyon elde edilemediği takdirde DVMR'nin doğrusal olmayan durumuna dönüştürülebilmesi için giriş uzayından daha yüksek boyutlu bir nitelik uzayına geçişin sağlanması gerekmektedir. Bu geçiş, çekirdek (kernel) fonksiyonları aracılığı ile haritalama fonksiyonları kullanılarak sağlanır ve böylece optimum hiper düzlem belirlenmektedir.

Eğitme veri setinin elemanları $S=\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ olmak üzere; giriş uzayında bulunan x_i değişkenleri $\emptyset: R_d \rightarrow H$ fonksiyonu ile yüksek boyutlu nitelik uzayına haritalanmaktadır. Daha önceden verilen $w \cdot x + b = 0$ eşitliğinde x olan yere $\emptyset(x)$ haritalama fonksiyonu yazıldığında DVMR hiper düzlemde;

$$f(x) = Y_{(x_t)} = w^T \cdot \emptyset(X_t) + b \quad w \in R, \quad b \in R \quad (2.68)$$

regresyon fonksiyonunu elde etmeye çalışır. Burada w ağırlık vektörünü, $\emptyset$ haritalama parametresini ve b ise bias (sapma ya da hata) değerini temsil etmektedir. Doğrusal olmayan regresyon problemlerinin çözümünde iç çarpımları doğrusal olmayan çekirdek fonksiyonları kullanılır. DVMR'nin öğrenme algoritmaları sadece x_i değişkenlerinin bulunduğu H giriş uzayındaki iç çarpım noktalarına bağlıdır. Bu yüzden iç çarpım sonucu, $\emptyset$ haritalama fonksiyonunun bilinmesine gerek kalmadan $k(x_i, x_j) = \emptyset(x_i)^T \emptyset(x_j)$ fonksiyonunun hesaplanması ile bulunabilmektedir. Yani giriş uzayındaki çekirdek nitelik uzayındaki bir iç çarpıma eşitlenmektedir. k fonksiyonu yüksek boyutlu nitelik uzayında bir noktaya karşılık gelen bir işlevi temsil etmektedir [187]. Ortamlar arası geçişler sağlandıktan sonra aşağıda verilen şu hiper düzlem eşitliği elde edilmektedir:

$$f(x) = (\sum a_i \cdot y_i \cdot \emptyset(x_i) \cdot \emptyset(x_j) + b) = \sum a_i \cdot y_i \cdot k(x_i, y_i) + b \quad (2.69)$$

Eşitlik 2.69'daki hataları azaltmak amacıyla Lagrange çarpanları ile birlikte karesel programlama problemi çözülür ve son durumda nihai regresyon fonksiyonu elde edilir. Tüm bu hesap adımlarının ardından elde edilen DVMR regresyon fonksiyonu şu şekildedir:

$$f(x) = \sum_{i=1}^n (a^* - a) k(x_i, x_j) + b \quad (2.70)$$

Eşitlik 2.70'de verilen a^* ve a ifadeleri Lagrange çarpanlarıdır. $k(x_i, x_j)$ çekirdek fonksiyonlarını temsil etmekte olup nitelik uzayındaki iç çarpımı vermektedir.

Çekirdek fonksiyonları hem sınıflandırma hem de regresyon problemlerinde kullanılan öğrenme algoritmalarına esneklik kazandırmaktadır. Doğrusal, Anova, Bessel, polinom, radyal tabanlı, Gauss, Laplace, sigmoid (hiperbolik tanjant) gibi başlıca çekirdek fonksiyonları bulunmaktadır. Her çekirdek fonksiyonunun farklı yapısı, farklı hesap ve

optimizasyon adımları ile farklı parametreleri vardır. DVM’de kullanılan çekirdek tipleri ve ana fonksiyonları Tablo 2.5’te verilmiştir.

Tablo 2.5. Çekirdek tipleri ve fonksiyonları [188]

Çekirdek tipi	Fonksiyonu
Doğrusal	$k(x, y) = x^T y + c$
Polinom	$k(x, y) = (ax^T y + c)^d$
Sigmoid (Hiperbolik tanjant)	$k(x, y) = \tanh(ax^T y + c)$
Bessel	$k(x, x') = -Bessel_{(nu+1)}^n(\sigma x - x' ^2)$
Gauss (Radyal tabanlı)	$k(x, y) = \exp(-\gamma\ x - y\ ^2)$
Anova (Radyal tabanlı)	$k(x, y) = \sum_{k=1}^n \exp(-\sigma(x^k - y^k)^2)^d$
Laplace	$k(x, y) = \exp(-\frac{\ x - y\ }{\sigma})$

DVMR’nin özellikle tahmin çalışmalarında yaygın bir şekilde kullanılmasında ve model performanslarının iyi çıkmasında çekirdek fonksiyonlarının kullanımının önemli bir etkisi vardır.

2.2.7.4. Gauss Süreç Regresyonu (GSR)

Gauss Süreç Regresyonu (GSR) (Gaussian Process Regression-GPR), Rasmussen ve Williams (2006) tarafından önerilen, parametrik olmayan ve Bayes öğrenme yaklaşımına dayalı bir makine öğrenmesi yöntemidir [189]. Ayrıca çekirdek (kernel) fonksiyonlarını temel alarak olasılık dağılımlarını belirleyen öğrenme yaklaşımlarına sahiptir. Kendine özgü bu öğrenme algoritmaları sayesinde daha az veriye ve daha az parametreye ihtiyaç duyan ve veri koruma özelliği bulunan esnek bir denetimli öğrenme aracıdır. Yine DVM’de olduğu gibi çekirdek fonksiyonları da kullanıldığından doğrusal olmayan problemlerin çözümünde başarılı sonuçlar vermektedir. Tüm bu özelliklerinden dolayı son yıllarda yapay zekânın kullanıldığı tahmin çalışmalarında sıklıkla tercih edilmektedir.

Tez çalışmasında daha önceki bölümlerde bahsedilen denetimli öğrenme algoritması, ele alınan bir eğitme veri setindeki giriş değişkenlerini baz alarak çıkış değişkenini

tahmin etmeyi amaçlayan ve öğrenen sistemin öğrenmesi istenen olay ile o olayın sonuçları arasındaki ilişkiyi belirlemesi istenen bir öğrenme yaklaşımıdır. Öğrenme algoritmasına yapılan dış müdahaleler nedeniyle denetimli olarak adlandırılmaktadır. Denetimli öğrenmede, sonlu bir eğitme veri setindeki tüm girdi değerleri için tahminler yapan bir fonksiyonu elde etmek oldukça güç olabilmektedir. Bu problemi ortadan kaldırmak adına çeşitli yöntemler geliştirilmiştir. Bu yöntemlerde başlıca iki farklı strateji dikkate alınmaktadır. Bunlardan ilki, veri setindeki girdinin sadece doğrusal fonksiyonlarını dikkate alarak ele alınacak olan fonksiyonu sınırlamaktır. İkinci strateji ise her fonksiyona önceden bir olasılık vermektir; hatta, daha olası olduğu düşünülen fonksiyonlara daha yüksek olasılıklar vermektir. İlk stratejide fonksiyon seçimi kritik bir husus olup ikinci stratejide ise sonsuz sayıdaki olasılık fonksiyonun sonlu hale nasıl getirileceği problem olmaktadır. İşte bu noktada Gauss süreci devreye girmektedir. Gauss süreci, Gauss olasılık dağılımının özelleştirilmiş bir formudur. Eğitme veri setini kendi içinde korumaya alır ve olasılık dağılımlarını detaylıca analiz ederek başarılı bir öğrenme sağlar. Diğer makine öğrenmesi algoritmalarında veri koruması yoktur ve verilerin dağılımını öğrenme konusunda zorluk yaşarlar. Olasılık dağılımları, skaler ya da vektör rastgele değişkenleri karakterize eder ancak fonksiyonların özelliklerini belirlemek ve tanımlamak için Gauss süreci gibi stokastik süreçler gerekir [190].

Genel olarak öğrenme algoritmaları, elde edilen çıktılar sürekli ise regresyon, kesikli (ayrık) ise sınıflandırma problemlerinde analiz edilmektedir. İki veya daha fazla sayıdaki değişken arasındaki ilişkiyi tahmin etmek için kullanılan denetimli öğrenme yöntemlerine ise regresyon denilmektedir. Stokastik Gauss sürecine regresyon analizi bu tanımlamalardan dolayı girmiş olup GSR yöntemi, tahmin belirsizliklerine yönelik çalışmalarda yaygın olarak kullanılmaktadır.

Gauss süreci ile ilgili olarak ilk önce standart doğrusal regresyon modeline ait Gauss dağılımı ve Bayes analizinden bahsetmek gerekir.

$$f(x) = x^T w, \quad y = f(x) + \varepsilon \quad (2.71)$$

Eşitlik 2.71’de verilen f fonksiyon değerini, x giriş vektörünü, w doğrusal modelin ağırlık vektörünü, ε bias (sapma ya da hata) değerini, y ise gözlenen hedef vektörünü temsil etmektedir. y gözlenen hedef vektörü, $f(x)$ fonksiyonundan ε sapma değeri kadar farklılık göstermektedir ve buna modelin gürültüsü de denmektedir. Bu gürültü

değerinin bağımsız, sıfır ortalama ve varyans değeri ile Gauss dağılımına uygun olduğu kabulü yapılmıştır. Bu varsayımın matematiksel gösterimleri şu şekildedir:

$$\varepsilon \sim N(0, \sigma_n^2) \quad (2.72)$$

$$y = f(x) + N(0, \sigma_n^2) \quad (2.73)$$

Gürültü ile ilgili bu varsayım, eğitme veri setindeki gözlemleri çarpanlarına ayıran parametreler aracılığı ile doğrudan gözlemlerin olasılık ve olasılık yoğunluklarına ulaşılmasını sağlar. Bu gürültü varsayımından yola çıkarak aşağıda verilen olasılık yoğunluk eşitliği elde edilmektedir.

$$p(y|X, w) = \prod_{i=1}^n p(y_i|x_i, w) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma_n} \exp\left(-\frac{(y_i - x_i^T w)^2}{2\sigma_n^2}\right) = N(X^T w, \sigma_n^2 I) \quad (2.74)$$

Bu eşitlikten Bayes formülüne geçebilmek için de gözlemlerden önce çarpan parametreleri ile ilgili çeşitli varsayımlar yapılmış olup ağırlık vektörlerine kovaryans matrisi ile sıfır ortalamalı bir Gauss eklenmiştir.

$$w \sim N(0, \Sigma_p) \quad (2.75)$$

Eşitlik 2.75'te verilen varsayımın anlamı, gözlem elemanlarının analizinden önce ağırlık vektörleri üzerinde bir öncül dağılımın uygulanmasıdır. Bu işlemten sonra ise Bayes kuralına göre gözlem kümesinin soncul olasılık dağılımı belirlenmektedir. İngiliz matematikçi, istatistikçi ve teolog Thomas Bayes'in 18. yy'da temellerini attığı ve sonradan istatistik ve olasılık çalışmalarında yaygın olarak kullanılan Bayes teoremi ya da Bayes kuralı, bir rastgele değişken için olasılık dağılımı içindeki koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi göstermektedir [191].

$$p(w|y, X) = \frac{p(y|X, w)p(w)}{p(y|X)} \quad (2.76)$$

Eşitlik 2.76'yı sözel olarak ifade edecek olursak Bayes kuralında soncul dağılım şu şekilde olmaktadır: Soncul olasılık dağılımı = (Olasılık $\times$ öncül) / (marjinal olasılık)

Gauss süreci, Gauss dağılımına sahip sonlu sayıdaki rastgele değişkenlerin toplamını ifade eder. Daha önce bahsedildiği üzere ele alınan ağırlık vektörlerine kovaryans

matrisi ile sıfır ortalamalı bir Gauss eklenmektedir. Son durumda Gauss süreci aşağıda verilen şu eşitlik ile temsil edilmektedir:

$$f(x) \sim GP(m(x_i), k(x_i, x_j)) \quad (2.77)$$

Eşitlik 2.77’de verilen $m(x_i)$ ortalama bir fonksiyonu, $k(x_i, x_j)$ ise kovaryans fonksiyonunu temsil etmektedir. Kovaryans matrisini elemanları rastgele değişkenler arasındaki benzerlikleri temsil eder. Rastgele değişkenler arasındaki benzerlikler ise aşağıda verilen üstel fonksiyon aracılığı ile belirlenebilmektedir.

$$k(x_i, x_j) = \exp\left(\|x_i - x_j\|^2 / (2\sigma^2)\right) \quad (2.78)$$

Eşitlik 2.78’de verilen σ , çekirdek genişlik parametresini ifade eder ve bu parametrenin optimize edilmesi gerekir. Gauss sürecinde kullanılan öğrenme algoritmalarının en önemli avantajlarından biri de Bayes kuralına dayalı olasılıksal öğrenme ile çekirdek fonksiyonlarını birleştirmesidir.

Gauss sürecinde gözlem kümesi dışında bir x_* değişken verisine bağlı olarak w ağırlık vektörü üzerindeki y_* çıktı değerinin tahmini dağılımını belirlemek için aşağıda verilen ve Gauss tarafından tanımlanan gömüleme fonksiyonu kullanılmaktadır.

$$p(y_*(x, y), x_*) = N(\mu_*(x_*), \sigma_*^2(x_*)) \quad (2.79)$$

Eşitlik 2.79’da verilen tahmini ortalama $\mu_*(x_*)$ ve kovaryans $\sigma_*^2(x_*)$ ifadelerinin değerlerini bulmak için aşağıda verilen eşitlikler kullanılmaktadır.

$$\mu_*(x_*) = k_*^T (K_\theta + \sigma^2 I)^{-1} y \quad (2.80)$$

$$\sigma_*^2(x_*) = k_{**} - k_*^T (K_\theta + \sigma^2 I)^{-1} k_* \quad (2.81)$$

Eşitlik 2.81’de verilen k_* ifadesi, eğitime ve test verileri arasındaki kovaryans değerlerine karşılık gelen $N \times 1$ matris boyutundaki kovaryans vektörüdür. k_{**} ifadesi ise test veri setinin otokovaryans vektörüdür. Tahmini ortalama ve kovaryansı elde etmek için uygun bir kovaryans fonksiyonu seçilmelidir. Çünkü Gauss sürecinde gözlem elemanları hakkında ağırlık vektörleri üzerinden önceden bilgi almak, kullanılan öğrenme algoritmasının en önemli yaklaşımıdır [192]. Kovaryans matrisi, eğitime ve test

çıktıları arasındaki ilişkiyi mesafelerine göre modelleyen çekirdek (kernel) fonksiyonları kullanılarak belirlenir. Bu noktada da çekirdek fonksiyonları baz alınarak belirlenen kovaryans fonksiyonunun seçimi model performansı açısından oldukça önemli olmaktadır. Ayrıca farklı çekirdek fonksiyonlarının kombine edilmesi ile de daha anlaşılır ve yeniden kullanılabilir veri setleri elde edilmektedir. Gauss süreçlerinde yaygın olarak kullanılan kovaryans fonksiyonları, radyal tabanlı temel fonksiyonlar ve diğer çekirdek fonksiyonları ile bunların versiyonları olarak ayrılmaktadır. Radyal tabanlı temel fonksiyonlar şunlardır: sabit, doğrusal, sıfır, saf ikinci dereceden. Çekirdek fonksiyonları ise karesel üstel, üstel, matern 3/2, matern 5/2, rasyonel ikinci dereceden, ard karesel üstel, ard üstel, ard matern 3/2, ard matern 5/2, ard rasyonel ikinci derecedendir.


GSR, doğrusal olmayan fonksiyonların özelliklerini öğrenme konusunda oldukça başarılıdır. Eğitim veri setinde öncül olasılık dağılımları ile elde edilen bilgilere göre giriş ve çıkış değerlerinin arasındaki regresyonu ortaya koyar. GSR, öğrenme aşamasında daha az veriye ve daha az parametreye ihtiyaç duyan ve belirsizlik problemleri üzerinde etkili olan bir öğrenme yöntemidir.

2.2.7.5. Uzun-Kısa Süreli Bellek (UKSB)

Uzun-Kısa Süreli Bellek (UKSB) (Long-Short Term Memory-LSTM), 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılan bir derin öğrenme algoritmasıdır. UKSB modeli, geleneksel Tekrarlayan Sinir Ağı (TSA) modellerinin uzun dönem zaman serilerini tahmin etmede karşılaştığı gradyan kaybolması ve sınırlı bellek kapasitesi problemlerini çözmek için geliştirilmiştir. UKSB modeli, TSA'nın mimarisini kullanmakta olup daha da geliştirilmiş özel bir türüdür [193].

UKSB öğrenme algoritmalarının yapısı ve işleyişi anlatılmadan önce TSA'nın yapısından bahsetmek gerekir. En basit haliyle TSA, ilk kez Amerikalı psikodilbilimci Jeffrey Elman tarafından 1990 yılında cümle yapısı simülasyonları ile ilgili çalışmada önerilmiştir. Evrişimli Sinir Ağları (ESA) ile birlikte derin öğrenme algoritmalarındaki iki ana mimariden biri de TSA mimarisidir. TSA mimarisi sıralı olarak bilgileri işleyen modelleme birimlerinden oluşmaktayken ESA mimarisi ise hiyerarşik bir öğrenme yaklaşımına sahiptir [194]. TSA mimarisinde ayrıca geri beslemeli bir yaklaşımla çok yönlü bir öğrenme döngüsü bulunduğu için özellikle dil

işleme problemleri ve zaman serilerinin tahminleri için uygun bir yapısı vardır. TSA mimarisinde tekrarlayan kavramının bulunmasının sebebi, bir eğitme veri setindeki her bir veri için aynı öğrenme işlevini önceki çıktılarına bağlı olarak yapmasından dolayıdır. Yani her bir veriyi sırayla teker teker ele alan bir öğrenme algoritmasına sahiptir. Bu sayede her bir verinin bağımsız bilgilerini kendi belleğinde tutarak tüm veri setinin özelliklerini ve bağımlılıklarını öğrenebilmektedir [161]. Şekil 2.24'te basit haliyle bir TSA mimarisi gösterilmektedir.




Şekil 2.24. TSA mimarisi [195]

TSA, her ne kadar sıralı bağımlılığı yakalamak amacıyla tüm verileri işleyerek çok yönlü bir öğrenme sunsa da bazı dezavantajlara sahiptir. Bu dezavantajların başında gradyan kaybolması (Vanishing gradient) problemi gelmektedir. TSA'da kullanılan geri beslemeli yaklaşımda bir önceki verinin bilgilerinin ağırlık değerleri ile çarpılması ile bir sonraki adıma (katmana) geçilmektedir. Ağırlık değerlerini güncellemek amacıyla türev yardımı ile gradyanlar kullanılmaktadır. Türevle ilgili bu hesap adımında bazı gradyan değerleri kaybolur. Buna gradyan kaybolması denilmektedir. Ayrıca sıralı bir şekilde tüm verilerin işlenmesi ve bir döngüde ele alınması hem zaman hem de bellek problemlerini ortaya çıkarmaktadır. Bazı durumlarda TSA, uzun ve sıralı verilere ait

bilgilerin birbirine bağımlılığını bulmakta problem yaşar ve önceki öğrendiği bilgileri unutmaya başlar.

Hem gradyan kaybolması hem de özellikle uzun veri setlerinin ele alındığı durumlarda TSA'nın bellek probleminden dolayı UKSB derin öğrenme algoritması geliştirilmiştir. TSA'nın mimarisini kullanan UKSB yönteminin özellikle uzun zaman serilerindeki derin özelliği son yıllarda geliştirilen önemli teknolojilerden biridir. UKSB yöntemi, veriler hakkındaki bilgileri uzun vadeli bağımlılıkları hatırlama yeteneği sayesinde rahatlıkla öğrenebilmektedir. UKSB'nin derin özelliği sayesinde unutma, giriş ve çıkış kapıları ile bellek hücreleri aracılığıyla verinin durum bilgisinin ne zaman unutulacağı ve ne kadar süreyle saklanacağı öğrenilebilmektedir. UKSB yönteminin TSA'dan en önemli farklı bellek hücrelerinin olması ve burada gizli hücrelerin hesabının yapılmasıdır. UKSB öğrenme algoritmasında, elde edilen bir bilgi bellek hücresinde saklanır ve ardından kapı kontrolleri aracılığıyla bir sonraki hücreye gönderilir. Bu kapılar aracılığıyla bilgileri detaylı bir şekilde işlemek oldukça kolaydır. Bu öğrenme akışı nihai çıktılar elde edilene kadar devam eder. Şekil 2.25'te UKSB modelinin mimari yapısı gösterilmektedir.



Şekil 2.25. UKSB mimarisi [196]

Şekil 2.25'te gösterimi verilen UKSB mimarisinde; x_t girdi değerini, h_t çıktı değerini, C_t bellek hücresi durumunu temsil etmektedir. Ayrıca mimaride gösterilen $\times$ ve $+$ sembolleri öğrenme aşamasında kullanılan toplama ve çarpma işlemlerini temsil etmektedir. Bellek hücresi, yapılan çeşitli iterasyonlar sonucunda verilere ait faydalı

bilgileri saklamak amacıyla tasarlanmış bir bileşendir. Kısacası UKSB mimarisinde ağı belleğidir [197]. Yine Şekil 2.25'te gösterilen ve kapı diye adlandırılan bölümler açıklanacak olursa hücre durumu elemanlarının hangi faydalı bilgileri taşıyacağı kapılar vasıtasıyla belirlenmektedir. Öğrenme akışı devam ettikçe kapılar ile hücre durumuna bilgi eklenir ya da çıkarılır. Kapılar aslında öğrenme sırasında hangi bilgilerin faydalı ya da faydasız olduğu ile hangi bilgilerin unutulup hangi bilgilerin de saklanacağına karar veren gelişmiş sinir ağlarıdır [198]. Tek hücreli bir UKSB mimarisindeki öğrenme akışının hem kapı bölümleri açıklaması hem de matematiksel ifade edilişi sırasıyla aşağıda verilmiştir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.82)$$

Eşitlik 2.82'de verilen f_t fonksiyonu, UKSB mimarisindeki unutma kapısını ve unutma sürecini, σ ifadesi sigmoid fonksiyonunu, W_f ve b_f parametreleri ise sırasıyla ağırlık vektörünü ve bias (hata ya da sapma) değerini temsil etmektedir. İlk kapı olan unutma kapısı, hücre durumundan hangi bilgilerin unutulacağını ya da saklanacağını kararının verildiği katmandır. Bu kapıda; bir önceki hücreden (h_{t-1}) iletilen bilgi ile birlikte yeni bilgi değeri x_t , sigmoid fonksiyonuna gönderilir. Buradan elde edilen çıktı bilgisi 0 ile çarpılarak bilgi unutulur ya da 1 ile çarpılarak hücre durumuna aktarılır.

Unutma sürecinden sonra giriş kapısındaki sigmoid katmanı olarak adlandırılan i_t değeri aşağıda verilen eşitlikle hesap edilmektedir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.83)$$

Giriş kapısı, hücre durumunda hangi yeni bilgilerin saklanacağını belirlediği ve ayrıca hücre durumunun güncellendiği katmandır. Bu kapıda veriler alınarak sahip olduğu kısa süreli bellek aracılığı ile daha önceki bildiklerine ek olarak yeni bilgileri öğrenmektedir. Unutma kapısında olduğu gibi yine (h_{t-1}) ve x_t değerleri sigmoid fonksiyonuna gönderilir. Sigmoid fonksiyonunun sonucuna göre önceden elde edilen bilgi ile yeni ele alınan bilgilerin güncellenip güncellenmeyeceğinin kararı verilmektedir. Elde edilen çıktı bilgisi 0 ile çarpılan bilgilerin faydasız, 1 ile çarpılan bilgilerin ise faydalı olduğu sonucuna varılır. Sigmoid fonksiyonundan sonra ağı düzenlemek amacıyla yine giriş kapısında (h_{t-1}) ve x_t değerleri tanjant fonksiyonu aracılığı ile aday hücre durumu değeri olan $\tilde{C}_t$ elde edilmektedir. Burada hangi bilgilerin

saklanacağına karar verebilmek amacıyla elde edilen çıktı sigmoid fonksiyonu ile çarpılır.

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.84)$$

Eşitlik 2.84'te verilen $\tilde{C}_t$ ifadesi 0 ile 1 arasında değer alan bir aday hücre durumu değerini temsil etmektedir.

Giriş kapısındaki işlemlerden sonra hücreye gelen C_{t-1} hücre durumu diğer katmanlardan gelen verilere bağlı olarak f_t unutma fonksiyonu ile çarpılır ve yeni hücre durumu olan C_t değeri elde edilmektedir. Bu adımda uzun vadeli belleğin bölümlerine yeni bilgiler eklenerek uzun süreli bellek yenilenmektedir.

$$C_t = f \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.85)$$

UKSB mimarisinin son kapısı olan çıkış kapısında; önceki katmanlardan geçirilen gizli hücre duruma ait (h_{t-1}) ve x_t değerleri sigmoid fonksiyonu ile çarpılarak çıkış kapısı çıktısı olan O_t değerinin hücre durumundan ne kadar etkilendiği belirlenir.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.86)$$

Eşitlik 2.85'te yeni değiştirilen C_t hücre durumu, tanjant fonksiyonuna aktarılmakta ve gizli hücre durumunun hangi bilgileri taşıyacağına karar vermek amacıyla tanjant fonksiyonu çıktısı, Eşitlik 2.86'da hesaplanan sigmoid fonksiyonu çıktısı ile çarpılır ve en sonunda gizli hücre durumu çıkışı olan h_t elde edilmektedir [199].

$$h_t = O_t \cdot \tanh(C_t) \quad (2.87)$$

Yukarıda özetlenen UKSB'nin öğrenme algoritması bu işlemi her bir veri için uzun vadeli bağımlılıkları belirlemek amacıyla gerçekleştirmektedir. Öğrenme akışında hem kısa süreli belleği hem de uzun süreli belleği aracılığı ile daha önceki bilgilerine ek olarak yeni bilgiler öğrenmekte ve yararlı bilgileri hücre durumunda saklamaktadır.

Yapısı ve işlevleri yukarıda anlatılan geleneksel UKSB yöntemine ait ağ mimarisinde zamanla bazı iyileştirmeler yapılmıştır. Hücre durumunda saklanan yararlı bilgilerin unutma ve giriş kapılarına da etki etmesini sağlamak amacıyla gözetleme deliği bağlantıları eklenmiştir. Yapılan bir diğer iyileştirme de unutma ve giriş kapılarının,

kapılı tekrarlayan birim (Gated Recurrent Unit-GRU) kapısı olarak tek bir kapı haline dönüştürülmesidir. Bu kapı sayesinde güncelleme işlemleri daha pratik olarak yapılmaktadır [200].

TSA öğrenme algoritmasındaki gradyan kaybolması ve sınırlı bellek kapasitesi problemlerini ortadan kaldıran UKSB derin öğrenme algoritması büyük ve karmaşık veri setlerini öğrenme konusunda oldukça başarılıdır. UKSB yönteminin öğrenme kapasitesinin diğer makine öğrenmesi ve derin öğrenme yöntemlerine göre üstün olması nedeniyle özellikle son on yıllık dönemde tahmin çalışmaları başta olmak üzere birçok alanda yaygın bir kullanımı söz konusudur.

2.2.8. Model Performansı Değerlendirme Kriterleri

Kuraklık ile ilgili yapılan bu tez çalışmasında ele alınan tahmin modellerinin doğruluğu ve birbirleri ile karşılaştırılması, literatürde yaygın olarak kullanılan istatistik hesaplarına dayalı altı farklı performans kriteri ile değerlendirilmiştir. Tahmin modellerindeki eğitime ve test sonuçları için bu performans kriterleri ayrı ayrı hesaplanmıştır. Çalışmada ele alınan performans kriterleri sırasıyla şunlardır: ortalama karesel hata (OKH), kök ortalama karesel hata (KOKH), ortalama mutlak hata (OMH), Nash-Sutcliffe etkinliği (NSE), model performansının genel indeksi (Overall Index (OI)) ve determinasyon katsayısı (R^2).

OKH, KOKH ve OMH değerlerinin 0'a ve R^2 değerinin ise 1'e yaklaşması modelden elde edilen tahmin değerinin orijinal verilere güçlü bir şekilde yakınsadığını ve yüksek bir tahmin yeteneği olduğunu göstermektedir. NSE, $-\infty$ ile 1 arasında değerler almaktadır. 0,5'ten düşük NSE değerleri yetersiz, 0,5 ile 0,7 arası kabul edilebilir, 0,7 ile 0,9 arası yüksek ve 0,9 ile 1 arası ise mükemmel bir performansı göstermektedir. Ayrıca NSE değerlerinin 0'dan küçük olması modelin kabul edilebilir bir model olmadığını göstermektedir [201]. Normalleştirilmiş kök ortalama karesel hata ile model verimlilik göstergeleri, OI kriterinde birleştirilmiştir. OI değeri de NSE'de olduğu gibi $-\infty$ ile 1 arasında değerler almaktadır. OI'nin 1 değerini alması modelin mükemmel bir tahmin yeteneği olduğunu göstermektedir [202]. Bu çalışmada kullanılan performans kriterleri sırasıyla aşağıda verilen eşitliklerle hesaplanmaktadır.

$$OKH = \frac{1}{N} \sum_{n=1}^N (SYI_{\text{tah}} - SYI_{\text{hes}})^2 \quad (2.88)$$

$$KOKH = \sqrt{\frac{1}{N} \sum_{n=1}^N (SYI_{tah} - SYI_{hes})^2} \quad (2.89)$$

$$OMH = \frac{1}{N} \sum_{n=1}^N |SYI_{tah} - SYI_{hes}| \quad (2.90)$$

$$NSE = 1 - \left[\frac{\sum_{n=1}^N (SYI_{hes} - SYI_{tah})^2}{\sum_{n=1}^N (SYI_{hes} - \overline{SYI_{hes}})^2} \right] \quad (2.91)$$

$$OI = \frac{1}{2} \left(2 - \frac{KOKH}{SYI_{hes\ max} - SYI_{hes\ min}} - \frac{\sum_{n=1}^N (SYI_{hes} - SYI_{tah})^2}{\sum_{n=1}^N (SYI_{hes} - \overline{SYI_{hes}})^2} \right) \quad (2.92)$$

$$R^2 = 1 - \left[\frac{\sum_{n=1}^N (SYI_{hes} - SYI_{tah})^2}{\sum_{n=1}^N (SYI_{tah} - \overline{SYI_{tah}})^2} \right] \quad (2.93)$$

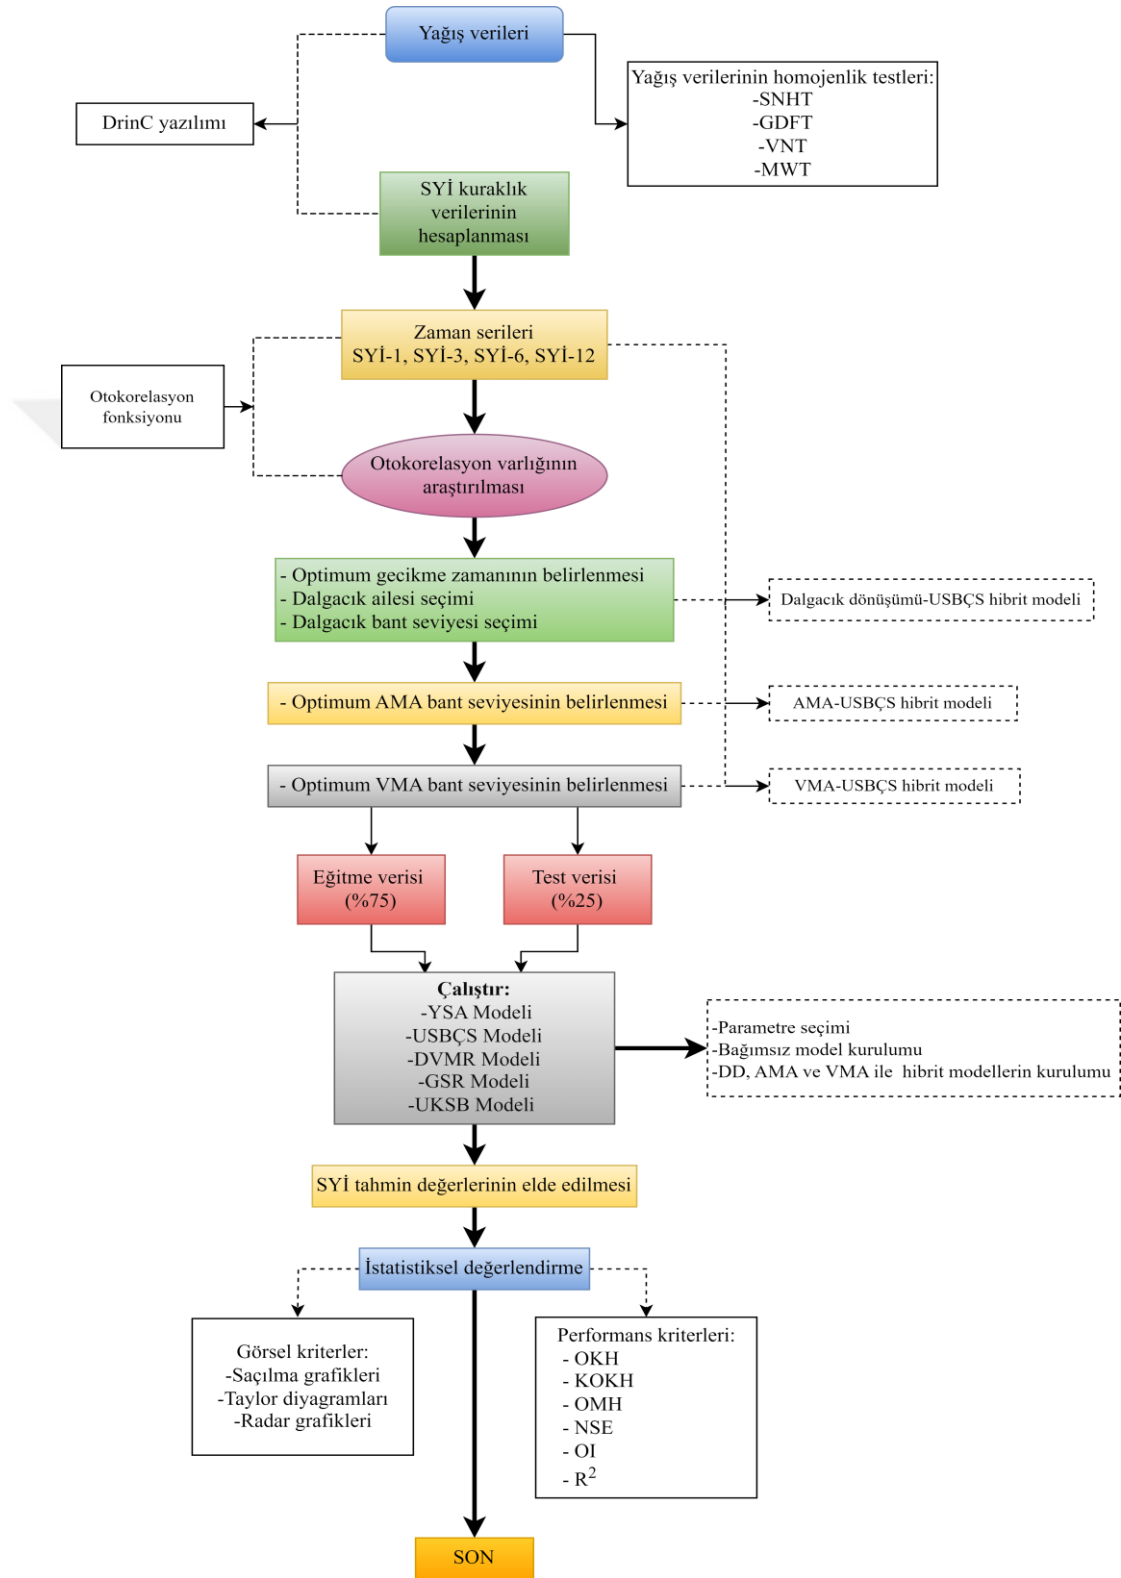
Eşitlik 2.88–2.93’te verilen N ifadesi serideki veri sayısını, SYI_{hes} istasyonlarda kaydedilen yağış verilerinden hesaplanan kuraklık değerini, SYI_{tah} ise tahmin modellerinden elde edilen kuraklık tahmin değerini ifade etmektedir. $\overline{SYI_{hes}}$ ve $\overline{SYI_{tah}}$ ifadeleri hesaplanan ve tahmin edilen kuraklık değerlerinin ortalamalarını, $SYI_{hes\ max}$ and $SYI_{hes\ min}$ sembolleri ise hesaplanan kuraklık değerlerine ait serideki maksimum ve minimum değerleri temsil etmektedir.

Yukarıda sayılan performans kriterlerinin yanı sıra hesaplanan kuraklık değerleri ile modelden elde edilen kuraklık tahmin değerleri arasındaki ilişkiyi bir arada gösterebilmek amacıyla saçılma grafikleri de kullanılmıştır. Yine aynı şekilde hesaplanan referans kuraklık değerleri ile tahmin edilen kuraklık değerlerinin standart sapma, korelasyon katsayısı ve merkezlenmiş kök ortalama karesel farkı istatistiksel değerlerinin eş zamanlı olarak değerlendirilebildiği Taylor diyagramları bu çalışmada kullanılmış ve model sonuçları karşılaştırılmıştır. Tüm bunlara ek olarak tüm performans kriterlerini bir arada gösteren radar grafikleri, en üstün sonuçları veren modeller için hataları daha kolay karşılaştırmak amacıyla kullanılmıştır [91].

2.2.9. Model Gelişimi

Bu tez çalışmasında; Türkiye'nin kuzeybatısında yer alan ve önemli nehir havzalarından biri olan Sakarya havzasını temsil edecek 10 adet meteoroloji gözlem istasyonuna ait uzun dönem yağış verileri kullanılarak 1, 3, 6 ve 12 aylık kısa dönemlerdeki meteorolojik kuraklık değerleri tahmin edilmeye çalışılmıştır. İstasyonların aylık yağış verilerinden hesaplanan SYI -1, SYI -3, SYI -6 ve SYI -12 kuraklık değerleri, bağımsız ve

hibrit tahmin modellerinde eğitime ve test giriş verisi olarak kullanılmıştır. Çalışmada dikkate alınan metodolojiye ait akış şeması Şekil 2.26'da gösterilmektedir.



Şekil 2.26. Çalışmanın akış şeması

Şekil 2.26’da gösterildiği üzere çalışmada ilk olarak istasyonlara ait yağış verileri ele alınmıştır. Yağış verileri, Meteoroloji Genel Müdürlüğünden (MGM)’den temin edilmiş olup gözlem süresinin yeterli kabul edilebilecek uzunlukta olması, eksik veri olmaması, verilerin güncel olması ve havzayı temsil etme durumlarına göre havza içerisinde 10 adet yağış istasyonu seçilmiştir. Seçilen istasyonlarda gözlem süreleri içerisinde eksik veri bulunmadığından verilerin tamamlanmasına yönelik herhangi bir işleme gerek kalmamıştır.

Özellikle hidrometeorolojik zaman serilerindeki değişkenlerin dağılımlarında serinin homojen, durağan ve bağımsız olması önemlidir. Seride görülen trendlerin, ekstrem sapmaların ya da değişimlerin yalnızca ilgili değişkene bağlı olması durumu olan homojenlik, zaman serisi tahmin modellerinin doğruluğunu, tutarlılığını ya da güvenilirliğini doğrudan etkilemektedir. Bu nedenle ele alınan serinin homojenlik, durağanlık ve bağımsızlık durumlarının istatistiksel testlerle kontrol edilmesi gerekmektedir. Bu çalışmada, ele alınan tüm istasyonlara ait ham yağış verilerinin homojenliğini araştırmak amacıyla literatürde yaygın bir şekilde kullanılan Standart Normal Homojenlik Testi (SNHT), Genişletilmiş Dickey-Fuller Testi (GDFT), Von-Neumann Homojenlik Testi (VNT) ve Mann-Whitney u Testi (MWT) yöntemleri kullanılmıştır. Testlerle ilgili analizler MATLAB 2021b yazılımında tamamlanmıştır.

Bu çalışmanın temelini oluşturan kuraklık tahmininde, kısa dönem meteorolojik kuraklık değerlerini temsil edecek olan kuraklık indisi ile birlikte indisin değerlerini hesaplamak da önemli bir yer tutmaktadır. Bu nedenle havzada ele alınan 10 adet yağış istasyonunun geçmiş dönem kaydedilen aylık yağış verilerinden meteorolojik kuraklık değerlerini temsil edecek olan Standartlaştırılmış Yağış İndeksi (SYİ) kuraklık değerleri 1, 3, 6 ve 12 aylık zaman ölçekleri için SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 olacak şekilde hesaplanmıştır. Hesaplama işlemi için araştırmacılara ücretsiz ve açık olan pratik bir kuraklık indisi hesaplama yazılımı DrinC (Drought Indices Calculator) kullanılmıştır. DrinC yazılımının kullanılmasının sebebi, çalışmada ele alınan istasyon sayısının fazla olması ve dört farklı zaman ölçeğinde hesaplamalar yapılması gerektiği için işlem yükünden ve zamandan tasarruf sağlamaktır. DrinC yazılımı ile tüm istasyonlara ait SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık değerleri hesaplanarak tahmin modellerinin altlığını oluşturacak olan kuraklık zaman serileri elde edilmiştir.

SYİ kuraklık zaman serileri elde edildikten sonra bu serilerde otokorelasyon probleminin olup olmadığı araştırılmıştır. Otokorelasyon varlığı, zaman serileri ile ilgili analizlerde hata terimleri arasındaki bir iç bağımlılık durumudur. Bu bağımlılık tahmin modellerinin başarısını etkileyen önemli bir faktördür. Bu çalışmada; SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık değerlerinin farklı gecikme zamanları (t , $t-1$, $t-2$, $t-3$, ...vb.) tahmin modellerinde girdi değişkeni, $t+1$ zamanı ise çıktı değeri olarak kabul edilmiştir. Zaman serilerine dayalı tahmin modellerinin başarısı, gecikme süreleri ile optimum sayıda girdi değişkeni arasındaki ilişki ile belirlenmektedir. Bu nedenle çalışmada, otokorelasyon fonksiyonu aracılığı ile hem serilerdeki otokorelasyon varlığı araştırılmış hem de tahmin modellerine girecek olan optimum gecikme zamanlarının hangi güven aralığında kaldığı belirlenmiştir. Çalışmada nihai olarak kullanılan gecikme zamanları ADD-USBÇS hibrit modelleri ile belirlenmiş olup bu bölümün ilerleyen kısımlarında daha detaylı bir şekilde anlatılacaktır. SYİ kuraklık zaman serilerindeki otokorelasyon varlığı ve optimum gecikme zamanı güven aralığını belirlemek için MATLAB 2021b yazılımında geliştirilen otokorelasyon fonksiyonunun açık kodları kullanılmıştır.


Bu tez çalışmasında; kuraklık zaman serilerinin analizleri üzerinde durulduğundan veri dönüştürme ve ayrıştırma, özellik çıkarma, öznitelik seçimi gibi veri ön işlemleri yerine getiren Ayrık Dalgacık Dönüşümü (ADD), Ampirik Mod Ayrıştırma (AMA) ve Varyasyonel Mod Ayrıştırma (VMA) teknikleri kullanılmıştır. İlk olarak ele alınan ön işleme tekniği ADD'dir. DD tekniğinin bir alt yöntemi olan Ayrık Dalgacık Dönüşümü (ADD) kullanılarak Sakarya meteoroloji istasyonunun yağış verilerinden hesaplanan orijinal SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık verileri, dalgacık alt bantlarına ayrılmış ve bu alt bantlar, USBÇS tahmin modelinde eğitime ve test verisi şeklinde girdi değişkeni olarak kullanılmıştır. Burada sadece Sakarya meteoroloji istasyonunun kuraklık değerleri dalgacık alt bantlarına ayrılmıştır. Bu istasyonun dalgacık alt bantlarına göre oluşturulan hibrit ADD-USBÇS tahmin modelinde, optimum gecikme zamanlarının belirlenmesi ile birlikte dalgacık ailesi seçimi ve dalgacık bant seviyesi seçimi yapılmıştır. Bu modelden elde edilen en iyi sonuçlar her bir zaman ölçeği için diğer istasyonlarla birlikte diğer yöntemlerle oluşturulan modellerde de kullanılmıştır.

Optimum gecikme zamanları, otokorelasyon fonksiyonu ile ortaya konulan güven aralığı sınırlarına göre ele alınmış olup t orijinal kuraklık verisi olmak üzere (t , $t-1$, $t-2$, $t-3$, $t-4$ ve $t-5$) 5 farklı gecikme zamanına göre analiz edilmiştir. Yalnızca Sakarya

istasyonunun her bir zaman ölçeği (SYİ-1, SYİ-3, SYİ-6 ve SYİ-12) için hibrit ADD-USBÇS tahmin modelindeki en iyi performansı gösteren gecikme zamanları belirlenmiş ve belirlenen bu optimum gecikme zamanları tüm istasyon ve modellerde kullanılmıştır.

Kuraklık zaman serilerinin ADD ile alt serilerine ayrıştırılması sürecinde diğer çalışmalara nazaran bu çalışmada çok daha fazla dalgacık ailesi ve onların versiyonları incelenmiştir. Çünkü dalgacık ailesi seçimi ile dalgacık ailesinin serileri alt bantlarına ayrıştırma yeteneği modelin tüm performansını etkileyen özelliklerdir. Ayrıca, kuraklık zaman serilerinin hangi dalgacık ailesi ile daha uyumlu olduğunu belirlemek amacıyla da çok sayıda dalgacık ailesi ele alınarak çalışmanın kapsamı artırılmıştır. Bu çalışmadaki dalgacık dönüşümünde; Haar, Daubechies (db40), Symlets (sym3), Coiflets (coif2), Biortogonal (bior1.3), Ters Biortogonal (rbio1.3), Meyer'in Ayrık Yaklaşımı (Discrete Approximation of Meyer (dmey)) ve Fejer-Korovkin (fk4) dalgacık aileleri kullanılmıştır. Sayılan bu dalgacık ailelerinin Sakarya istasyonuna ait kuraklık zaman serilerini alt bantlarına ayrıştırma yetenekleri, performans kriterlerine göre birbirleri ile karşılaştırılmış ve her bir zaman ölçeği için en üstün sonuçlara sahip dalgacık ailesi çalışmanın tümünde kullanılmıştır.

ADD ile serinin alt bantlarına ayrıştırılması işlemindeki en önemli hususlardan biri de dalgacık bant seviyesinin (dalgaçık ayrıştırma seviyesinin) belirlenmesidir. Burada yine çalışmanın kapsamını artıracak şekilde diğer çalışmalara göre daha fazla dalgacık bant seviyesi üzerinde durulmuştur. Bu çalışmada; 3, 4, 5, 6 ve 7 olmak üzere beş farklı dalgacık bant seviyesine göre kuraklık zaman serileri alt bantlarına ayrıştırılmıştır. ADD ile ilgili yapılan analizler yine MATLAB 2021b yazılımında geliştirilen açık kodlar kullanılarak tamamlanmıştır. MATLAB 2021b yazılımı ile Sakarya istasyonu SYİ-1 için yapılan dmey dalgacık ailesine sahip, 3 gecikme zamanlı ve 3. bant seviyesine göre bir dalgacık dönüşümü Şekil 2.27'de gösterilmiştir.



Şekil 2.27. dmey dalgacık ailesi ile 3 gecikme zamanlı 3. bant seviyesine göre yapılan dalgacık dönüşümü

ADD ile alt bantlarına ayrılan Sakarya istasyonu SYİ kuraklık serileri, USBÇS tahmin modelinde eğitime ve test verisi şeklinde girdi değişkeni olarak kullanılmıştır. Bu aşamada USBÇS makine öğrenmesi yönteminin seçilme sebebi, bu yöntemin uyarlanabilir özelliği ile hızlı analizler yapmasıdır. ADD-USBÇS hibrit tahmin modelinde, Sakarya istasyonunun alt bantlarına ayrılan giriş verilerinin %75'i (1960–2005) eğitime verileri, %25'i (2006–2021) ise test verisi olarak kabul edilmiştir. USBÇS tahmin modeli ile ilgili analizler yine MATLAB 2021b yazılımında geliştirilen açık kodlar kullanılarak tamamlanmıştır.


USBÇS tahmin modelinde bulanık çıkarım sistemi olarak Takagi-Sugeno yaklaşımı kullanılmıştır. Takagi-Sugeno yaklaşımı, optimizasyon ve uyarlanabilir tekniklerle birlikte ele alındığında Mamdani yaklaşımına göre daha başarılıdır ve hesap adımları pratiktir. Sinir ağı modeli olarak ise ızgara kümeleme (grid partition) yöntemi tercih edilmiş olup bunun sebebi daha az bağlantı ile katmanları birbirine daha hızlı bağlama özelliğidir. USBÇS'de öğrenme algoritması olarak hem bulanık mantık hem de sinir ağı

kurallarını kolaylıkla öğrenebilen hibrit algoritması kullanılmıştır. Ayrıca bu algoritma diğer öğrenme algoritmalarına göre daha hızlıdır. Giriş üyelik fonksiyonları olarak Gauss (gaussmf) ve üçgen (triangular-trimf), çıkış üyelik fonksiyonları olarak ise sabit (constant) ve doğrusal (linear) fonksiyonlar kullanılmıştır. Bu çalışmada kullanılan USBÇS yönteminde dikkate alınan model parametreleri Tablo 2.6’da verilmiştir.


Tablo 2.6. USBÇS tahmin modeli parametreleri

Parametre adı	Parametre özelliği veya değeri
Bulanık çıkarım tipi	Takagi-Sugeno
Sinir ağı modeli	Izgara kümeleme (Grid partition)
Eğitme optimizasyonu	Hibrit algoritması
Girdi sayısı	6 adet (t, t-1, t-2, t-3, t-4 ve t-5)
Çıktı sayısı	1 adet (t+1)
Üyelik fonksiyon sayıları	2 ve 3
İterasyon sayısı	1-10
Öğrenme oranını artırma katsayısı	1.1
Öğrenme oranını azaltma katsayısı	0.9
Giriş üyelik fonksiyonları	Gauss (gaussmf) ve üçgen (triangular-trimf)
Çıkış üyelik fonksiyonları	Sabit (constant) ve doğrusal (linear)

Dalgacık dönüşümünden sonra Ampirik Mod Ayırıştırma (AMA) ve Varyasyonel Mod Ayırıştırma (VMA) ön işleme teknikleri ile Sakarya istasyonunun orijinal kuraklık zaman serilerinin (SYİ-1, SYİ-3, SYİ-6 ve SYİ-12) alt bantlarına ayrıştırılması işlemine geçilmiştir. ADD-USBÇS hibrit modelinde elde edilen optimum gecikme zamanına göre her iki yöntemde de dört farklı bant seviyesi (2D, 3D, 4D, 5D) için orijinal kuraklık zaman serileri alt bantlarına ayrılmıştır. Bant seviyelerinin ayrıştırma kapasitesini ve model başarısındaki etkilerini görebilmek adına farklı bant seviyeleri ele alınmıştır. Her bant seviyesi için serilerin İçsel Mod Fonksiyonu (İMF) ve artık bileşenlerinin toplamaları alınarak alt bantlar elde edilmiştir. AMA ve VMA ön işleme teknikleri ile alt bantlarına ayrıştırma analizleri, MATLAB 2021b yazılımında geliştirilen açık kodlar kullanılarak tamamlanmıştır. MATLAB 2021b yazılımı ile Sakarya istasyonu SYİ-1 için 2D (2. bant seviyesi) bant seviyesine göre yapılan bir AMA dönüşümü örneği Şekil 2.28’de, VMA dönüşüm örneği ise Şekil 2.29’da gösterilmiştir.



Şekil 2.28. 2D bant seviyesine göre yapılan AMA örnek dönüşümü



Şekil 2.29. 2D bant seviyesine göre yapılan VMA örnek dönüşümü

AMA ve VMA ile elde edilen alt bant serileri, AMA-USBÇS ve VMA-USBÇS hibrit modellerinde eğitime ve test verisi şeklinde girdi değişkeni olarak kullanılmıştır. Yine daha önce olduğu gibi bu hibrit modellerde, Sakarya istasyonunun alt bantlarına ayrılan giriş verilerinin %75'i (1960–2005) eğitime verileri, %25'i (2006–2021) ise test verisi

olarak kabul edilmiştir. Sakarya istasyonunun her bir zaman ölçeği için belirlenen en optimum AMA ve VMA bant seviyeleri, diğer istasyonlarda ve modellerde de kullanılmıştır.

Sakarya meteoroloji istasyonunun orijinal kuraklık değerlerine her bir zaman ölçeği için (SYİ-1, SYİ-3, SYİ-6 ve SYİ-12) DD, AMA ve VMA ön işleme teknikleri uygulanarak USBÇS hibrit tahmin modellerinde çalışmanın tamamında dikkate alınacak olan optimum gecikme zamanı, optimum dalgacık ailesi, optimum dalgacık bant seviyesi ile optimum AMA ve VMA bant seviyeleri bulunmuştur. Tüm bu analizlerin sonucunda bağımsız veya hibrit tahmin modellerine girecek olan nihai eğitime ve test verilerinin giriş karakteristikleri elde edilmiştir. Daha sonraki aşamada ise tüm istasyonların kuraklık tahmin değerlerinin elde edilmesi için bağımsız ve hibrit tahmin modeli oluşturulmuştur. Bağımsız modeller olarak sadece YSA, USBÇS, GSR, DVMR ve UKSB tahmin modelleri ele alınmıştır. Hibrit tahmin modelleri ise yine bu beş modele ADD, AMA ve VMA ön işleme tekniklerinin dâhil edilmesi ile oluşturulmuştur. Çalışmada; her bir istasyonun her bir zaman ölçeği için toplamda 20 adet (5 adet bağımsız ve 15 adet hibrit) kuraklık tahmin modeli kullanılmıştır.


Daha önce USBÇS yönteminin model kurulumu ve parametrelerinden bahsedildiğinden dolayı kalan dört yöntemin model kurulumu ve parametrelerinden bahsedilecektir. YSA, güçlü öğrenme algoritmaları ve tahmin problemlerindeki başarısı nedeniyle kuraklık tahmini ile ilgili bu çalışmada da tercih edilmiştir. Bağımsız ve hibrit YSA tahmin modellerine girecek olan eğitime ve test verileri, tüm veri setinin %75'i eğitime ve %25'i test olacak şekilde kabul edilmiştir. Giriş verileri, hızlı ve diğer öğrenme yöntemlerine göre daha doğru tahminler veren sayısal bir optimizasyon tekniği olan Levenberg-Marquardt öğrenme algoritması (trainlm) ile eğitilmiştir. YSA modelinde, bilgi akışının iki yönlü olarak sağlanması istendiğinden geri beslemeli ağ yapısı tercih edilmiştir. Ayrıca bu çalışmada bir ara (gizli) katmana sahip çok katmanlı bir sinir ağı modeli kullanılmıştır. Katmanlar arası bilgi aktarımını sağlayan transfer fonksiyonları olarak hiperbolik tanjant sigmoid (tansig) ve logaritmik sigmoid fonksiyonu (logsig) tercih edilmiştir. Girdilere dayalı olarak çıktıların özelliklerini belirleyen ve çıktıların elde edilmesini sağlayan aktivasyon fonksiyonu olarak ise doğrusal transfer fonksiyonu (purelin) kullanılmıştır. Çalışmada tercih edilen transfer ve aktivasyon fonksiyonları ile birlikte 2–10 aralığındaki nöron sayısı ve 1–200 arasında değişen iterasyonlarla farklı ve

çok çeşitli model kombinasyonlarına göre tahmin modelleri elde edilmiştir. Tablo 2.7’de YSA tahmin modellerine ait parametreler özet olarak verilmiştir.

Tablo 2.7. YSA tahmin modeli parametreleri

Parametre adı	Parametre özelliği veya değeri
Ağın bağlantı yönü	Geri beslemeli
Sinir ağı modeli	Çok katmanlı
Öğrenme algoritması	Levenberg-Marquardt (trainlm)
Girdi sayısı	4 adet (t, t-1, t-2, t-3)
Çıktı sayısı	1 adet (t+1)
Nöron sayısı	2-10
İterasyon sayısı	1-200
Transfer fonksiyonları	Logaritmik sigmoid (logsig) ve hiperbolik tanjant sigmoid (tansig)
Aktivasyon fonksiyonu	Doğrusal transfer fonksiyonu (purelin)

MATLAB 2021b yazılımında Sakarya istasyonu SYİ-1 için YSA tahmin modeline ait örnek bir öğrenme süreci Şekil 2.30’da gösterilmiştir.




Şekil 2.30. YSA tahmin modeli öğrenme süreci

Çalışmada ele alınan bir diğer makine öğrenmesi yöntemi Destek Vektör Makine Regresyonu (DVMR)'dir. İstatistiksel öğrenme teorisi ile yapısal risk minimizasyonuna dayalı bir yöntem olan DVM'nin regresyon yani tahmin problemlerine yönelik geliştirilen bir alt grubu olan DVMR, iyi bir genelleme yeteneği olması ve doğrusal olmayan problemleri çekirdek (kernel) fonksiyonları aracılığı ile kolaylıkla çözebilmesi nedenlerinden dolayı tercih edilmiştir. DVMR'nin hem bağımsız hem de ADD, AMA ve VMA'lı hibrit kuraklık tahmin modelleri oluşturulmuştur. DVMR tahmin modelleri, MATLAB 2021b yazılımında geliştirilen açık kodlar kullanılarak tamamlanmıştır. DVMR tahmin modellerinde; Gaussian, polinom, radyal tabanlı fonksiyon ve doğrusal (lineer) olmak üzere dört farklı çekirdek fonksiyonu kullanılmıştır. Ayrıca, DVMR'nin öğrenme aşamasında ortaya çıkan ikinci dereceden programlama problemini çözen Sıralı Minimum Optimizasyon (SMO) yöntemi modellerde optimizasyon algoritması olarak kullanılmıştır. DVMR modellerinde kutu sınırlama seviyesi belirlenerek optimum hiper düzlem aralığı için gerekli işlemler ve parametre hesapları bu aralıkta yapılır. Bu çalışmada, kutu sınırlama seviyesi 1 olarak seçilmiştir. Tahmin modellerindeki girdi ve çıktılar, 1–30 arasında değişen iterasyonlarla ve doğru standardizasyon yöntemi ile analiz edilerek elde edilmiştir. DVMR tahmin modeli parametreleri Tablo 2.8'de özetlenmiştir.

Tablo 2.8. DVMR tahmin modeli parametreleri

Parametre adı	Parametre özelliği veya değeri
Çekirdek fonksiyonları	Gauss, polinom, radyal tabanlı ve doğrusal
Optimizasyon algoritması	Sıralı minimum optimizasyon (SMO)
Standardize yöntemi	Doğru
Girdi sayısı	4 adet (t, t-1, t-2, t-3)
Çıktı sayısı	1 adet (t+1)
İterasyon sayısı	1-30
Kutu sınırı	1-1000
Kernel ölçeği	1
ε parametresi	0.09
C parametresi	Otomatik

MATLAB 2021b yazılımı ile DVMR modelinde Sakarya istasyonu SYİ-1 için optimizasyonla hiper düzlemin ve minimum hata oranının bulunmasına yönelik model örneği Şekil 2.31’de verilmiştir.



Şekil 2.31. DVMR yöntemi ile optimum hiper düzlemin ve minimum hata oranının bulunmasına ait örnek model

Bu çalışmada ele alınan bir diğer makine öğrenmesi yöntemi, Gauss Süreç Regresyonu (GSR)’dur. Tahmin problemlerini ele alırken daha az veriye ve daha az parametreye ihtiyaç duyan parametrik olmayan bir öğrenme algoritmasına sahiptir. Çekirdek (kernel)

fonksiyonları ile oldukça iyi uyum gösteren bu yöntem, tahmin problemlerindeki başarısından dolayı bu çalışmada tercih edilmiştir. GSR modellerindeki en kritik parametre optimum kovaryans matrisinin ve buna bağlı olarak kovaryans fonksiyonunun belirlenmesidir. Çalışmada; GSR'nin tahmin kapasitesini kapsamlı bir şekilde ele alabilmek ve model performanslarını artırabilmek adına birçok farklı fonksiyon ele alınmıştır. Gauss süreçlerinde yaygın olarak kullanılan kovaryans fonksiyonları, radyal tabanlı temel fonksiyonlar ve diğer çekirdek fonksiyonları olarak ayrılmaktadır. Radyal tabanlı temel fonksiyonlar şunlardır: sabit, doğrusal, sıfır, saf ikinci dereceden. Çekirdek fonksiyonları ise karesel üstel, üstel, matern 3/2, matern 5/2, rasyonel ikinci dereceden, ard karesel üstel, ard üstel, ard matern 3/2, ard matern 5/2, ard rasyonel ikinci derecedendir. GSR modeli ile yapılan analizlerde bu fonksiyonlar içinden hata kriteri en az olan yönteme ait çıktılar sonuç çıktısı olarak kabul edilmiştir. Ayrıca bu denli çok fonksiyonun ele alınmasındaki önemli bir neden de MATLAB 2021b yazılımında GSR modeli tahmin işlemlerinin hızlı bir şekilde yapılabilmesidir.

GSR tahmin modellerinde, öğrenme algoritması olarak önceden herhangi bir ön parametre bilgisine ihtiyaç duymayan ve olasılık tabanlı Bayes optimizasyon tekniği kullanılmıştır. GSR modellerinde değerleri bulunmaya çalışılan β (tahmini ortalama değer) (bazı kaynaklarda μ olarak gösterilmektedir [192]) ve σ (çekirdek genişlik parametresi) parametreleri, tamamen bağımsız koşullu yaklaşım (fully independent conditional approximation) ile bulunarak varyans probleminin önüne geçilmekte ve çekirdek fonksiyonları daha da işlevsel hale getirilmektedir [203]. Kernel ölçeği DVMR'de oldu gibi GPR tahmin modellerinde de 1 alınmıştır. 1–30 arasında değişen iterasyonlarla ve doğru standardizasyon yöntemi ile analizler yapılarak model çıktıları elde edilmiştir. GSR yöntemi kullanılarak oluşturulan tahmin modelleri, MATLAB 2021b yazılımında analiz edilmiştir. GSR tahmin modeli parametreleri Tablo 2.9'da özetlenmiştir.

Tablo 2.9. GSR tahmin modeli parametreleri

Parametre adı	Parametre özelliği veya değeri
Radyal tabanlı temel fonksiyonlar	Sabit, doğrusal, sıfır, saf ikinci dereceden
Çekirdek fonksiyonları	Karesel üstel, üstel, matern 3/2, matern 5/2, rasyonel ikinci dereceden, ard karesel üstel, ard üstel, ard matern 3/2, ard matern 5/2, ard rasyonel ikinci dereceden
Optimizasyon algoritması	Bayes optimizasyon tekniği
Parametre hesap yöntemi	Tamamen bağımsız koşullu yaklaşım
Standardize yöntemi	Doğru
Girdi sayısı	4 adet (t, t-1, t-2, t-3)
Çıktı sayısı	1 adet (t+1)
İterasyon sayısı	1-30
Kernel ölçeği	1

Çalışmada ele alınan tahmin modellerinden biri de son dönemin popüler öğrenme algoritmalarından biri olan Uzun-Kısa Süreli Bellek (UKSB) ile oluşturulmuştur. Geleneksel yöntemlerde karşılaşılan gradyan kaybolması ve sınırlı bellek kapasitesi problemlerini çözmek için geliştirilen UKSB, bir derin öğrenme yöntemidir. Veri setindeki bilgileri uzun vadeli bağımlılıkları hatırlama yeteneği sayesinde rahatlıkla öğrenebildiğinden bu çalışmada tercih edilmiştir.


Kuraklık tahmin çalışmasında önerilen UKSB modellerine ait hücre mimarisinde; giriş katmanı olarak “dizi giriş katmanı” (sequence input layer), gizli katman olarak “çift yönlü UKSB katmanı” (bidirectional LSTM layer-BILLSTM), bağlantı katmanı olarak “tam bağlantılı katman” (fully connected layer) ve çıkış katmanı olarak ise “regresyon katmanı” (regression layer) kullanılmıştır. UKSB tahmin modellerinde, derin ağı eğitmesi amacıyla üç farklı öğrenme algoritması kullanılmıştır. Bu algoritmalar; “momentumlu stokastik gradyan inişi” (stochastic gradient descent with momentum-SGDM), “kök ortalama karesel yayılma” (root mean squared propagation-RMSProp) ve Adam algoritmasıdır. Bu algoritmalar her analiz için tek tek denenmiş ve içlerinden hata kriterlerine göre en iyi sonucu veren algoritma seçilmiştir. Hücredeki bilgi iletimini sağlayan kapılar için sigmoid aktivasyon fonksiyonu, verileri saklama işlevi olan hücre

durum bellekleri için tanjant aktivasyon fonksiyonu kullanılmıştır. Ayrıca UKSB tahmin modellerinde; karesel gradyan kaybolma faktörü 1, eğitme sürecinin başında belirlenen ilk öğrenme oranı 0,05, öğrenme oranı azaltma faktörü 0,2 ve öğrenme oranı azaltma döngüsü 50 olarak tercih edilmiştir. Modellerde ele alınan bir gizli katmanda nöron sayısı 5–20 aralığında olup maksimum döngü sayısı ise 200 olarak kabul edilmiştir. UKSB derin öğrenme algoritması, verileri kendi içinde standartlaştırdığından ilave bir yönteme ihtiyaç duymamaktadır. Tablo 2.10’da UKSB tahmin modeli parametreleri verilmiştir.

Tablo 2.10. UKSB tahmin modeli parametreleri

Parametre adı	Parametre özelliği veya değeri
Hücre mimarisi	-Dizi giriş katmanı (sequence input layer) -Çift yönlü UKSB katmanı (bidirectional LSTM layer (BILLSTM)) -Tam bağlantılı katman (fully connected layer) -Regresyon katmanı (regression layer)
Öğrenme algoritmaları	SGDM, RMSProp, Adam
Aktivasyon fonksiyonları	Tanjant ve sigmoid
Karesel gradyan kaybolma faktörü	1
Maksimum döngü sayısı	200
Nöron sayısı	5-20
İlk öğrenme oranı	0.05
Öğrenme oranı azaltma faktörü	0.2
Öğrenme oranı azaltma döngüsü	50
Girdi sayısı	4 adet (t, t-1, t-2, t-3)
Çıktı sayısı	1 adet (t+1)

UKSB tahmin modelleri, MATLAB 2021b yazılımında geliştirilen açık kodlar kullanılarak tamamlanmıştır. UKSB tahmin modelinde Sakarya istasyonu SYİ-1 için örnek bir öğrenme süreci Şekil 2.32’de verilmiştir.



Şekil 2.32. UKSB tahmin modeli örnek öğrenme süreci

3. BÖLÜM

BULGULAR

3.1. Sakarya Havzası Meteoroloji İstasyonları Yağış Verilerinin İstatistiksel Özellikleri

Bu tez çalışmasında; Sakarya havzası sınırları içerisinde yer alan 10 adet meteoroloji istasyonunun yağış verileri kullanılmıştır. Çalışmada; havzanın kısa dönem meteorolojik kuraklığı ve buna bağlı olarak sadece yağış verisinden hesaplanabilen bir kuraklık indisi olan Standartlaştırılmış Yağış İndeksi (SYİ) değerlendirildiğinden diğer iklimsel ve meteorolojik parametrelere ihtiyaç duyulmamıştır. Materyal bölümünde temel özelliklerinden bahsedildiğinden dolayı tekrar bu istasyonlardan bahsedilmeyecektir. Seçilen bu 10 adet istasyonun tercih edilme sebebi havzanın bütününe temsil kabiliyeti, uzun dönem gözlemlerinin olması, güncel olması ve eksik verinin bulunmamasıdır. İstasyonların dikkate alınan gözlem aralığı içerisinde eksik veri bulunmamasından dolayı veri tamamlama işlemlerine gerek duyulmamıştır. Çalışmada kullanılan bu 10 adet MGİ'e ait istatistiksel bilgiler Tablo 3.1'de verilmiştir.

Tablo 3.1. Meteoroloji gözlem istasyonları (MGİ) istatistiksel bilgileri

İstasyon Adı	Min. Ort. Yağış (mm/ay)	Mak. Ort. Yağış (mm/ay)	Ort. Yağış (μ) (mm/ay)	Standart Sapma (σ) (mm/ay)	Çarpıklık Katsayısı (C_s)	Basıklık Katsayısı (K)	Değişim Katsayısı (C_v) (%)
Sakarya	49.86	108.87	71.16	18.70	0.58	-0.23	26.28
Ankara	13.37	52.39	34.48	13.07	-0.57	-0.90	37.89
Kütahya	18.40	82.38	47.61	20.04	-0.08	-0.55	42.09
Bolu	23.24	63.27	47.35	13.12	-0.83	-0.57	27.71
Emirdağ	16.62	49.33	34.57	11.77	-0.57	-0.90	34.02
Polatlı	10.09	45.08	30.37	12.18	-0.53	-0.90	40.12
Geyve	27.39	96.10	53.86	20.58	0.56	0.06	38.21
Ilgın	10.78	51.46	35.74	14.00	-0.93	-0.50	39.17
Sivrihisar	13.80	52.27	34.58	13.02	-0.48	-0.82	37.65
Yunak	12.49	59.24	38.05	15.36	-0.67	-0.65	40.37

Tablo 3.1'den görüleceği üzere minimum, maksimum ve ortalama yağış değerlerine bağlı olarak yağış potansiyeli en yüksek istasyon Sakarya MGİ'dir. 71,16 mm olan aylık yağış ortalaması ile diğer istasyonlara göre daha fazla yağış almaktadır. Ayrıca %26,28'lik değişim katsayısı değerine bakıldığında aylar arasındaki yağış değerlerinin diğer istasyonlara göre daha az değişiklik gösterdiği yani daha homojen bir yağış rejimine sahip olduğu görülmektedir. İstatistiksel olarak yağış potansiyeli en düşük olan istasyon ise Polatlı MGİ'dir. Minimum, maksimum ve ortalama yağış değerlerinin tamamında seçilen bu 10 adet istasyon içerisinde en düşük değerler Polatlı MGİ'e aittir. Polatlı MGİ'nin standart sapması her ne kadar diğerlerinden küçük de olsa özellikle basıklık (-0,90) ve değişim katsayıları (%40,12) incelendiğinde aylar arasındaki değişimlerin yüksek olduğu ve normal dağılımdan uzaklaştığı görülmektedir. Kütahya MGİ'nin minimum ve maksimum aylık yağış değerleri arasındaki fark oldukça yüksek olup standart sapma (20,04 mm/ay) ve değişim katsayısı değerine (%42,09) bakıldığında ortalamadan uzaklaşan ve düzensiz bir yağış rejimine sahip bir istasyon olduğu rahatlıkla söylenebilir. Minimum ve maksimum yağış değerleri arasındaki fark ile standart sapması (20,58 mm/ay) en yüksek olan istasyon Geyve MGİ'dir. Geyve MGİ'nin değişim katsayısı değeri (%38,21) de yüksek olup bu istasyonun da aylık ölçekte düzensiz bir yağış rejimine sahip olduğu görülmektedir.

3.2. Sakarya Havzası Meteoroloji İstasyonları Yağış Verilerinde Homojenlik, Durağanlık ve Bağımsızlık Testleri

Hidrometeorolojik zaman serileri üzerinden çeşitli analizler ya da modellemeler yapılmadan önce çalışmanın doğruluğu, tutarlılığı ve güvenilirliği açısından çok önemli olan serideki homojenlik, durağanlık ve bağımsızlık durumları istatistiksel testlerle incelenmeli ve değerlendirmeleri yapılmalıdır. Bu kapsamda, çalışmada ele alınan Sakarya havzasındaki 10 adet istasyonun kuraklık tahminlerinin güvenilir bir şekilde tamamlanabilmesi için bu istasyonlara ait ham yağış verilerine homojenlik, durağanlık ve bağımsızlık testleri uygulanmıştır. Testlerle ilgili analizler MATLAB 2021b yazılımında tamamlanmıştır. İstasyonlara ait ham yağış verileri, %95 güven aralığında kalacak şekilde Standart Normal Homojenlik Testi (SNHT), Genişletilmiş Dickey-Fuller Testi (GDFT), Von-Neumann Homojenlik Testi (VNT) ve Mann-Whitney u Testine (MWT) tabi tutulmuş olup test sonuçları Tablo 3.2'de verilmiştir.

Tablo 3.2. İstasyonlara ait homojenlik, durağanlık ve bağımsızlık test sonuçları

İstasyon Adı	Standart Normal Homojenlik Testi (SNHT)			Genişletilmiş Dickey-Fuller Testi (GDFT)			Von-Neumann Homojenlik Testi (VNT)			Mann-Whitney u Testi (MWT)		
	T ₀	T _{test}	Karar	Test ist.	c değ.	Karar	Q	P	Karar	q	P1/2	Karar
Sakarya	6.08	10.50	H	-10.66	-1.94	D	1.80	0.997	B	0.16	0.025	H
Ankara	3.29	10.50	H	-11.66	-1.94	D	1.71	1	B	0.49	0.025	H
Kütahya	4.21	10.50	H	-11.21	-1.94	D	1.54	1	B	0.30	0.025	H
Bolu	4.28	10.45	H	-10.37	-1.94	D	1.89	0.928	B	0.18	0.025	H
Emirdağ	4.65	10.45	H	-10.23	-1.94	D	1.81	0.988	B	0.41	0.025	H
Polatlı	3.54	10.45	H	-9.73	-1.94	D	1.57	1	B	0.41	0.025	H
Sivrihisar	4.63	10.45	H	-9.89	-1.94	D	1.57	1	B	0.21	0.025	H
Geyve	3.14	10.45	H	-10.19	-1.94	D	1.67	1	B	0.09	0.025	H
Ilgın	3.10	10.45	H	-9.86	-1.94	D	1.69	1	B	0.13	0.025	H
Yunak	4.20	10.20	H	-8.94	-1.94	D	1.59	1	B	0.33	0.025	H

Tablo 3.2’de verilen testlere ait sonuç tablosunda yer alan H: homojen, D: durağan ve B: bağımsız durumu temsil etmektedir. İstasyonların ham yağış verilerine uygulanan bu dört teste ait istatistiksel sonuçlara göre, istasyon verilerinin tamamı homojen, durağan ve bağımsız çıkmıştır. Bu sonuçlara göre istasyonlara ait yağış verileri ele alınacak olan kuraklık tahmin modelleri için tutarlı ve kullanışlıdır. Ayrıca yağış verilerinde şüpheli bir durum söz konusu olmadığından dolayı bu çalışmada istasyonlara ait yağış verilerinin homojen hale getirilmesine gerek yoktur.

3.3. DrinC Yazılımı ile SYİ Kuraklık Değerlerinin Hesaplanması

Bu çalışmada; kuraklık tahmin modellerinde eğitime ve test verisi şeklinde giriş verisi olarak kullanılacak olan SYİ kuraklık değerleri, istasyonların aylık yağış verilerine bağlı olarak hesaplanmıştır. Çalışmada, Sakarya havzasının kısa dönem meteorolojik kuraklığı tahmin edilmek istendiğinden dolayı burada 1, 3, 6 ve 12 aylık kısa dönemler dikkate alınmış olup tüm istasyonlar için dört farklı zaman ölçeğinde SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık değerleri hesaplanmıştır. Kuraklık indislerinin hesabı manuel olarak yapılabildiği gibi özellikle son dönemde çeşitli kuraklık indisi hesaplama yazılımları ile de yapılabilmektedir. Bu çalışmada; istasyon sayısının fazla olması, uzun dönem yağış verilerinin kullanılması ve dört farklı zaman ölçeğinin dikkate alınmasından dolayı kuraklık indisi hesaplama adımında çok fazla işlem yükü ve

zamana gereksinim duyulması sebebi ile bir kuraklık indisi hesaplama yöntemi olan DrinC (Kuraklık İndisleri Hesaplayıcısı (Drought Indices Calculator)) yazılımı kullanılmıştır. SYİ kuraklık değerlerinin hesaplanma sürecinde oldukça kolaylık sağlayan bu yazılım sayesinde istenilen parametrelere ve seçilen zaman ölçeklerine göre (SYİ-1, SYİ-3, SYİ-6 ve SYİ-12) her istasyon için kuraklık değerleri hesaplanmıştır. Ayrıca DrinC yazılımı ile elde edilen bazı değerler için manuel olarak hesaplama yapılmış ve yazılımın hesap doğruluğu teyit edilmiştir.


3.3.1. SYİ Kuraklık Değerlendirmesi

Sakarya havzasındaki istasyonların gözlenen aylık yağış verilerine göre hesaplanan geçmiş dönem SYİ kuraklık değerlerinin kabul gören SYİ kuraklık sınıflandırmasına göre değerlendirmeleri yapılmıştır. Kuraklık ile ilgili değerlendirmeler, SYİ-1 ve SYİ-12 zaman ölçekleri için kuraklık izleme tabloları, kuraklık zaman serisi grafikleri ile aylara ve yıllara göre kuraklık sınıfları oluşum yüzde grafikleri üzerinden yapılmıştır. SYİ-3 ve SYİ-6 zaman ölçeklerine ait kuraklık değerlendirmeleri, hem tez içerisinde fazla yer tutmaması için hem de bu zaman ölçeklerinde kuraklık sınıflarının birbirine benzer ve öngörülebilir olmasından dolayı yapılmamıştır. Örnek olarak Sakarya SYİ-1 için Tablo 3.3'te kuraklık değerleri izleme tablosu, Şekil 3.1'de kuraklık zaman serisi grafiği ve Şekil 3.2'de aylara göre kuraklık sınıfları oluşumu yüzde grafiği verilmiştir. Diğer istasyonlara ait SYİ-1 kuraklık izleme tabloları ise ekte verilmiştir.


Tablo 3.3. Sakarya SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	0.99	0.27	0.30	-0.52	0.36	0.45	0.28	0.45	-0.09	-2.14	-1.39	-0.34
1961 - 1962	0.52	0.26	0.28	-0.41	0.60	0.36	1.36	-1.31	0.83	-0.28	-0.35	-0.99
1962 - 1963	-0.99	1.15	0.46	0.42	-0.88	-1.59	0.81	-1.51	0.21	0.87	-0.13	1.81
1963 - 1964	1.81	-1.14	1.69	-0.12	-0.13	-1.01	0.43	-1.18	1.01	-0.01	-0.87	1.63
1964 - 1965	-1.16	0.75	0.29	-0.59	0.16	0.19	-0.52	0.83	1.21	-2.10	1.25	0.95
1965 - 1966	-2.02	1.09	0.13	1.19	0.20	-0.83	1.03	-0.47	-2.10	-0.42	0.61	0.06
1966 - 1967	0.42	-2.13	1.30	-0.18	-1.05	-0.31	-0.51	0.51	-0.96	-0.55	-2.33	0.08
1967 - 1968	0.25	0.34	0.54	0.36	0.45	-0.22	-1.24	-0.83	0.69	-0.30	1.39	-0.12
1968 - 1969	1.14	-0.70	0.67	0.23	-0.91	-1.44	-3.20	1.38	1.80	0.61	0.38	-0.29
1969 - 1970	0.32	-0.12	-0.19	1.69	-0.32	0.98	0.46	-1.51	-1.90	-1.76	-0.13	-0.41
1970 - 1971	0.16	1.73	0.57	0.56	-0.56	-0.19	-1.22	-0.14	1.00	0.72	0.33	0.69
1971 - 1972	-1.35	-0.43	1.17	-0.07	0.17	-0.13	-0.10	-0.15	0.69	0.05	0.36	1.28
1972 - 1973	-0.76	-0.57	-1.61	-0.17	-0.59	2.83	1.48	1.55	0.96	0.34	-0.34	-2.09
1973 - 1974	-1.64	-1.02	-0.07	-0.34	-1.48	0.17	-0.57	0.49	-0.39	0.83	1.10	-0.30
1974 - 1975	-0.57	-0.89	-0.22	-0.53	0.61	-0.30	-1.27	1.78	-0.21	-1.55	-0.28	0.46
1975 - 1976	0.56	1.16	0.13	-0.67	1.12	0.02	-0.30	1.02	-0.01	0.59	0.48	0.54
1976 - 1977	-0.48	-0.13	-1.92	-0.23	-0.67	0.64	0.85	0.47	0.41	0.23	0.47	-0.54
1977 - 1978	-0.49	-2.02	0.76	0.55	-0.77	0.53	0.02	-0.63	0.29	-0.79	-0.24	0.97
1978 - 1979	1.11	-0.05	-0.35	1.42	-0.55	-1.38	-1.48	0.73	0.56	0.85	-2.39	0.03
1979 - 1980	0.75	-0.03	-1.46	0.21	0.51	-0.25	0.77	0.83	0.38	-0.14	0.67	0.47
1980 - 1981	0.79	-0.60	0.90	-0.80	0.22	-0.76	-0.38	0.04	0.23	-0.59	1.42	0.63
1981 - 1982	1.10	1.18	0.56	-1.30	0.53	-0.99	1.85	-0.62	0.30	-0.14	-0.63	1.18
1982 - 1983	0.46	0.02	0.08	1.29	0.01	-1.14	0.35	0.61	-0.92	-0.94	-0.43	-0.27
1983 - 1984	0.24	0.63	-1.69	0.25	-0.13	0.45	0.16	0.92	0.18	1.23	1.27	-1.24
1984 - 1985	-0.66	0.48	0.13	1.69	-0.90	0.36	1.39	0.73	-2.02	-0.47	0.25	-1.95
1985 - 1986	-0.17	0.48	-1.31	-1.13	1.00	-1.32	-0.59	-0.93	0.06	0.91	-0.03	-0.46
1986 - 1987	0.45	0.67	-2.91	-1.39	-0.66	0.94	0.60	-1.33	-0.45	0.58	0.92	-0.44
1987 - 1988	1.54	-1.02	1.84	0.14	-0.24	-0.90	0.08	0.65	-1.90	1.03	0.50	0.99
1988 - 1989	-1.66	-0.14	0.23	-0.13	1.28	0.21	0.67	-1.20	-0.47	0.61	1.06	-0.51
1989 - 1990	-1.50	-1.50	-2.82	-3.60	0.26	0.45	0.20	-0.40	-0.12	1.29	1.24	-0.39
1990 - 1991	-0.46	-0.21	-0.01	0.80	-0.25	-0.12	-0.55	-0.62	1.22	0.16	0.07	-0.94
1991 - 1992	-0.97	0.81	-1.04	1.45	1.60	0.53	-0.27	-0.46	1.13	-0.09	-0.22	0.92
1992 - 1993	-0.91	0.36	1.22	-0.07	-1.01	0.65	1.12	-1.43	-0.25	0.74	-0.10	0.55
1993 - 1994	-0.41	-0.64	-1.54	-0.55	1.00	-0.25	-1.00	0.31	-0.11	-1.88	1.24	-0.62
1994 - 1995	0.32	-0.26	-0.83	-0.61	-0.72	0.91	-0.42	0.31	-2.14	1.48	1.60	0.63
1995 - 1996	0.43	-1.80	0.98	0.87	-2.98	1.03	0.34	-0.15	0.04	0.89	0.31	-1.43
1996 - 1997	0.20	0.16	1.20	0.29	0.95	-0.94	-0.82	0.71	0.70	0.25	-1.67	0.09
1997 - 1998	-0.93	0.23	0.25	1.95	-1.29	-0.27	1.39	2.06	-0.46	2.02	-1.24	0.85
1998 - 1999	0.18	-0.23	0.98	-0.34	2.13	0.29	0.48	-1.51	-0.06	0.05	0.06	0.38
1999 - 2000	-1.32	0.68	-0.30	-0.24	-0.68	2.00	0.68	1.29	-1.46	-0.14	0.13	-0.56
2000 - 2001	1.44	0.05	0.88	1.07	-0.46	0.29	-0.07	1.10	1.24	1.13	-1.38	-1.13
2001 - 2002	-2.28	0.44	-0.67	0.86	0.14	-0.71	0.62	-0.02	-0.93	-1.33	1.34	2.32
2002 - 2003	0.18	-1.50	-0.87	0.56	-0.59	0.28	1.42	1.40	1.02	-0.02	-0.63	-0.96

2003 - 2004	-0.25	1.65	-0.22	0.58	-2.13	-3.92	-0.83	-1.01	0.41	0.65	0.35	0.72
2004 - 2005	1.93	0.38	0.04	-0.13	-0.13	0.96	-0.56	1.37	-1.10	-1.49	1.45	-1.11
2005 - 2006	1.06	0.35	0.50	-0.06	-0.67	0.00	1.87	-0.50	0.61	0.40	1.71	-0.54
2006 - 2007	-0.24	0.68	-0.04	-2.98	-1.49	0.66	-2.95	-0.98	1.00	-0.49	-0.13	-0.59
2007 - 2008	0.31	-1.94	-0.39	-0.06	0.25	-0.72	-0.22	0.60	-0.69	-0.34	0.42	0.39
2008 - 2009	-0.47	0.00	0.63	-1.46	1.16	-0.85	-0.85	-0.88	1.19	-1.06	0.18	-0.02
2009 - 2010	0.28	2.18	0.79	0.08	-1.09	-0.50	0.69	-0.78	1.10	0.06	0.57	0.31
2010 - 2011	0.82	1.15	0.60	1.07	0.96	-0.01	-0.75	-0.94	0.66	1.91	-1.82	0.58
2011 - 2012	0.43	-1.48	0.76	0.41	-1.07	-0.36	0.08	-0.66	-0.68	0.08	-1.86	-0.40
2012 - 2013	0.72	0.94	0.39	0.11	1.64	-0.60	-1.16	0.21	-1.27	-1.40	0.34	0.65
2013 - 2014	0.06	-0.15	0.59	-0.88	-0.03	-0.02	-0.83	0.04	0.27	1.24	-1.04	-0.91
2014 - 2015	-2.34	-1.11	0.64	-1.02	1.54	0.91	0.61	0.74	1.77	-0.03	0.43	0.51
2015 - 2016	1.82	1.88	-0.72	1.43	0.52	2.37	0.05	0.14	1.09	1.48	-1.57	-1.76
2016 - 2017	1.33	1.31	0.54	0.03	1.29	0.61	-0.22	0.69	0.19	-0.69	0.32	1.72
2017 - 2018	-0.05	-1.79	-0.92	0.58	0.61	0.86	0.31	0.66	-0.03	0.49	-0.75	0.36
2018 - 2019	-0.60	-0.45	1.09	-1.26	2.08	0.00	1.07	-0.50	0.43	-0.25	0.33	1.42
2019 - 2020	0.22	0.23	-1.14	0.62	0.07	0.64	1.29	1.44	-0.65	-1.01	-1.30	0.19
2020 - 2021	0.45	0.48	-0.51	-0.23	1.14	1.14	-0.98	-1.51	-0.84	-0.06	-1.04	-2.14



Şekil 3.1. Sakarya SYİ-1 kuraklık zaman serisi grafiği




Şekil 3.2. Sakarya SYİ-1 aylara göre kuraklık sınıfları oluşumu yüzde grafiği

Tablo 3.3'te verilen Sakarya SYİ-1 kuraklık değerleri izleme tablosunda, SYİ'nin kabul edilen kuraklık sınıflandırması dikkate alınarak farklı renkler aracılığı ile SYİ-1 kuraklık değerleri sınıflarına ayrılmıştır. Tablo 3.3 incelendiğinde; toplam 732 ay bulunan SYİ-1 veri setinde 507 ay normale yakın sınıfında, 79 ay orta şiddette nemli, 61 ay orta şiddette kurak, 28 ay çok nemli, 26 ay şiddetli kurak, 23 ay aşırı kurak ve son olarak da sadece 8 ay aşırı nemli olarak belirlenmiştir. 1969 yılının ağustos, eylül ve ekim aylarında 3 aylık bir dönemde şiddetli kuraklıklar görülmüştür. 1989 yılının ilk dört aylık döneminde de şiddetli ve aşırı kurak bir dönem görülmüştür. 2003 yılının mayıs ve haziran aylarında ardı ardına aşırı kuraklık görülmüştür. Yine 2015 yılının son iki ayını kapsayan dönemi de şiddetli kurak bir şekilde geçmiştir. Tüm bunların yanı sıra 1972 yılı haziran, temmuz ve ağustos aylarının arka arkaya aşırı nemli, orta şiddette nemli ve çok nemli bir dönem olduğu görülmektedir. 2002 yılı temmuz, ağustos ve eylül aylarında da çok nemli bir dönem görülmüştür.


Tablo 3.3 ile Şekil 3.1'de verilen SYİ-1 kuraklık zaman serisi grafiği birlikte incelendiğinde; 1968 yılı temmuz ayında -3,20, 1989 yılı mayıs ayında -3,60, 2003 yılı haziran ayında -3,92 olarak hesaplanan SYİ-1 değerlerinden dolayı, bu veri setindeki en şiddetli kuraklıklar bu dönemlerde görülmüştür. 1972 yılı haziran ayında 2,83, 2001 yılı aralık ayında 2,32 ve 2015 yılı haziran ayında 2,37 olarak hesaplanan SYİ-1 değerlerinden dolayı da bu dönemler veri setindeki en nemli dönemler olarak belirlenmiştir.

Şekil 3.2'den görüleceği üzere Sakarya SYİ-1 kuraklık değerleri, büyük bir oranda normale yakın sınıfında yer almaktadır. Tüm veri seti içinde aylara göre normale yakın sınıfının oluşum yüzdesi %75,41 olarak bulunmuştur. %6,56 oranında orta şiddette kuraklık, %4,92 oranlarında orta şiddette nemli ve çok nemli kuraklık, %3,28 oranlarında şiddetli kurak ve aşırı kurak ve son olarak da %1,64 oranında aşırı nemli kuraklık sınıflarının oluştuğu belirlenmiştir.


Sakarya SYİ-1 zaman ölçeğinde olduğu gibi SYİ-12 zaman ölçeğinde de kuraklık değerlendirmeleri yapılmıştır. Sakarya SYİ-12 için Şekil 3.3'te kuraklık zaman serisi grafiği, Şekil 3.4'te yıllık kuraklık değerleri ve kuraklık sınıfları grafiği ve Şekil 3.5'te yıllara göre kuraklık sınıfları oluşumu yüzde grafiği verilmiştir.



Şekil 3.3. Sakarya SYİ-12 kuraklık zaman serisi grafiği



Şekil 3.4. Sakarya SYİ-12 kuraklık değerleri ve kuraklık sınıfları grafiği



Şekil 3.5. Sakarya SYİ-12 yıllara göre kuraklık sınıfları oluşumu yüzde grafiği

Şekil 3.3, 3.4 ve 3.5'te görüldüğü üzere; Sakarya istasyonu SYİ-12 zaman ölçeğinde bulunan toplam 61 yılın 43 yılı normale yakın, 7 yılı orta şiddette kuraklık, 4 yılı orta şiddette nemli, 3 yılı şiddetli kuraklık, 2 yılı aşırı nemli ve 2 yılı da çok nemli olarak belirlenmiştir. SYİ-12 zaman ölçeğinin yıllara göre kuraklık sınıfları oluşum yüzdelere bakıldığında ise %70,49 değeri ile normale yakın SYİ sınıfının, bu istasyonda hâkim kuraklık sınıfı olduğu görülmüştür. Bu sınıfı %11,48 ile orta şiddette kuraklık takip etmektedir. Bu zaman ölçeğinde aşırı kurak bir yıl görülmemiş olup 1966, 1993 ve 2011 yıllarında şiddetli kuraklık görülmüştür. 1997 ve 2015 yılları ise aşırı nemli geçmiştir. 2015 yılından itibaren Sakarya istasyonunun SYİ-12 zaman ölçeğinde kuraklıkların sürekli artma eğiliminde olduğu tespit edilmiştir.

Sakarya istasyonu için örnek olarak verilen SYİ-1 ve SYİ-12 zaman ölçeklerinde yapılan kuraklık değerlendirmeleri tüm istasyonlar için yapılmış olup Tablo 3.4'te ve Tablo 3.5'te sırasıyla SYİ-1 ve SYİ-12 zaman ölçeklerinde istasyonlardaki kuraklık sınıflarına göre oluşum sayıları ve oluşum yüzdeleri verilmiştir.

Tablo 3.4. İstasyonların aylara göre SYİ-1 kuraklık sınıfları oluşum sayıları ve yüzdeleri

İstasyon adı	Veri sayısı (ay)	Aylara göre SYİ-1 kuraklık sınıfları oluşum sayıları ve yüzdeleri						
		Aşırı nemli	Çok nemli	Orta şiddette nemli	Normale yakın	Orta şiddette kurak	Şiddetli kurak	Aşırı kurak
Sakarya	732	8 (%1.09)	28 (%3.83)	79 (%10.79)	507 (%69.26)	61 (%8.33)	26 (%3.55)	23 (%3.14)
Ankara	732	8 (%1.09)	36 (%4.92)	69 (%9.43)	503 (%68.72)	65 (%8.88)	34 (%4.64)	17 (%2.32)
Kütahya	732	14 (%1.91)	30 (%4.10)	71 (%9.70)	504 (%68.85)	65 (%8.88)	32 (%4.37)	16 (%2.19)
Bolu	672	13 (%1.93)	29 (%4.32)	52 (%7.74)	464 (%69.05)	70 (%10.42)	23 (%3.42)	21 (%3.13)
Emirdağ	576	9 (%1.56)	19 (%3.30)	57 (%9.90)	398 (%69.10)	55 (%9.55)	21 (%3.65)	17 (%2.95)
Polatlı	564	11 (%1.95)	16 (%2.84)	62 (%10.99)	388 (%68.79)	46 (%8.16)	23 (%4.08)	18 (%3.19)
Sivrihisar	624	6 (%0.96)	33 (%5.29)	53 (%8.49)	432 (%69.23)	58 (%9.29)	23 (%3.69)	19 (%3.04)
Geyve	624	13 (%2.08)	21 (%3.37)	57 (%9.13)	440 (%70.51)	43 (%6.89)	28 (%4.49)	22 (%3.53)
Ilgın	528	4 (%0.76)	30 (%5.68)	50 (%9.47)	360 (%68.18)	54 (%10.23)	19 (%3.60)	11 (%2.08)
Yunak	492	7 (%1.42)	15 (%3.05)	52 (%10.57)	339 (%68.90)	49 (%9.96)	23 (%4.67)	7 (%1.42)

Tablo 3.4'ten görüleceği üzere, havzada yer alan 10 adet istasyonun tamamında SYİ-1 zaman ölçeğine göre %68,18 ile %70,51 arasında değişen yüzdelerde normale yakın SYİ sınıfı görülmektedir. Bu nedenle SYİ-1 zaman ölçeğinde görülen normale yakın sınıfın havzanın hâkim kuraklık sınıfı olduğu sonucuna ulaşılmıştır. Geyve istasyonu bu zaman ölçeğinde hem aşırı nemli hem de aşırı kurak sınıflarında en yüksek SYİ değerlerinin görüldüğü istasyon olmuştur. Meteorolojik kuraklığın hissedildiği orta şiddette kurak, şiddetli kurak ve aşırı kurak sınıflarında en yüksek yüzdeye (%16,97) sahip olan istasyon ise Bolu istasyonudur. Bu üç kuraklık sınıfında diğer istasyonlar yaklaşık %15'lik oranlara sahiptir. Orta şiddette nemli, çok nemli ve aşırı nemli sınıflarında en yüksek yüzdeye (%15,91) sahip olan istasyon Ilgın istasyonu olup diğer istasyonlar ise yaklaşık %14-15 aralığında değişmektedir. Tablo 3.4'te verilen SYİ-1 kuraklık sayıları ve oluşum yüzdeleri incelendiğinde, kuraklık sınıflarına göre istasyonlar arasında benzer sayıların ve yüzdelerin olduğu görülmekte olup havzadaki kuraklık durumunun homojen bir dağılımda olduğu söylenebilir.

Tablo 3.5. İstasyonların yıllara göre SYİ-12 kuraklık sınıfları oluşum sayıları ve yüzdeleri


İstasyon adı	Veri sayısı (yıl)	Yıllara göre SYİ-12 kuraklık sınıfları oluşum sayıları ve yüzdeleri						
		Aşırı nemli	Çok nemli	Orta şiddette nemli	Normale yakın	Orta şiddette kurak	Şiddetli kurak	Aşırı kurak
Sakarya	61	2 (%3.28)	2 (%3.28)	4 (%6.56)	43 (%70.49)	7 (%11.48)	3 (%4.92)	0
Ankara	61	2 (%3.28)	2 (%3.28)	6 (%9.84)	40 (%65.57)	8 (%13.11)	1 (%1.64)	2 (%3.28)
Kütahya	61	0	1 (%1.64)	14 (%22.95)	35 (%57.38)	6 (%9.84)	3 (%4.92)	2 (%3.28)
Bolu	56	0	6 (%10.71)	3 (%5.36)	38 (%67.86)	5 (%8.93)	2 (%3.57)	2 (%3.57)
Emirdağ	48	1 (%2.08)	2 (%4.17)	4 (%8.33)	33 (%68.75)	3 (%6.25)	5 (%10.42)	0
Polatlı	47	1 (%2.13)	1 (%2.13)	5 (%10.64)	32 (%68.09)	3 (%6.38)	5 (%10.64)	0
Sivrihisar	52	1 (%1.92)	3 (%5.77)	5 (%9.62)	35 (%67.31)	5 (%9.62)	2 (%3.85)	1 (%1.92)
Geyve	52	1 (%1.92)	2 (%3.85)	6 (%11.54)	32 (%61.54)	8 (%15.38)	2 (%3.85)	1 (%1.92)
Ilgın	44	0	2 (%4.55)	6 (%13.64)	30 (%68.18)	3 (%6.82)	0	3 (%6.82)
Yunak	41	2 (%4.88)	0	5 (%12.20)	27 (%65.85)	3 (%7.32)	4 (%9.76)	0

Tablo 3.5'ten görüleceği üzere, SYİ-12 zaman ölçeğinde yıllara göre %57,38 ile %70,49 arasında değişen yüzdelerde normale yakın sınıfı görülmektedir. Yine bu zaman ölçeğinde de hâkim SYİ kuraklık sınıfının, normale yakın olduğu belirlenmiştir. Sakarya, Emirdağ, Polatlı ve Yunak istasyonlarında aşırı kuraklık hiç görülmemiştir. Kütahya, Bolu ve Ilgın istasyonlarında ise aşırı nemli bir yıl görülmemiştir. Ayrıca Yunak istasyonunda çok nemli ve Ilgın istasyonunda ise şiddetli kuraklık hiç görülmemiştir. Orta şiddette kurak, şiddetli kurak ve aşırı kurak sınıflarının tamamı için %21,15 ile en yüksek değer Geyve istasyonuna aittir. Orta şiddette nemli, çok nemli ve aşırı nemli sınıflarında ise en yüksek değer (%24,59), Kütahya istasyonuna aittir. Tablo 3.5'te verilen SYİ-12 kuraklık sayıları ve oluşum yüzdeleri ile aylara göre belirlenen SYİ-1 kuraklık değerlerinin birbiri ile tutarlı olduğu görülmüştür.


3.4. Otokorelasyon Varlığının Araştırılması

Tek değişkenli zaman serilerine dayalı tahmin modellerinin tahmin başarısını önemli ölçüde etkileyen otokorelasyon varlığı, bir serinin kendinden önceki veya sonraki gecikmeli değerlerine ait hata terimleri arasındaki seri bağımlılığını gösteren istatistiksel bir kavramdır. Mevcut zaman serisi ile gecikmeli zaman serisi arasındaki korelasyonun istenmeyen bir durum olmasından dolayı bu çalışmada otokorelasyon varlığı araştırılmıştır. Ayrıca zaman serilerine dayalı tahmin modellerinin başarısı, gecikme zamanları ile optimum sayıda girdi değişkeni arasındaki ilişkiyle de alakalıdır. Bu nedenle tahmin modellerine girecek olan optimum gecikme zamanlarının hangi güvenilir aralıkta kaldığı da bu aşamada belirlenmiştir.


Bu çalışmada; SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık değerlerinin farklı gecikme zamanları (t , $t-1$, $t-2$, $t-3$, ...vb.) tahmin modellerinde girdi değişkeni, $t+1$ zamanı ise çıktı değeri olarak kabul edilmiştir. İstasyonların aylık yağış verilerinden elde edilen SYİ kuraklık zaman serileri, MATLAB 2021b yazılımında geliştirilen otokorelasyon fonksiyonuna ait açık kodlar yardımıyla analiz edilmiştir. Her bir istasyon ve her bir zaman ölçeği için ele alınan kuraklık zaman serileri, %95 güven aralığında ve en fazla 10 gecikmeye kadar otokorelasyon fonksiyonuna tabi tutularak sonuçlar elde edilmiştir. Örnek olarak Sakarya istasyonu için SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık zaman serilerinden elde edilen otokorelasyon fonksiyonu grafikleri Şekil 3.6–3.9 arasında verilmiştir.




Şekil 3.6. Sakarya istasyonu SYİ-1 otokorelasyon fonksiyonu grafiği



Şekil 3.7. Sakarya istasyonu SYİ-3 otokorelasyon fonksiyonu grafiği



Şekil 3.8. Sakarya istasyonu SYİ-6 otokorelasyon fonksiyonu grafiği



Şekil 3.9. Sakarya istasyonu SYİ-12 otokorelasyon fonksiyonu grafiği

Şekil 3.6–3.9 arasındaki grafiklerde sonuçları verilen otokorelasyon fonksiyonları, Gauss dağılımını temel almakta olup tüm zaman ölçeklerinde 0 gecikmesindeki (aslında serinin kendisi) otokorelasyon katsayısı değeri doğal olarak 1'i göstermektedir. Grafiklerde yer alan bazı gecikme zamanlarında (Şekil 3.8'de) otokorelasyon katsayısı değerinin 0 olduğu görülmekte olup bunun anlamı gecikme zamanındaki serinin

bağımsız olduğudur. Şekil 3.6–3.9 arasında verilen grafiklerden elde edilen sonuçlara göre; tüm zaman ölçeklerinde dikkate alınan en fazla gecikme zamanı olan 10 gecikmeye kadar gecikme zaman serileri arasında otokorelasyon varlığı söz konusu değildir. Her bir zaman ölçeği için tüm gecikme zamanları %95 güven aralığındaki otokorelasyon katsayısının alt ve üst sınırları içerisinde kalmıştır. Otokorelasyon katsayılarının alt ve üst sınırları; SYİ-1 için $\pm 0,0742$, SYİ-3 için $\pm 0,1292$, SYİ-6 için $\pm 0,1858$ ve SYİ-12 için $\pm 0,2658$ olarak bulunmuştur. Şekil 3.6’da görüldüğü üzere, Sakarya SYİ-1 otokorelasyon fonksiyonu grafiğinde 6 ve 9 gecikme zamanlarında alt ve üst sınırlara yaklaşılmış ancak aşılmamıştır. Şekil 3.8’de Sakarya SYİ-6 otokorelasyon fonksiyonu grafiğinde 2 gecikme zamanında otokorelasyon katsayısı değeri 0 olup bu gecikme zamanı için serinin bağımsız olduğu sonucuna ulaşılmıştır. Ayrıca yine bu zaman ölçeğinde 4 gecikme zamanında alt güven sınırına yaklaşılmış ancak aşılmamıştır.

Şekil 3.6–3.9 arasında verilen otokorelasyon fonksiyonu grafiklerine göre tüm zaman ölçeklerinde 10 gecikme zamanına kadar olan gecikmelerin, tahmin modellerinde girdi değişkenleri olarak kullanılabileceği sonucuna ulaşılmıştır.

3.5. Ayrık Dalgacık Dönüşümü Sonuçları

Her bir zaman ölçeği için optimum gecikme zamanlarının belirlenmesi, en uygun dalgacık ailesi ile en uygun dalgacık bant seviyesinin seçilmesi amacıyla SYİ kuraklık zaman serilerine Ayrık Dalgacık Dönüşümü (ADD) uygulanmıştır. Havzadaki 10 istasyonu temsilen sadece Sakarya istasyonunun SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık zaman serileri ADD ile alt bantlarına ayrılarak ADD-USBÇS hibrit modelinde eğitime ve teste tabi tutulmuştur. t orijinal kuraklık serisi olmak üzere t , $t-1$, $t-2$, $t-3$, $t-4$ ve $t-5$ olarak 5 farklı gecikme zamanı, 8 farklı dalgacık ailesi ve 3, 4, 5, 6 ve 7 olmak üzere 5 farklı bant seviyesine göre analizler tamamlanarak sonuçlar elde edilmiştir. Ancak yapılan ADD analizlerinde çok fazla model kombinasyonu denendiğinden dolayı öncelikle her bir zaman ölçeğinde belirlenen optimum gecikme zamanına göre (3 gecikme zamanı) en iyi sonucu veren dalgacık ailesi ile dalgacık bant seviyelerine ait ADD-USBÇS hibrit model sonuçlarına yer verilmiştir. Daha sonra ise optimum gecikme zamanı ile ilgili tablolar verilecektir. Sakarya istasyonunun 3 gecikme zamanı için (t , $t-1$, $t-2$, $t-3$ girdi değişkeni) ele alınan SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 zaman

ölçeklerindeki dalgacık ailesi ve dalgacık bant seviyesi model sonuçları sırasıyla Tablo 3.6, 3.7, 3.8 ve 3.9’da verilmiştir.

Tablo 3.6. Sakarya SYİ-1’e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması

Dalgacık ailesi	Dalgacık Bant Seviyesi	<u>EĞİTME</u>		<u>TEST</u>		Sıra
		OMH	R ²	OMH	R ²	
Haar	3	0.7445	0.2987	0.5513	0.5102	8
	4	0.7649	0.3001	0.5540	0.5090	
	5	0.7775	0.3028	0.5531	0.5098	
	6	0.7880	0.2998	0.5574	0.5066	
	7	0.7958	0.3009	0.5558	0.5067	
Symlets (sym3)	3	0.3603	0.7763	0.3958	0.7487	5
	4	0.3600	0.7768	0.3866	0.7600	
	5	0.3599	0.7768	0.3816	0.7663	
	6	0.3598	0.7769	0.3836	0.7640	
	7	0.3598	0.7769	0.3855	0.7614	
Coiflets (coif2)	3	0.3231	0.8202	0.4006	0.7468	4
	4	0.3222	0.8213	0.3807	0.7753	
	5	0.3220	0.8215	0.3753	0.7789	
	6	0.3221	0.8215	0.3767	0.7781	
	7	0.3221	0.8214	0.3734	0.7779	
Biorthogonal (bior1.3)	3	0.4031	0.7082	0.4287	0.6974	7
	4	0.4025	0.7087	0.4282	0.6944	
	5	0.4023	0.7090	0.4313	0.6913	
	6	0.4023	0.7089	0.4308	0.6939	
	7	0.4023	0.7089	0.4334	0.6921	
Reverse biorthogonal (rbio1.3)	3	0.7682	0.3530	0.4267	0.6946	6
	4	0.7925	0.3589	0.4277	0.6934	
	5	0.7905	0.3664	0.4259	0.6954	
	6	0.7908	0.3662	0.4295	0.6914	
	7	0.7872	0.3651	0.4297	0.6913	
Discrete approximation of Meyer (dmey)	3	0.7637	0.5799	0.2976	0.8537	1
	4	0.8007	0.5917	0.2973	0.8534	
	5	0.8291	0.5817	0.2972	0.8533	
	6	0.8474	0.5832	0.2973	0.8533	
	7	0.8575	0.5881	0.2975	0.8531	
Fejer-Korovkin (fk4)	3	0.7363	0.5654	0.3160	0.8368	2
	4	0.7616	0.5789	0.3122	0.8411	
	5	0.7797	0.5761	0.3117	0.8420	
	6	0.7908	0.5786	0.3117	0.8418	
	7	0.7978	0.5744	0.3122	0.8417	
Daubechies (db40)	3	0.7592	0.5715	0.3254	0.8301	3
	4	0.7708	0.5767	0.3240	0.8310	
	5	0.7625	0.5744	0.3240	0.8309	
	6	0.7574	0.5701	0.3237	0.8313	
	7	0.7574	0.5702	0.3241	0.8310	

Tablo 3.7. Sakarya SYİ-3'e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması

Dalgacık ailesi	Dalgacık Bant Seviyesi	EĞİTME		TEST		Sıra
		OMH	R ²	OMH	R ²	
Haar	3	0.7002	0.4458	0.6307	0.2657	8
	4	0.7242	0.4664	0.7169	0.2520	
	5	0.7383	0.4677	0.7460	0.2402	
	6	0.7547	0.4748	0.7393	0.2424	
	7	0.7660	0.4720	0.7309	0.2452	
Symlets (sym3)	3	0.7203	0.5888	0.4546	0.6592	2
	4	0.7514	0.5913	0.5285	0.6041	
	5	0.7682	0.5921	0.4375	0.6090	
	6	0.7818	0.5963	0.4699	0.5781	
	7	0.8606	0.5811	0.4656	0.5828	
Coiflets (coif2)	3	0.6984	0.6280	0.6017	0.4650	6
	4	0.7276	0.6314	0.5963	0.4902	
	5	0.7557	0.6219	0.5996	0.4906	
	6	0.7757	0.6249	0.6700	0.4101	
	7	0.8379	0.6167	0.6838	0.4062	
Biorthogonal (bior1.3)	3	0.7194	0.5628	0.6036	0.4074	7
	4	0.7465	0.5707	0.6057	0.4465	
	5	0.7819	0.5579	0.6105	0.4360	
	6	0.8123	0.5650	0.6066	0.4347	
	7	0.8606	0.5358	0.6231	0.4276	
Reverse biorthogonal (rbio1.3)	3	0.7492	0.5217	0.6060	0.4870	5
	4	0.7920	0.5403	0.6664	0.5092	
	5	0.8192	0.5440	0.7130	0.4667	
	6	0.8524	0.5426	0.6924	0.4926	
	7	0.8815	0.5482	0.6919	0.4934	
Discrete approximation of Meyer (dmey)	3	0.7205	0.6403	0.2974	0.8745	1
	4	0.7642	0.6402	0.3524	0.8268	
	5	0.7897	0.6337	0.3227	0.8514	
	6	0.8553	0.6275	0.4453	0.7803	
	7	0.8108	0.6423	0.3227	0.8503	
Fejer-Korovkin (fk4)	3	0.7193	0.4775	0.4733	0.5976	4
	4	0.7471	0.4900	0.8288	0.4412	
	5	0.7734	0.4930	0.8541	0.4286	
	6	0.8011	0.4932	0.8562	0.4191	
	7	0.8718	0.4580	0.9417	0.4124	
Daubechies (db40)	3	0.7553	0.4439	0.4896	0.6326	3
	4	0.7856	0.4419	0.4793	0.6432	
	5	0.8079	0.4523	0.4598	0.6487	
	6	0.8409	0.4471	0.5227	0.5499	
	7	0.9666	0.3970	0.7096	0.4510	

Tablo 3.8. Sakarya SYİ-6'a ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması

Dalgacık ailesi	Dalgacık Bant Seviyesi	EĞİTME		TEST		Sıra
		OMH	R ²	OMH	R ²	
Haar	3	0.6392	0.5635	1.7249	0.1808	3
	4	0.6712	0.5725	1.7120	0.1911	
	5	0.6937	0.5805	1.7126	0.1901	
	6	0.7163	0.5790	1.7154	0.1892	
	7	0.7570	0.5683	1.7209	0.1849	
Symlets (sym3)	3	0.6241	0.7232	1.4839	0.0030	8
	4	0.6603	0.7429	1.6122	0.0021	
	5	0.6905	0.7279	1.6124	0.0028	
	6	0.8073	0.7010	1.8496	0.0047	
	7	1.1043	0.5631	1.7844	0.0055	
Coiflets (coif2)	3	0.6328	0.6908	1.6352	0.0608	6
	4	0.6659	0.7029	1.6306	0.0568	
	5	0.6918	0.7085	1.6386	0.0523	
	6	0.7439	0.7051	1.6517	0.0563	
	7	0.8537	0.6792	1.6322	0.0580	
Biorthogonal (bior1.3)	3	0.6536	0.5970	1.9760	0.0319	7
	4	0.6947	0.5856	1.9437	0.0295	
	5	0.7261	0.5954	1.8940	0.0245	
	6	0.7423	0.5914	1.8970	0.0255	
	7	0.7490	0.5866	1.8955	0.0255	
Reverse biorthogonal (rbio1.3)	3	0.6981	0.6379	2.0154	0.0955	5
	4	0.7465	0.6605	2.0105	0.0932	
	5	0.7764	0.6821	2.0180	0.0808	
	6	0.8131	0.6664	2.0146	0.0808	
	7	0.8344	0.6693	2.0199	0.0801	
Discrete approximation of Meyer (dmey)	3	0.6759	0.6318	0.2942	0.9323	1
	4	0.6971	0.6368	0.2785	0.9371	
	5	0.7142	0.6396	0.2788	0.9368	
	6	0.7214	0.6406	0.2887	0.9381	
	7	0.7224	0.6411	0.2883	0.9376	
Fejer-Korovkin (fk4)	3	0.6643	0.6801	2.4297	0.1255	4
	4	0.7559	0.6362	2.6447	0.1147	
	5	0.7318	0.6731	2.1573	0.1352	
	6	0.7577	0.6568	2.0215	0.1498	
	7	0.7577	0.6567	2.0540	0.1540	
Daubechies (db40)	3	0.6322	0.4292	0.6494	0.6130	2
	4	0.6639	0.4498	0.6582	0.6187	
	5	0.6834	0.4499	1.5942	0.2900	
	6	0.7409	0.4340	1.5982	0.2888	
	7	0.8696	0.4479	1.5359	0.3012	

Tablo 3.9. Sakarya SYİ-12'e ait 3 gecikme zamanlı ADD-USBÇS hibrit modeli dalgacık ailesi ve dalgacık bant seviyelerinin karşılaştırması

Dalgacık ailesi	Dalgacık Bant Seviyesi	EĞİTME		TEST		Sıra
		OMH	R ²	OMH	R ²	
Haar	3	0.6945	0.4318	1.0161	0.1402	8
	4	0.7110	0.4472	1.0078	0.1467	
	5	0.7234	0.4495	1.0074	0.1373	
	6	0.7569	0.4418	1.0223	0.1163	
	7	0.8004	0.4249	1.0480	0.0972	
Symlets (sym3)	3	0.7522	0.4775	0.5655	0.8210	1
	4	0.7873	0.4601	0.5943	0.8035	
	5	0.8599	0.4402	0.6726	0.7823	
	6	1.0337	0.4007	0.6169	0.8083	
	7	1.0961	0.4327	0.5762	0.8194	
Coiflets (coif2)	3	0.7153	0.5913	0.7673	0.5222	4
	4	0.7690	0.5812	0.7504	0.5520	
	5	0.7907	0.5949	0.7466	0.5566	
	6	0.8114	0.5944	0.7433	0.5558	
	7	0.8220	0.5888	0.7434	0.5558	
Biorthogonal (bior1.3)	3	0.7300	0.5233	0.9451	0.3425	6
	4	0.7499	0.5027	1.0186	0.2958	
	5	0.7699	0.5076	1.0249	0.2953	
	6	0.7928	0.5053	1.0738	0.2953	
	7	0.7928	0.5053	1.0738	0.2953	
Reverse biorthogonal (rbio1.3)	3	0.7236	0.5867	0.9882	0.3147	7
	4	0.7706	0.5566	0.9977	0.3064	
	5	0.8109	0.5748	0.9990	0.3060	
	6	0.8280	0.5745	0.9967	0.3063	
	7	0.9444	0.5799	0.9974	0.3059	
Discrete approximation of Meyer (dmey)	3	0.7267	0.6647	0.6525	0.7013	3
	4	0.7606	0.6353	0.6685	0.6945	
	5	0.7676	0.6566	0.6654	0.6988	
	6	0.7736	0.6344	0.7115	0.6688	
	7	0.7692	0.6564	0.6654	0.6989	
Fejer-Korovkin (fk4)	3	0.7489	0.5938	0.5532	0.7717	2
	4	0.7833	0.5783	0.5935	0.7180	
	5	0.8312	0.5926	0.5974	0.7164	
	6	0.8880	0.5535	0.5961	0.7170	
	7	0.9518	0.5425	0.5940	0.7180	
Daubechies (db40)	3	0.7579	0.4926	0.9211	0.3603	5
	4	0.7875	0.4785	0.9177	0.3734	
	5	0.7930	0.4769	0.9129	0.3755	
	6	0.7961	0.4814	0.9148	0.3749	
	7	0.8351	0.4817	0.9148	0.3749	

Tablo 3.6'da görüleceği üzere, SYİ-1 zaman ölçeğinde 3 gecikme zamanlı ADD-USBÇS hibrit modelinde OMH=0,2976 ve R²=0,8537 test verisi performans kriterlerine göre en iyi sonucu Discrete approximation of Meyer (dmey) dalgacık ailesi ile 3.

dalgacık bant seviyesi vermiştir. Fejer-Korovkin (fk4) ve Daubechies (db40) dalgacık ailelerinin sonuçlarının da dmey dalgacık ailesine oldukça yakın olduğu görülmüştür. Haar dalgacık ailesi dışındaki diğer dalgacık ailelerinin SYİ-1 kuraklık değerlerini alt bantlarına ayrıştırma işlemindeki performansları da makul seviyelerdedir. Hibrit modelde en iyi sonucu veren dmey dalgacık ailesinde bant seviyesinin artması ile ayrıştırma performansının artmadığı görülmüştür. Diğer dalgacık ailelerinde de bant seviyesinin artması ile ayrıştırma performansı arasında anlamlı bir ilişkinin olmadığı tespit edilmiştir.

Tablo 3.7’de görüleceği üzere, SYİ-3 zaman ölçeğinde 3 gecikme zamanlı ADD-USBÇS hibrit modelinde $OMH=0,2974$ ve $R^2=0,8745$ test verisi performans kriterlerine göre en iyi sonucu yine Discrete approximation of Meyer (dmey) dalgacık ailesi ile 3. dalgacık bant seviyesi vermiştir. Bu zaman ölçeğinde dmey dalgacık ailesini, Symlets (sym3) ve Daubechies (db40) dalgacık aileleri takip etmektedir. Ancak burada dmey dalgacık ailesinin sonuçları diğer dalgacık ailelerinin sonuçlarına göre oldukça üstündür. Ayrıca bu zaman ölçeği için elde edilen model sonuçlarına göre dmey dalgacık ailesinde bant seviyesi arttıkça ayrıştırma performansları düşmüştür.

Tablo 3.8’de görüleceği üzere, SYİ-6 zaman ölçeğinde 3 gecikme zamanlı ADD-USBÇS hibrit modelinde $OMH=0,2785$ ve $R^2=0,9371$ test verisi performans kriterlerine göre en iyi sonucu yine Discrete approximation of Meyer (dmey) dalgacık ailesi ile öncekilerden farklı olarak 4. dalgacık bant seviyesi vermiştir. Daubechies (db40) dalgacık ailesinin 3. ve 4. bant seviyeleri hariç diğer tüm dalgacık ailelerinin, bu zaman ölçeğinde test verisi performans kriterlerine göre oldukça başarısız sonuçlar verdiği görülmüştür. Burada, dmey dalgacık ailesinde bant seviyesinin artması ile R^2 değerleri ve OMH değerleri artmıştır. OMH ’de 0’a yaklaşıldıkça daha başarılı sonuçlar elde edildiğinden hem R^2 hem de OMH ’e bakılarak en iyi sonuç olarak 4. dalgacık bant seviyesi seçilmiştir.

Tablo 3.9’da görüleceği üzere, SYİ-12 zaman ölçeğinde 3 gecikme zamanlı ADD-USBÇS hibrit modelinde $OMH=0,5655$ ve $R^2=0,8210$ test verisi performans kriterlerine göre en iyi sonucu Symlets (sym3) dalgacık ailesi ile 3. dalgacık bant seviyesi vermiştir. Burada, Symlets (sym3) dalgacık ailesinin ayrıştırma performansını Fejer-Korovkin (fk4) dalgacık ailesinin performansı takip etmektedir. Ayrıca dmey dalgacık ailesi de

yine bu ölçekte yüksek R^2 değerlerini vermiştir. Bu zaman ölçeğinde hem en iyi sonucu veren Symlets (sym3) dalgacık ailesinde hem de diğer dalgacık ailelerinde OMH değerlerinin diğer zaman ölçeklerine göre daha yüksek değerlere sahip olmasından dolayı model performansının düşük kaldığı görülmüştür.

ADD-USBÇS hibrit modellerinden elde edilen OMH ve R^2 performans kriterlerine göre, Sakarya istasyonunun her bir zaman ölçeği için optimum gecikme zamanı 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) olarak bulunmuştur. Optimum gecikme zamanının belirlenmesine yönelik olarak Sakarya istasyonu SYİ-1 zaman ölçeği için dmey dalgacık ailesine göre elde edilen gecikme zamanları ve dalgacık bant seviyelerinin karşılaştırması örnek olması açısından Tablo 3.10'da verilmiştir.

Tablo 3.10. Sakarya SYİ-1 için dmey dalgacık ailesine sahip ADD-USBÇS hibrit modeli gecikme zamanları ve dalgacık bant seviyelerinin karşılaştırması

Gecikme zamanı	Dalgacık Bant Seviyesi	<u>EĞİTME</u>		<u>TEST</u>	
		OMH	R^2	OMH	R^2
t, t-1	3	0.6018	0.4206	0.7465	0.2952
	4	0.6001	0.4213	0.7700	0.3130
	5	0.5990	0.4220	0.8023	0.3053
	6	0.5995	0.4217	0.8197	0.2973
	7	0.5995	0.4217	0.8278	0.2983
t, t-1, t-2	3	0.7710	0.5204	0.7377	0.5558
	4	0.8059	0.5314	0.8012	0.5656
	5	0.8299	0.5261	0.8578	0.5544
	6	0.8500	0.5274	0.8709	0.5565
	7	0.8582	0.5312	0.8915	0.5561
t, t-1, t-2, t-3	3	0.7637	0.5799	0.2976	0.8537
	4	0.8007	0.5917	0.2973	0.8534
	5	0.8291	0.5817	0.2972	0.8533
	6	0.8474	0.5832	0.2973	0.8533
	7	0.8575	0.5881	0.2975	0.8531
t, t-1, t-2, t-3, t-4	3	0.7651	0.6028	0.7209	0.7047
	4	0.8065	0.6102	0.8014	0.6986
	5	0.8362	0.6014	0.8479	0.6902
	6	0.8564	0.6009	0.8862	0.6931
	7	0.8665	0.6066	0.8990	0.6897
t, t-1, t-2, t-3, t-4, t-5	3	0.7619	0.6192	0.7216	0.7127
	4	0.8056	0.6266	0.8017	0.7085
	5	0.8363	0.6187	0.8537	0.6948
	6	0.8568	0.6189	0.8909	0.7006
	7	0.8675	0.6237	0.9021	0.6968

Tablo 3.10’da görüleceği üzere, Sakarya istasyonu SYİ-1 zaman ölçeğinde dmey dalgacık ailesine sahip ADD-USBÇS hibrit modelinde OMH=0,2976 ve $R^2=0,8537$ performans kriterlerine göre 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) ve 3. dalgacık bant seviyesi en iyi sonuçları vermiştir. 3 gecikme zamanına kadar performans kriterlerinin değeri iyileşirken 4 ve 5 gecikme zamanlarında ise değerler düşmüştür. Burada olduğu gibi Sakarya istasyonunun diğer tüm zaman ölçeklerinde de gecikme zamanları için benzer sonuçlar elde edilmiş olup optimum gecikme zamanı olarak 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) kabul edilmiştir. Elde edilen bu sonuç diğer istasyonlar ve diğer hibrit modeller için de kullanılmıştır.

Sakarya istasyonunun her bir zaman ölçeği için ADD-USBÇS hibrit modelinde belirlenen optimum gecikme zamanları ile dalgacık ailelerinin başarı sıraları Tablo 3.11’de verilmiştir.

Tablo 3.11. Sakarya istasyonu optimum gecikme zamanları için ADD-USBÇS hibrit modelinde dalgacık ailelerinin başarı sıraları

Zaman ölçeği	Gecikme zamanı	OMH ve R^2 Performans Kriterlerine Göre Model Başarı Sırası							
		1	2	3	4	5	6	7	8
SYİ-1	t, t-1	dmey	coif2	fk4	db40	rbio1.3	sym3	haar	bior1.3
	t, t-1, t-2	dmey	fk4	db40	coif2	sym3	rbio1.3	bior1.3	haar
	t, t-1, t-2, t-3	dmey	fk4	db40	coif2	sym3	rbio1.3	bior1.3	haar
	t, t-1, t-2, t-3, t-4	db40	dmey	fk4	coif2	sym3	bior1.3	rbio1.3	haar
	t, t-1, t-2, t-3, t-4, t-5	dmey	db40	fk4	coif2	sym3	bior1.3	haar	rbio1.3
SYİ-3	t, t-1	coif2	dmey	sym3	db40	rbio1.3	fk4	bior1.3	haar
	t, t-1, t-2	coif2	sym3	dmey	bior1.3	db40	rbio1.3	fk4	haar
	t, t-1, t-2, t-3	dmey	sym3	db40	fk4	rbio1.3	coif2	bior1.3	haar
	t, t-1, t-2, t-3, t-4	dmey	db40	coif2	rbio1.3	bior1.3	haar	fk4	sym3
	t, t-1, t-2, t-3, t-4, t-5	dmey	db40	coif2	bior1.3	rbio1.3	haar	sym3	fk4
SYİ-6	t, t-1	db40	haar	coif2	dmey	fk4	sym3	rbio1.3	bior1.3
	t, t-1, t-2	dmey	db40	sym3	coif2	haar	fk4	rbio1.3	bior1.3
	t, t-1, t-2, t-3	dmey	db40	haar	fk4	rbio1.3	coif2	bior1.3	sym3
	t, t-1, t-2, t-3, t-4	dmey	db40	rbio1.3	sym3	coif2	fk4	haar	bior1.3
	t, t-1, t-2, t-3, t-4, t-5	dmey	coif2	fk4	sym3	bior1.3	db40	haar	rbio1.3
SYİ-12	t, t-1	fk4	rbio1.3	dmey	haar	sym3	bior1.3	db40	coif2
	t, t-1, t-2	dmey	fk4	db40	rbio1.3	coif2	bior1.3	sym3	haar
	t, t-1, t-2, t-3	sym3	fk4	dmey	coif2	db40	bior1.3	rbio1.3	haar
	t, t-1, t-2, t-3, t-4	fk4	db40	dmey	bior1.3	haar	sym3	rbio1.3	coif2
	t, t-1, t-2, t-3, t-4, t-5	dmey	bior1.3	db40	sym3	fk4	coif2	rbio1.3	haar

Tablo 3.11 incelendiğinde; 4 farklı zaman ölçeği, 5 farklı gecikme zamanı ve 8 farklı dalgacık ailesine göre toplam 160 adet (5 farklı dalgacık bant seviyesi de dikkate alınırsa 800 adet olmaktadır) ADD-USBÇS hibrit modeli dalgacık dönüşümü aşamasında ele alınmıştır. Bu hibrit modeller dikkate alındığında SYİ kuraklık zaman

serilerinin dalgacık dönüşümü ile analizinde, Discrete approximation of Meyer (dmey) dalgacık ailesinin oldukça başarılı olduğu ve diğer dalgacık ailelerine göre kuraklık verilerine daha iyi uyum sağladığı görülmüştür. Tablo 3.11'den görüleceği üzere, dmey dalgacık ailesinin ardından sıralama açısından en başarılı 2. dalgacık ailesi ise yine hidrometeorolojik çalışmalarda yaygın kullanılan Daubechies (db40) dalgacık ailesidir. Ayrıca gecikme zamanı olarak 3 gecikme zamanı (t , $t-1$, $t-2$, $t-3$ girdi değişkeni) dalgacık dönüşümünün genelinde daha iyi bir performans göstermiştir. Çalışmada ele alınan dalgacık dönüşümünde, 3 gecikme zamanından sonraki 4 ve 5 gecikme zamanlarının OMH ve R^2 performans kriterlerini iyileştiremediği görülmüştür.

Çalışmada Sakarya istasyonu için yapılan tüm bu dalgacık dönüşümü analizlerinin sonucunda;

-SYİ-1 ve SYİ-3 zaman ölçekleri için dmey dalgacık ailesine sahip, 3 gecikme zamanlı ve 3. dalgacık bant seviyesi,

-SYİ-6 zaman ölçeği için dmey dalgacık ailesine sahip, 3 gecikme zamanlı ve 4. dalgacık bant seviyesi,

-SYİ-12 zaman ölçeği için Symlets (sym3) dalgacık ailesine sahip, 3 gecikme zamanlı ve 3. dalgacık bant seviyesi en üstün model performanslarını göstermiştir.

Burada her bir zaman ölçeği için elde edilen optimum gecikme zamanı, en uygun dalgacık ailesi ve en uygun dalgacık bant seviyesi diğer istasyonlar ve diğer hibrit modeller için de kullanılmıştır.

3.6. Ampirik Mod Ayırıştırması (AMA) Sonuçları

Her bir zaman ölçeği için optimum AMA bant seviyesinin belirlenmesi amacıyla SYİ kuraklık zaman serileri, AMA yöntemi ile alt bantlarına ayrılmıştır. AMA ile alt bantlarına ayırıştırma işleminde 2D, 3D, 4D ve 5D olmak üzere 4 farklı bant seviyesi dikkate alınmıştır. Ayrıca otokorelasyon fonksiyonu ve dalgacık dönüşümü sonucunda belirlenen optimum 3 gecikme zamanına (t , $t-1$, $t-2$, $t-3$) göre alt bantlarına ayrılan SYİ kuraklık zaman serileri eğitme ve test verisi şeklinde AMA-USBÇS hibrit modelinde girdi verisi olmak üzere kullanılmıştır. Dalgacık dönüşümünde olduğu gibi burada da

havzadaki 10 adet istasyonu temsilen sadece Sakarya istasyonuna ait SYİ kuraklık zaman serileri için AMA yöntemi uygulanmıştır. Tablo 3.12’de her bir zaman ölçeği için Sakarya istasyonuna ait AMA-USBÇS hibrit modeli sonuçları verilmiştir.

Tablo 3.12. Sakarya istasyonu her bir zaman ölçeği için AMA-USBÇS hibrit model performansları

Zaman ölçeği	Gecikme zamanı	Çıkış	AMA Bant seviyesi	EĞİTME		TEST	
				KOKH	R ²	KOKH	R ²
SYİ-1	t, t-1, t-2, t-3	t+1	2D	0.447	0.940	0.571	0.881
			3D	0.486	0.939	0.604	0.880
			4D	0.507	0.939	0.605	0.880
			5D	0.523	0.939	0.605	0.880
SYİ-3	t, t-1, t-2, t-3	t+1	2D	0.411	0.945	0.708	0.896
			3D	0.468	0.943	0.749	0.899
			4D	0.501	0.942	0.740	0.900
			5D	0.559	0.942	0.743	0.900
SYİ-6	t, t-1, t-2, t-3	t+1	2D	0.406	0.935	0.702	0.942
			3D	0.442	0.936	0.662	0.940
			4D	0.484	0.938	0.657	0.941
			5D	0.500	0.937	0.661	0.940
SYİ-12	t, t-1, t-2, t-3	t+1	2D	0.449	0.838	0.607	0.842
			3D	0.470	0.829	0.615	0.840
			4D	0.471	0.830	0.614	0.840
			5D	0.474	0.829	0.621	0.838

Tablo 3.12’de verilen AMA-USBÇS hibrit modeli test sonuçları incelendiğinde; SYİ-1, SYİ-3 ve SYİ-12 zaman ölçekleri için hem KOKH (0,571, 0,708, 0,607) hem de R² (0,881, 0,896, 0,842) performans kriteri değerlerine göre 2D bant seviyesi en başarılı sonuçları vermiştir. Bu zaman ölçeklerinde bant seviyesinin artması model performansını iyileştirememiştir. SYİ-6 zaman ölçeği için R²=0,942 değerine göre 2D bant seviyesi, KOKH=0,657 değerine göre ise 4D bant seviyesi daha başarılıdır. Bu çalışmada, AMA yöntemi ile alt bantlarına ayrıştırma işleminin bütünü düşünüldüğünde bant seviyelerinin artması ile model performanslarının önemli ölçüde iyileşmediği tespit edildiğinden SYİ-6 zaman ölçeğinde de R²=0,942 değerinden dolayı optimum AMA bant seviyesi olarak 2D seçilmiştir. Tablo 3.12’den elde edilen ve her bir zaman ölçeği için belirlenen optimum AMA bant seviyeleri hem diğer istasyonlar hem de diğer hibrit modeller için de dikkate alınmıştır.

3.7. Varyasyonel Mod Ayrıştırması (VMA) Sonuçları

AMA yönteminde olduğu gibi her bir zaman ölçeği için optimum VMA bant seviyesinin belirlenmesi amacıyla SYİ kuraklık zaman serileri, VMA yöntemi ile alt bantlarına ayrılmıştır. VMA ile alt bantlarına ayrıştırma işleminde yine 2D, 3D, 4D ve 5D olmak üzere 4 farklı bant seviyesi dikkate alınmıştır. Ayrıca otokorelasyon fonksiyonu ve dalgacık dönüşümü sonucunda belirlenen optimum 3 gecikme zamanına (t, t-1, t-2, t-3) göre alt bantlarına ayrılan SYİ kuraklık zaman serileri eğitime ve test verisi şeklinde VMA-USBÇS hibrit modelinde girdi verisi olmak üzere kullanılmıştır. Dalgacık dönüşümü ve AMA yönteminde olduğu gibi burada da havzadaki 10 adet istasyonu temsilen sadece Sakarya istasyonuna ait SYİ kuraklık zaman serileri için VMA yöntemi uygulanmıştır. Tablo 3.13'te her bir zaman ölçeği için Sakarya istasyonuna ait VMA-USBÇS hibrit modeli sonuçları verilmiştir.

Tablo 3.13. Sakarya istasyonu her bir zaman ölçeği için VMA-USBÇS hibrit model performansları

Zaman ölçeği	Gecikme zamanı	Çıkış	VMA Bant seviyesi	EĞİTME		TEST	
				KOKH	R ²	KOKH	R ²
SYİ-1	t, t-1, t-2, t-3	t+1	2D	0.967	0.379	0.644	0.607
			3D	1.012	0.464	0.531	0.722
			4D	0.982	0.627	0.377	0.857
			5D	1.029	0.703	0.254	0.935
SYİ-3	t, t-1, t-2, t-3	t+1	2D	0.907	0.572	0.964	0.442
			3D	0.963	0.509	0.830	0.510
			4D	0.967	0.628	0.469	0.826
			5D	0.955	0.673	0.294	0.932
SYİ-6	t, t-1, t-2, t-3	t+1	2D	0.878	0.462	1.070	0.346
			3D	0.851	0.558	1.224	0.489
			4D	0.867	0.768	0.639	0.825
			5D	0.971	0.721	0.720	0.847
SYİ-12	t, t-1, t-2, t-3	t+1	2D	0.935	0.576	0.957	0.527
			3D	0.938	0.602	0.788	0.637
			4D	0.983	0.747	0.829	0.760
			5D	0.951	0.702	0.465	0.910

Tablo 3.13'te verilen VMA-USBÇS hibrit modeli test sonuçları incelendiğinde; SYİ-1, SYİ-3 ve SYİ-12 zaman ölçekleri için hem KOKH (0,254, 0,294, 0,465) hem de R² (0,935, 0,932, 0,910) performans kriteri değerlerine göre 5D bant seviyesi en başarılı sonuçları vermiştir. Bu zaman ölçeklerinde bant seviyesinin 2D'den 5D'e kadar

artırılması, KOKH ve R^2 performans kriterlerinin her ikisine göre de model performansını önemli ölçüde iyileştirmiştir. SYİ-6 zaman ölçeğinde KOKH=0,639 değerine göre 4D bant seviyesi, $R^2=0,847$ değerine göre ise 5D bant seviyesi en iyi sonuçları vermiştir. SYİ-6 zaman ölçeğinde 4D ile 5D bant seviyeleri için elde edilen KOKH değerleri arasında önemli bir performans farkı olmasına rağmen 4D ile 5D bant seviyelerindeki R^2 değerleri birbirine çok yakın sonuçlar vermiştir. Bu sebepten dolayı SYİ-6 zaman ölçeğinde KOKH değerleri dikkate alınarak optimum bant seviyesi olarak 4D bant seviyesi seçilmiştir. VMA yönteminde, AMA yönteminin aksine bant seviyeleri arttıkça model performansları fark edilir bir şekilde iyileşme göstermiştir. Burada belirlenen optimum VMA bant seviyeleri, hem diğer istasyonlar hem de diğer hibrit modeller için de dikkate alınmıştır.

3.8. Bağımsız ve Hibrit Tahmin Model Sonuçlarının Elde Edilmesi

ADD, AMA ve VMA analizleri ile optimum gecikme zamanı, en uygun dalgacık ailesi ve dalgacık bant seviyeleri ile optimum AMA ve VMA bant seviyeleri belirlenmiş olup bu değerlere göre alt bantlarına ayrılan ve yeniden elde edilen SYİ kuraklık zaman serileri tüm istasyonlar için bağımsız ve hibrit tahmin modellerinde eğitime ve test verisi şeklinde girdi değişkeni olarak kullanılmıştır. Veri setinin %75'i eğitime, veri setinin %25'i ise test verisi olacak şekilde bir kabul yapılarak 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) için modellerde t+1 zamanındaki çıkış değerleri elde edilmiştir. Daha önceden model gelişiminde bahsedilen parametrelere göre oluşturulan bağımsız tahmin modellerinde; YSA, USBÇS, GSR, DVMR makine öğrenmesi yöntemleri ve UKSB derin öğrenme yöntemi kullanılmıştır. Hibrit modeller için ise ADD, AMA ve VMA'lı YSA, USBÇS, GSR, DVMR ve UKSB modelleri bu çalışmada ele alınmıştır. Böylece her bir istasyonun her bir zaman ölçeği için toplamda 20 adet tahmin modeli oluşturulmuştur. Tahmin modellerinden elde edilen tüm sonuçlar 6 farklı performans kriterine göre birbirleri ile karşılaştırılmıştır. Tablo 3.14–3.17'de Sakarya SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 için elde edilen tahmin modellerine ait sonuçların karşılaştırması verilmiştir.

Tablo 3.14. Sakarya istasyonu SYİ-1 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.889	0.943	0.093	0.477	0.729	0.122	1.566	1.252	-0.628	0.069	0.921	0.002
ADD-USBÇS	0.986	0.993	-0.005	0.604	0.764	0.580	0.145	0.380	0.850	0.889	0.298	0.854
AMA-USBÇS	0.200	0.447	0.796	0.830	0.317	0.940	0.325	0.571	0.662	0.778	0.456	0.881
VMA-USBÇS	1.058	1.029	-0.080	0.709	0.830	0.703	0.064	0.254	0.933	0.943	0.204	0.935
YSA	0.926	0.962	0.055	0.456	0.755	0.055	1.220	1.105	-0.268	0.263	0.876	0.164
ADD-YSA	0.115	0.339	0.880	0.920	0.267	0.883	0.148	0.385	0.846	0.887	0.301	0.851
AMA-YSA	0.359	0.599	0.634	0.769	0.463	0.881	0.341	0.584	0.646	0.768	0.471	0.880
VMA-YSA	0.064	0.253	0.935	0.949	0.198	0.935	0.060	0.245	0.939	0.946	0.200	0.940
GSR	0.935	0.967	0.046	0.451	0.763	0.094	1.013	1.007	-0.053	0.380	0.809	0.054
ADD-GSR	0.135	0.367	0.863	0.892	0.291	0.863	0.143	0.378	0.852	0.891	0.297	0.861
AMA-GSR	0.360	0.600	0.633	0.765	0.461	0.881	0.348	0.590	0.638	0.764	0.474	0.879
VMA-GSR	0.065	0.255	0.933	0.941	0.201	0.934	0.063	0.251	0.935	0.944	0.205	0.937
DVMR	0.964	0.982	0.016	0.435	0.757	0.021	1.247	1.117	-0.296	0.248	0.870	0.293
ADD-DVMR	0.132	0.364	0.865	0.940	0.283	0.869	0.217	0.466	0.774	0.844	0.347	0.780
AMA-DVMR	0.372	0.610	0.620	0.769	0.470	0.878	0.344	0.586	0.643	0.767	0.471	0.875
VMA-DVMR	0.065	0.255	0.934	0.946	0.199	0.934	0.079	0.282	0.918	0.933	0.227	0.921
UKSB	0.029	0.171	0.970	0.951	0.119	0.974	0.029	0.170	0.971	0.955	0.111	0.972
ADD-UKSB	0.047	0.216	0.953	0.916	0.176	0.972	0.049	0.221	0.949	0.918	0.173	0.955
AMA-UKSB	0.017	0.131	0.982	0.982	0.107	0.989	0.062	0.249	0.937	0.945	0.187	0.954
VMA-UKSB	0.051	0.225	0.948	0.921	0.202	0.989	0.054	0.208	0.948	0.937	0.179	0.970

Tablo 3.15. Sakarya istasyonu SYİ-3 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.834	0.913	0.110	0.479	0.728	0.153	1.999	1.414	-0.621	0.069	1.034	0.080
ADD-USBÇS	0.848	0.921	0.090	0.660	0.721	0.640	0.158	0.398	0.872	0.902	0.315	0.875
AMA-USBÇS	0.169	0.411	0.820	0.777	0.291	0.945	0.502	0.708	0.593	0.736	0.528	0.896
VMA-USBÇS	0.912	0.955	0.026	0.678	0.766	0.673	0.087	0.294	0.930	0.940	0.224	0.932
YSA	0.740	0.860	0.211	0.534	0.658	0.211	1.134	1.065	0.081	0.450	0.893	0.136
ADD-YSA	0.128	0.357	0.863	0.917	0.282	0.895	0.153	0.391	0.876	0.905	0.315	0.884
AMA-YSA	0.259	0.509	0.723	0.763	0.395	0.890	0.400	0.633	0.676	0.784	0.505	0.914
VMA-YSA	0.127	0.356	0.865	0.903	0.297	0.941	0.118	0.344	0.904	0.923	0.277	0.961
GSR	0.921	0.960	0.018	0.429	0.758	0.018	1.325	1.151	-0.074	0.365	0.916	0.034
ADD-GSR	0.135	0.367	0.863	0.890	0.291	0.863	0.155	0.394	0.874	0.904	0.322	0.876
AMA-GSR	0.262	0.512	0.720	0.764	0.395	0.889	0.404	0.636	0.672	0.782	0.506	0.911
VMA-GSR	0.062	0.249	0.934	0.941	0.193	0.942	0.058	0.241	0.953	0.956	0.196	0.957
DVMR	0.671	0.819	0.284	0.574	0.579	0.301	1.239	1.113	-0.005	0.403	0.865	0.020
ADD-DVMR	0.110	0.332	0.882	0.981	0.255	0.883	0.167	0.409	0.837	0.876	0.330	0.843
AMA-DVMR	0.268	0.518	0.714	0.827	0.394	0.887	0.221	0.470	0.821	0.871	0.349	0.934
VMA-DVMR	0.052	0.229	0.944	0.970	0.180	0.954	0.179	0.423	0.855	0.891	0.327	0.876
UKSB	0.029	0.169	0.970	0.941	0.139	0.988	0.098	0.313	0.913	0.930	0.220	0.927
ADD-UKSB	0.027	0.163	0.971	0.946	0.136	0.981	0.132	0.364	0.894	0.916	0.300	0.907
AMA-UKSB	0.008	0.087	0.992	0.989	0.068	0.993	0.122	0.349	0.901	0.921	0.278	0.909
VMA-UKSB	0.011	0.104	0.988	0.976	0.082	0.990	0.057	0.239	0.954	0.956	0.166	0.962

Tablo 3.16. Sakarya istasyonu SYİ-6 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.701	0.837	0.082	0.462	0.643	0.121	3.235	1.799	-0.920	-0.082	1.348	0.016
ADD-USBÇS	0.761	0.872	0.000	0.643	0.697	0.637	0.109	0.330	0.935	0.945	0.276	0.937
AMA-USBÇS	0.165	0.406	0.785	0.800	0.270	0.935	0.493	0.702	0.707	0.806	0.535	0.942
VMA-USBÇS	0.752	0.867	0.014	0.426	0.734	0.768	0.409	0.639	0.758	0.836	0.492	0.825
YSA	0.557	0.747	0.257	0.558	0.555	0.257	2.240	1.497	-0.329	0.234	1.119	0.113
ADD-YSA	0.107	0.327	0.860	0.867	0.253	0.864	0.102	0.319	0.940	0.948	0.256	0.945
AMA-YSA	0.238	0.488	0.688	0.738	0.376	0.884	0.565	0.752	0.665	0.781	0.571	0.936
VMA-YSA	0.098	0.314	0.871	0.906	0.244	0.874	0.238	0.487	0.859	0.897	0.387	0.865
GSR	0.691	0.831	0.078	0.461	0.655	0.200	1.665	1.290	0.012	0.419	0.940	0.020
ADD-GSR	0.085	0.291	0.888	0.899	0.233	0.890	0.114	0.338	0.932	0.943	0.291	0.934
AMA-GSR	0.243	0.493	0.681	0.725	0.381	0.889	0.641	0.801	0.620	0.756	0.597	0.926
VMA-GSR	0.069	0.262	0.910	0.922	0.209	0.910	0.158	0.398	0.906	0.926	0.324	0.914
DVMR	0.449	0.670	0.401	0.638	0.415	0.420	1.636	1.279	0.030	0.428	0.923	0.035
ADD-DVMR	0.099	0.315	0.870	0.899	0.250	0.870	0.374	0.611	0.778	0.848	0.482	0.821
AMA-DVMR	0.228	0.478	0.701	0.848	0.359	0.890	0.396	0.630	0.765	0.840	0.425	0.853
VMA-DVMR	0.053	0.230	0.931	0.943	0.189	0.933	0.256	0.506	0.848	0.890	0.400	0.881
UKSB	0.003	0.050	0.997	0.968	0.047	1.000	0.096	0.310	0.924	0.934	0.229	0.952
ADD-UKSB	0.002	0.044	0.998	0.973	0.035	0.998	0.293	0.542	0.830	0.766	0.352	0.883
AMA-UKSB	0.010	0.101	0.987	0.984	0.089	0.996	0.280	0.529	0.834	0.881	0.324	0.893
VMA-UKSB	0.008	0.088	0.990	0.973	0.071	0.993	0.221	0.470	0.869	0.903	0.330	0.945

Tablo 3.17. Sakarya istasyonu SYİ-12 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.783	0.885	0.060	0.420	0.709	0.096	2.740	1.655	-0.631	0.006	1.286	0.019
ADD-USBÇS	0.850	0.922	-0.021	0.375	0.752	0.478	0.495	0.704	0.705	0.776	0.565	0.821
AMA-USBÇS	0.202	0.449	0.758	0.823	0.301	0.838	0.369	0.607	0.781	0.825	0.425	0.842
VMA-USBÇS	0.905	0.951	-0.087	0.338	0.817	0.702	0.216	0.465	0.872	0.885	0.373	0.910
YSA	1.201	1.096	-0.443	0.142	0.892	0.009	2.441	1.562	-0.452	0.105	1.302	0.084
ADD-YSA	0.178	0.422	0.786	0.840	0.330	0.786	0.466	0.683	0.723	0.788	0.500	0.728
AMA-YSA	0.183	0.428	0.780	0.837	0.310	0.781	0.561	0.749	0.666	0.752	0.625	0.749
VMA-YSA	0.089	0.297	0.894	0.910	0.244	0.901	0.201	0.449	0.880	0.892	0.402	0.914
GSR	0.739	0.860	0.112	0.449	0.724	0.112	2.524	1.589	-0.502	0.077	1.317	0.051
ADD-GSR	0.135	0.368	0.837	0.873	0.274	0.842	0.615	0.784	0.634	0.732	0.607	0.782
AMA-GSR	0.221	0.470	0.735	0.809	0.368	0.743	0.474	0.689	0.718	0.784	0.560	0.754
VMA-GSR	0.070	0.264	0.917	0.926	0.212	0.917	0.170	0.412	0.899	0.905	0.362	0.912
DVMR	0.404	0.635	0.515	0.679	0.393	0.240	1.736	1.318	-0.033	0.341	1.130	0.020
ADD-DVMR	0.176	0.420	0.788	0.842	0.322	0.791	0.544	0.737	0.677	0.758	0.542	0.789
AMA-DVMR	0.238	0.488	0.714	0.797	0.344	0.720	0.519	0.720	0.691	0.768	0.478	0.712
VMA-DVMR	0.075	0.275	0.910	0.921	0.215	0.911	0.435	0.659	0.741	0.799	0.560	0.891
UKSB	0.000	0.007	1.000	0.999	0.003	1.000	0.180	0.424	0.893	0.901	0.304	0.917
ADD-UKSB	0.009	0.096	0.989	0.983	0.085	0.997	0.203	0.450	0.879	0.891	0.363	0.899
AMA-UKSB	0.005	0.073	0.994	0.988	0.068	0.999	0.277	0.526	0.835	0.861	0.417	0.931
VMA-UKSB	0.019	0.138	0.977	0.971	0.129	0.997	0.114	0.338	0.932	0.929	0.265	0.959

Tablo 3.14 ile 3.17 arasında verilen Sakarya SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 için tahmin modelleri test sonuçlarına ait performans karşılaştırmalarına bakıldığında; SYİ-1 zaman ölçeğinde performans kriterlerine ($OKH=0,029$, $KOKH=0,170$, $NSE=0,971$, $OI=0,955$, $OMH=0,111$ ve $R^2=0,972$) göre en üstün sonuçları bağımsız UKSB tahmin modeli vermiştir. Tablo 3.14'ten görüleceği üzere UKSB derin öğrenme yöntemine ait bağımsız ya da hibrit tüm modeller, diğer yöntemlere ait modellere göre SYİ kuraklık değerlerinin tahmininde daha başarılıdır. Ayrıca eğitme sonuçları da irdelenecek olursa UKSB yöntemine ait tüm modellerin eğitme başarısı oldukça üstündür. Bu zaman ölçeğinde VMA-USBÇS, VMA-YSA, VMA-GSR ve VMA-DVMR hibrit tahmin modellerinin başarıları da yüksek olup UKSB tahmin modellerine yakın bir performans göstermişlerdir. Bu nedenle VMA ön işleme tekniğinin diğer ADD ve AMA tekniklerine göre kuraklık zaman serilerini ayrıştırmada daha başarılı olduğu rahatlıkla söylenebilir. Ayrıca YSA, USBÇS, GSR ve DVMR yöntemlerine ait bağımsız modellere ait hem eğitme hem de test sonuçlarının oldukça düşük kaldığı görülmüştür.

Tablo 3.15'te görüleceği üzere, Sakarya istasyonu SYİ-3 zaman ölçeğinde tahmin modelleri test sonuçlarına ait performans kriterlerine ($OKH=0,057$, $KOKH=0,239$, $NSE=0,954$, $OI=0,956$, $OMH=0,166$ ve $R^2=0,962$) göre; VMA-UKSB hibrit tahmin modelinde en üstün sonuçlar elde edilmiştir. SYİ-1 zaman ölçeğinde olduğu gibi UKSB derin öğrenme yöntemine ait tüm modellerin yine oldukça başarılı sonuçlar verdiği görülmüştür. Yine SYİ-1'de olduğu gibi VMA-USBÇS, VMA-YSA, VMA-GSR hibrit tahmin modellerine ait test sonuçları da oldukça başarılıdır. Burada da YSA, USBÇS, GSR ve DVMR yöntemlerine ait bağımsız modellerin tahmin performanslarının oldukça zayıf olduğu görülmüştür.

Tablo 3.16'da verilen Sakarya istasyonu SYİ-6 zaman ölçeği tahmin modelleri test sonuçlarına ait performans kriterlerine ($OKH=0,096$, $KOKH=0,310$, $NSE=0,924$, $OI=0,934$, $OMH=0,229$ ve $R^2=0,952$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Bunun yanı sıra ADD-YSA hibrit tahmin modelinin test sonuçları, bağımsız UKSB tahmin modeline oldukça yakın sonuçlar vermiş olup $NSE=0,940$ ve $OI=0,948$ performans kriterlerinde bağımsız UKSB modelinden daha üstündür. Bu zaman ölçeğinde ADD-YSA ve ADD-GSR hibrit tahmin modellerinin performansları da oldukça tatmin edicidir. Burada, SYİ-1 ve SYİ-3 zaman ölçeklerinden farklı olarak ADD ve AMA'lı UKSB hibrit modellerinin tahmin başarısı ise beklenene göre düşük

kalmıştır. Diğer zaman ölçeklerinde olduğu gibi burada da YSA, USBÇS, GSR ve DVMR yöntemlerine ait bağımsız modellerin tahmin performanslarının oldukça zayıf olduğu görülmektedir.

Tablo 3.17’de görüleceği üzere, Sakarya istasyonu SYİ-12 zaman ölçeği tahmin modelleri test sonuçlarına ait performans kriterlerine ($OKH=0,114$, $KOKH=0,338$, $NSE=0,932$, $OI=0,929$, $OMH=0,265$ ve $R^2=0,959$) göre; VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Ayrıca yine UKSB yöntemine ait tüm bağımsız ve hibrit modellerin tahmin performanları oldukça başarılıdır. Bu zaman ölçeğinde; VMA’nın dâhil olduğu VMA-YSA, VMA-USBÇS ve VMA-GSR hibrit modellerin tahmin performansları yine oldukça iyi durumdadır. VMA-DVMR hibrit tahmin modelinde, $R^2=0,891$ değeri hariç diğer performans kriterlerinde iyileştirme sağlanamamıştır. Diğer tüm zaman ölçeklerinde olduğu gibi UKSB derin öğrenme modeli hariç olmak üzere bağımsız makine öğrenmesi yöntemlerinde oldukça zayıf tahmin performansları elde edilmiştir.

Tablo 3.14 ile 3.17 arasında verilen Sakarya SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 zaman ölçeklerine ait tahmin modeli performanslarının bütününe bakıldığında genel olarak benzer sonuçlar alındığı görülmüş olup örnek olması açısından detaylıca değerlendirmesi yapılmıştır. Bundan sonra ele alınacak olan istasyonlara ait tahmin model sonuçlarında yalnızca üstün olan modele ait test sonuçları için performans kriterleri değerleri belirtilecektir. Tablo 3.18–3.21 arasında Ankara istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.18. Ankara istasyonu SYİ-1 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.889	0.943	0.086	0.476	0.743	0.114	1.428	1.195	-0.556	0.118	0.888	0.004
ADD-USBÇS	0.929	0.964	0.044	0.454	0.765	0.618	0.135	0.367	0.853	0.895	0.295	0.854
AMA-USBÇS	0.215	0.464	0.779	0.856	0.370	0.885	0.204	0.451	0.778	0.850	0.352	0.793
VMA-USBÇS	1.259	1.122	-0.296	0.273	0.929	0.573	0.253	0.503	0.724	0.818	0.408	0.804
YSA	1.005	1.002	-0.034	0.412	0.811	0.001	0.960	0.980	-0.046	0.392	0.779	0.016
ADD-YSA	0.134	0.367	0.862	0.905	0.296	0.863	0.132	0.363	0.856	0.897	0.287	0.857
AMA-YSA	0.241	0.491	0.752	0.841	0.392	0.790	0.203	0.450	0.779	0.850	0.352	0.796
VMA-YSA	0.097	0.312	0.900	0.928	0.253	0.900	0.085	0.291	0.908	0.928	0.232	0.908
GSR	0.972	0.986	0.000	0.430	0.796	0.000	0.924	0.961	-0.006	0.413	0.764	0.000
ADD-GSR	0.130	0.361	0.866	0.908	0.293	0.866	0.130	0.360	0.859	0.898	0.288	0.859
AMA-GSR	0.254	0.504	0.739	0.834	0.402	0.827	0.197	0.444	0.785	0.854	0.351	0.815
VMA-GSR	0.096	0.309	0.902	0.929	0.250	0.902	0.087	0.296	0.905	0.927	0.236	0.905
DVMR	0.795	0.892	0.182	0.528	0.666	0.188	0.976	0.988	-0.063	0.382	0.786	0.007
ADD-DVMR	0.135	0.368	0.861	0.904	0.297	0.861	0.143	0.378	0.845	0.889	0.297	0.853
AMA-DVMR	0.274	0.524	0.718	0.822	0.420	0.843	0.244	0.494	0.735	0.824	0.390	0.838
VMA-DVMR	0.096	0.309	0.902	0.929	0.248	0.902	0.130	0.361	0.858	0.898	0.288	0.869
UKSB	0.007	0.085	0.993	0.990	0.065	0.995	0.036	0.189	0.961	0.964	0.147	0.977
ADD-UKSB	0.009	0.095	0.991	0.989	0.076	0.994	0.039	0.198	0.957	0.961	0.122	0.958
AMA-UKSB	0.012	0.108	0.988	0.986	0.088	0.994	0.045	0.212	0.951	0.957	0.174	0.975
VMA-UKSB	0.004	0.065	0.996	0.993	0.050	0.996	0.067	0.259	0.927	0.941	0.208	0.934

Tablo 3.19. Ankara istasyonu SYİ-3 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.858	0.926	0.127	0.477	0.722	0.182	1.695	1.302	-0.671	0.023	1.074	0.122
ADD-USBÇS	0.942	0.970	0.041	0.430	0.769	0.654	0.107	0.327	0.902	0.919	0.263	0.906
AMA-USBÇS	0.181	0.426	0.816	0.868	0.314	0.912	0.254	0.504	0.767	0.835	0.393	0.879
VMA-USBÇS	0.874	0.935	0.110	0.468	0.806	0.785	0.113	0.336	0.896	0.916	0.259	0.913
YSA	0.900	0.949	0.083	0.453	0.752	0.083	1.204	1.097	-0.187	0.287	0.893	0.069
ADD-YSA	0.111	0.333	0.887	0.913	0.269	0.889	0.120	0.346	0.890	0.911	0.283	0.894
AMA-YSA	0.248	0.498	0.747	0.827	0.402	0.848	0.242	0.492	0.778	0.841	0.388	0.869
VMA-YSA	0.487	0.698	0.504	0.687	0.620	0.894	0.132	0.363	0.879	0.905	0.283	0.927
GSR	0.788	0.888	0.198	0.516	0.711	0.352	1.238	1.113	-0.220	0.269	0.922	0.126
ADD-GSR	0.115	0.339	0.883	0.910	0.274	0.884	0.125	0.353	0.886	0.909	0.291	0.890
AMA-GSR	0.296	0.544	0.698	0.798	0.429	0.872	0.305	0.552	0.721	0.807	0.428	0.894
VMA-GSR	0.495	0.704	0.496	0.682	0.627	0.900	0.126	0.355	0.884	0.908	0.277	0.924
DVMR	0.616	0.785	0.373	0.613	0.514	0.375	1.775	1.332	-0.750	-0.020	1.083	0.122
ADD-DVMR	0.118	0.343	0.880	0.908	0.273	0.881	0.162	0.403	0.851	0.887	0.333	0.877
AMA-DVMR	0.334	0.578	0.660	0.776	0.452	0.877	0.320	0.566	0.706	0.798	0.397	0.899
VMA-DVMR	0.512	0.716	0.478	0.672	0.625	0.921	0.114	0.337	0.896	0.915	0.251	0.900
UKSB	0.005	0.071	0.995	0.991	0.056	0.996	0.067	0.260	0.938	0.944	0.227	0.967
ADD-UKSB	0.011	0.105	0.989	0.985	0.083	0.991	0.097	0.311	0.911	0.926	0.232	0.937
AMA-UKSB	0.012	0.109	0.988	0.984	0.086	0.993	0.073	0.270	0.933	0.941	0.177	0.939
VMA-UKSB	0.009	0.093	0.991	0.987	0.080	0.997	0.097	0.311	0.911	0.925	0.267	0.955

Tablo 3.20. Ankara istasyonu SYİ-6 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.543	0.737	0.420	0.635	0.470	0.613	1.334	1.155	0.019	0.400	0.893	0.034
ADD-USBÇS	0.959	0.979	-0.057	0.372	0.813	0.704	0.163	0.403	0.880	0.902	0.341	0.881
AMA-USBÇS	0.144	0.380	0.841	0.882	0.307	0.926	0.358	0.599	0.736	0.812	0.507	0.882
VMA-USBÇS	0.964	0.982	-0.063	0.369	0.834	0.645	0.221	0.470	0.838	0.874	0.390	0.842
YSA	0.817	0.904	0.127	0.472	0.701	0.131	1.380	1.175	-0.015	0.381	0.917	0.081
ADD-YSA	0.109	0.330	0.880	0.906	0.261	0.885	0.143	0.379	0.895	0.911	0.294	0.896
AMA-YSA	0.165	0.407	0.818	0.868	0.341	0.888	0.212	0.460	0.844	0.878	0.408	0.864
VMA-YSA	0.137	0.370	0.849	0.887	0.287	0.850	0.217	0.466	0.840	0.876	0.376	0.845
GSR	0.821	0.906	0.123	0.470	0.702	0.433	1.428	1.195	-0.050	0.362	0.900	0.088
ADD-GSR	0.120	0.347	0.868	0.899	0.280	0.871	0.144	0.379	0.894	0.911	0.312	0.895
AMA-GSR	0.181	0.425	0.801	0.857	0.354	0.896	0.220	0.469	0.838	0.875	0.423	0.846
VMA-GSR	0.154	0.392	0.831	0.876	0.304	0.831	0.207	0.455	0.848	0.881	0.345	0.851
DVMR	0.797	0.893	0.148	0.484	0.631	0.162	1.392	1.180	-0.024	0.376	0.898	0.005
ADD-DVMR	0.342	0.584	0.623	0.752	0.461	0.864	0.248	0.498	0.818	0.862	0.410	0.854
AMA-DVMR	0.200	0.447	0.779	0.844	0.366	0.887	0.276	0.525	0.797	0.849	0.434	0.916
VMA-DVMR	0.119	0.346	0.868	0.899	0.251	0.871	0.202	0.449	0.852	0.883	0.337	0.853
UKSB	0.002	0.044	0.998	0.995	0.034	0.999	0.215	0.464	0.842	0.877	0.263	0.865
ADD-UKSB	0.009	0.093	0.990	0.986	0.076	0.994	0.185	0.430	0.864	0.891	0.330	0.906
AMA-UKSB	0.032	0.179	0.965	0.964	0.161	0.993	0.241	0.491	0.823	0.865	0.407	0.925
VMA-UKSB	0.025	0.159	0.972	0.970	0.122	0.973	0.095	0.308	0.930	0.936	0.228	0.948

Tablo 3.21. Ankara istasyonu SYİ-12 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.785	0.886	0.229	0.519	0.622	0.474	1.635	1.279	-0.695	-0.028	1.108	0.135
ADD-USBÇS	1.160	1.077	-0.140	0.314	0.920	0.400	0.484	0.696	0.498	0.651	0.545	0.566
AMA-USBÇS	0.958	0.979	0.059	0.424	0.771	0.657	0.386	0.622	0.600	0.712	0.505	0.727
VMA-USBÇS	1.172	1.083	-0.152	0.308	0.917	0.738	0.097	0.311	0.900	0.906	0.215	0.920
YSA	0.877	0.937	0.138	0.468	0.738	0.144	0.969	0.984	-0.005	0.359	0.813	0.335
ADD-YSA	0.270	0.520	0.735	0.811	0.392	0.735	0.355	0.596	0.632	0.732	0.448	0.782
AMA-YSA	0.316	0.562	0.690	0.784	0.459	0.696	0.396	0.629	0.590	0.706	0.513	0.670
VMA-YSA	0.047	0.217	0.954	0.954	0.173	0.965	0.040	0.201	0.958	0.951	0.158	0.966
GSR	1.018	1.009	0.000	0.391	0.805	0.706	1.169	1.081	-0.212	0.241	0.925	0.251
ADD-GSR	0.115	0.340	0.887	0.907	0.266	0.887	0.262	0.512	0.728	0.792	0.409	0.794
AMA-GSR	0.305	0.552	0.701	0.791	0.460	0.705	0.361	0.600	0.626	0.728	0.497	0.735
VMA-GSR	0.021	0.145	0.979	0.974	0.115	0.982	0.059	0.243	0.939	0.935	0.151	0.964
DVMR	0.485	0.697	0.523	0.687	0.438	0.628	1.093	1.045	-0.133	0.286	0.772	0.192
ADD-DVMR	0.287	0.536	0.718	0.801	0.424	0.721	0.370	0.608	0.616	0.722	0.537	0.718
AMA-DVMR	0.309	0.556	0.696	0.788	0.464	0.700	0.375	0.613	0.611	0.719	0.502	0.661
VMA-DVMR	0.074	0.271	0.928	0.935	0.190	0.942	0.341	0.584	0.647	0.741	0.459	0.870
UKSB	0.001	0.033	0.999	0.996	0.025	0.999	0.069	0.262	0.929	0.927	0.229	0.931
ADD-UKSB	0.010	0.101	0.990	0.984	0.081	0.992	0.140	0.374	0.855	0.875	0.312	0.925
AMA-UKSB	0.030	0.174	0.970	0.967	0.137	0.976	0.147	0.383	0.848	0.870	0.312	0.908
VMA-UKSB	0.015	0.121	0.986	0.980	0.106	0.996	0.036	0.190	0.963	0.954	0.125	0.977

Tablo 3.18’de görüleceği üzere, Ankara istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,036, KOKH=0,189, NSE=0,961, OI=0,964, OMH=0,147 ve $R^2=0,977$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.19’da verilen Ankara istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,067, KOKH=0,260, NSE=0,938, OI=0,944, OMH=0,227 ve $R^2=0,967$) göre; yine bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.20’de verilen Ankara istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,095, KOKH=0,308, NSE=0,930, OI=0,936, OMH=0,228 ve $R^2=0,948$) göre; VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Tablo 3.21’de görüleceği üzere Ankara istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,036, KOKH=0,190, NSE=0,963, OI=0,954, OMH=0,125 ve $R^2=0,977$) göre; yine VMA-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Tablo 3.22–3.25 arasında Kütahya istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.22. Kütahya istasyonu SYİ-1 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R^2	OKH	KOKH	NSE	OI	OMH	R^2
USBÇS	0.812	0.901	0.110	0.476	0.707	0.140	1.241	1.114	-0.129	0.347	0.886	0.016
ADD-USBÇS	0.863	0.929	0.053	0.445	0.736	0.603	0.162	0.403	0.853	0.894	0.325	0.853
AMA-USBÇS	0.186	0.431	0.797	0.861	0.338	0.904	0.287	0.536	0.739	0.827	0.420	0.843
VMA-USBÇS	0.983	0.992	-0.078	0.374	0.801	0.645	0.111	0.333	0.900	0.923	0.266	0.900
YSA	0.862	0.929	0.054	0.446	0.739	0.054	1.082	1.040	0.017	0.426	0.824	0.017
ADD-YSA	0.135	0.368	0.852	0.894	0.290	0.852	0.156	0.395	0.858	0.897	0.322	0.858
AMA-YSA	0.241	0.491	0.736	0.825	0.379	0.858	0.305	0.552	0.723	0.818	0.436	0.854
VMA-YSA	0.094	0.306	0.897	0.922	0.247	0.898	0.108	0.328	0.902	0.925	0.264	0.903
GSR	0.839	0.916	0.080	0.460	0.730	0.122	1.149	1.072	-0.045	0.392	0.851	0.011
ADD-GSR	0.122	0.350	0.866	0.902	0.276	0.866	0.161	0.402	0.854	0.895	0.325	0.855
AMA-GSR	0.240	0.490	0.737	0.826	0.379	0.855	0.281	0.531	0.744	0.830	0.417	0.839
VMA-GSR	0.093	0.306	0.898	0.922	0.247	0.898	0.113	0.336	0.898	0.922	0.271	0.898
DVMR	0.746	0.864	0.182	0.515	0.644	0.193	1.298	1.139	-0.180	0.319	0.900	0.016
ADD-DVMR	0.142	0.376	0.845	0.889	0.294	0.847	0.166	0.407	0.849	0.892	0.327	0.851
AMA-DVMR	0.284	0.533	0.688	0.798	0.414	0.874	0.291	0.539	0.736	0.825	0.427	0.869
VMA-DVMR	0.090	0.299	0.902	0.925	0.240	0.902	0.126	0.355	0.885	0.914	0.285	0.894
UKSB	0.005	0.073	0.994	0.991	0.056	0.996	0.036	0.190	0.967	0.969	0.109	0.979
ADD-UKSB	0.006	0.078	0.993	0.990	0.062	0.994	0.037	0.193	0.966	0.968	0.142	0.976
AMA-UKSB	0.019	0.138	0.979	0.978	0.121	0.994	0.052	0.228	0.953	0.958	0.164	0.975
VMA-UKSB	0.004	0.066	0.995	0.992	0.052	0.996	0.036	0.190	0.967	0.968	0.149	0.977

Tablo 3.23. Kütahya istasyonu SYİ-3 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.844	0.919	0.089	0.460	0.721	0.117	1.944	1.394	-0.858	-0.098	0.969	0.063
ADD-USBÇS	0.905	0.952	0.003	0.414	0.768	0.604	0.191	0.437	0.847	0.886	0.348	0.848
AMA-USBÇS	0.281	0.530	0.691	0.796	0.402	0.823	0.282	0.531	0.775	0.842	0.404	0.819
VMA-USBÇS	1.036	1.018	-0.140	0.336	0.836	0.685	0.109	0.330	0.913	0.928	0.235	0.917
YSA	0.793	0.890	0.128	0.482	0.692	0.129	1.463	1.210	-0.399	0.154	0.945	0.372
ADD-YSA	0.123	0.351	0.864	0.900	0.284	0.865	0.186	0.431	0.852	0.889	0.347	0.853
AMA-YSA	0.195	0.442	0.785	0.852	0.350	0.845	0.283	0.532	0.774	0.841	0.398	0.828
VMA-YSA	0.054	0.233	0.940	0.949	0.181	0.943	0.050	0.223	0.960	0.961	0.179	0.963
GSR	0.909	0.953	0.000	0.412	0.749	0.050	1.253	1.120	-0.003	0.402	0.880	0.024
ADD-GSR	0.123	0.351	0.865	0.900	0.281	0.865	0.187	0.432	0.851	0.888	0.339	0.851
AMA-GSR	0.191	0.438	0.789	0.854	0.345	0.826	0.282	0.531	0.774	0.841	0.401	0.807
VMA-GSR	0.050	0.225	0.945	0.952	0.174	0.945	0.061	0.248	0.951	0.954	0.191	0.953
DVMR	0.696	0.835	0.249	0.548	0.580	0.279	1.313	1.146	-0.051	0.375	0.944	0.007
ADD-DVMR	0.126	0.355	0.862	0.898	0.282	0.862	0.247	0.497	0.802	0.858	0.380	0.831
AMA-DVMR	0.203	0.451	0.776	0.847	0.358	0.857	0.291	0.540	0.767	0.837	0.404	0.841
VMA-DVMR	0.054	0.233	0.940	0.949	0.179	0.941	0.130	0.360	0.896	0.917	0.286	0.932
UKSB	0.013	0.116	0.985	0.982	0.103	0.996	0.115	0.339	0.908	0.925	0.177	0.933
ADD-UKSB	0.009	0.093	0.991	0.987	0.072	0.991	0.119	0.345	0.905	0.922	0.252	0.927
AMA-UKSB	0.016	0.125	0.983	0.980	0.100	0.984	0.102	0.319	0.918	0.932	0.228	0.927
VMA-UKSB	0.026	0.161	0.971	0.971	0.124	0.976	0.034	0.184	0.973	0.971	0.150	0.978

Tablo 3.24. Kütahya istasyonu SYİ-6 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.855	0.925	0.084	0.466	0.710	0.111	1.754	1.324	-0.419	0.140	0.953	0.016
ADD-USBÇS	0.976	0.988	-0.045	0.396	0.824	0.724	0.117	0.343	0.905	0.914	0.255	0.913
AMA-USBÇS	0.308	0.555	0.670	0.789	0.443	0.836	0.212	0.461	0.828	0.862	0.373	0.828
VMA-USBÇS	0.960	0.980	-0.028	0.405	0.804	0.658	0.244	0.494	0.803	0.845	0.405	0.812
YSA	0.879	0.937	0.059	0.452	0.715	0.059	1.172	1.083	0.052	0.403	0.840	0.075
ADD-YSA	0.141	0.376	0.849	0.893	0.307	0.878	0.146	0.382	0.882	0.898	0.303	0.916
AMA-YSA	0.281	0.530	0.700	0.806	0.423	0.855	0.197	0.444	0.840	0.870	0.358	0.841
VMA-YSA	0.121	0.348	0.871	0.907	0.265	0.871	0.184	0.429	0.852	0.877	0.361	0.858
GSR	0.934	0.966	0.000	0.420	0.744	0.132	1.238	1.112	-0.001	0.373	0.866	0.057
ADD-GSR	0.120	0.347	0.871	0.907	0.264	0.872	0.107	0.327	0.914	0.920	0.258	0.917
AMA-GSR	0.322	0.567	0.655	0.781	0.452	0.826	0.222	0.471	0.821	0.857	0.381	0.821
VMA-GSR	0.114	0.338	0.878	0.911	0.270	0.886	0.198	0.445	0.840	0.869	0.354	0.847
DVMR	0.909	0.953	0.027	0.435	0.663	0.067	1.099	1.048	0.111	0.437	0.872	0.138
ADD-DVMR	0.123	0.350	0.869	0.905	0.262	0.870	0.122	0.349	0.902	0.911	0.269	0.905
AMA-DVMR	0.266	0.516	0.715	0.815	0.412	0.863	0.189	0.434	0.847	0.874	0.349	0.848
VMA-DVMR	0.114	0.337	0.878	0.911	0.269	0.892	0.199	0.446	0.839	0.869	0.340	0.845
UKSB	0.000	0.018	1.000	0.998	0.013	1.000	0.103	0.321	0.917	0.922	0.236	0.936
ADD-UKSB	0.021	0.145	0.977	0.977	0.115	0.982	0.104	0.323	0.916	0.921	0.199	0.920
AMA-UKSB	0.056	0.236	0.940	0.951	0.066	0.941	0.109	0.331	0.912	0.918	0.234	0.917
VMA-UKSB	0.028	0.167	0.970	0.971	0.135	0.980	0.109	0.330	0.912	0.919	0.215	0.939

Tablo 3.25. Kütahya istasyonu SYİ-12 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.786	0.887	0.075	0.417	0.735	0.122	1.269	1.126	0.092	0.401	0.970	0.106
ADD-USBÇS	0.901	0.949	-0.059	0.341	0.805	0.608	0.345	0.587	0.753	0.801	0.420	0.772
AMA-USBÇS	0.493	0.702	0.421	0.615	0.578	0.640	0.418	0.647	0.701	0.767	0.579	0.731
VMA-USBÇS	1.033	1.016	-0.215	0.255	0.838	0.746	0.127	0.357	0.909	0.909	0.299	0.914
YSA	0.651	0.807	0.235	0.508	0.616	0.235	1.020	1.010	0.270	0.505	0.859	0.352
ADD-YSA	0.167	0.409	0.804	0.846	0.314	0.811	0.330	0.574	0.764	0.808	0.439	0.795
AMA-YSA	0.279	0.528	0.672	0.764	0.448	0.726	0.417	0.646	0.702	0.768	0.566	0.716
VMA-YSA	0.069	0.262	0.919	0.924	0.224	0.926	0.267	0.517	0.809	0.838	0.447	0.890
GSR	0.345	0.587	0.594	0.717	0.485	0.782	1.007	1.004	0.279	0.511	0.905	0.382
ADD-GSR	0.156	0.395	0.817	0.855	0.308	0.823	0.251	0.501	0.821	0.846	0.412	0.836
AMA-GSR	0.276	0.525	0.676	0.766	0.444	0.731	0.393	0.627	0.719	0.779	0.550	0.744
VMA-GSR	0.043	0.207	0.950	0.947	0.168	0.957	0.159	0.398	0.886	0.892	0.331	0.928
DVMR	0.428	0.655	0.496	0.659	0.430	0.531	0.829	0.911	0.407	0.586	0.817	0.423
ADD-DVMR	0.190	0.436	0.777	0.829	0.354	0.789	0.350	0.592	0.750	0.799	0.435	0.779
AMA-DVMR	0.304	0.552	0.642	0.746	0.474	0.685	0.479	0.692	0.657	0.740	0.592	0.662
VMA-DVMR	0.063	0.251	0.926	0.929	0.190	0.936	0.209	0.457	0.851	0.867	0.405	0.907
UKSB	0.010	0.099	0.988	0.981	0.087	0.996	0.198	0.445	0.858	0.872	0.386	0.936
ADD-UKSB	0.003	0.055	0.997	0.991	0.044	0.997	0.173	0.416	0.876	0.885	0.350	0.918
AMA-UKSB	0.006	0.077	0.993	0.986	0.070	0.999	0.281	0.530	0.799	0.832	0.433	0.924
VMA-UKSB	0.004	0.066	0.995	0.989	0.051	0.996	0.110	0.331	0.921	0.918	0.288	0.941

Tablo 3.22’de görüleceği üzere, Kütahya istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,036, KOKH=0,190, NSE=0,967, OI=0,969, OMH=0,109 ve R²=0,979) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.23’te verilen Kütahya istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,034, KOKH=0,184, NSE=0,973, OI=0,971, OMH=0,150 ve R²=0,978) göre; VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Tablo 3.24’te verilen Kütahya istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,103, KOKH=0,321, NSE=0,917, OI=0,922, OMH=0,236 ve R²=0,936) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.25’te görüleceği üzere Kütahya istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,110, KOKH=0,331, NSE=0,921, OI=0,918, OMH=0,288 ve R²=0,941) göre ise VMA-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Tablo 3.26–3.29 arasında Emirdağ istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.26. Emirdağ istasyonu SYİ-1 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.819	0.905	0.126	0.493	0.704	0.160	1.876	1.370	-0.834	-0.055	1.076	0.002
ADD-USBÇS	0.919	0.959	0.018	0.435	0.737	0.582	0.190	0.435	0.815	0.863	0.344	0.826
AMA-USBÇS	0.216	0.465	0.769	0.849	0.381	0.899	0.265	0.514	0.741	0.819	0.420	0.831
VMA-USBÇS	1.161	1.078	-0.240	0.297	0.878	0.573	0.167	0.409	0.837	0.877	0.318	0.840
YSA	0.881	0.939	0.060	0.458	0.755	0.061	1.119	1.058	-0.094	0.347	0.868	0.007
ADD-YSA	0.115	0.339	0.878	0.913	0.269	0.878	0.179	0.423	0.825	0.870	0.334	0.833
AMA-YSA	0.291	0.539	0.690	0.803	0.431	0.848	0.267	0.517	0.739	0.818	0.422	0.820
VMA-YSA	0.140	0.374	0.851	0.897	0.295	0.854	0.159	0.399	0.845	0.882	0.308	0.847
GSR	0.788	0.888	0.159	0.511	0.704	0.245	1.012	1.006	0.011	0.404	0.824	0.025
ADD-GSR	0.113	0.337	0.879	0.914	0.267	0.880	0.190	0.436	0.814	0.863	0.347	0.826
AMA-GSR	0.304	0.552	0.675	0.795	0.440	0.854	0.279	0.528	0.728	0.811	0.438	0.843
VMA-GSR	0.140	0.374	0.850	0.896	0.295	0.853	0.156	0.395	0.848	0.884	0.305	0.850
DVMR	0.740	0.860	0.210	0.539	0.638	0.235	1.123	1.060	-0.098	0.344	0.869	0.007
ADD-DVMR	0.113	0.336	0.880	0.914	0.262	0.880	0.198	0.445	0.806	0.858	0.362	0.822
AMA-DVMR	0.332	0.577	0.645	0.778	0.462	0.856	0.272	0.522	0.734	0.814	0.435	0.828
VMA-DVMR	0.139	0.373	0.851	0.897	0.294	0.854	0.177	0.421	0.827	0.871	0.333	0.838
UKSB	0.075	0.274	0.920	0.939	0.255	0.986	0.064	0.253	0.937	0.943	0.198	0.962
ADD-UKSB	0.020	0.142	0.979	0.978	0.115	0.988	0.071	0.267	0.931	0.938	0.217	0.966
AMA-UKSB	0.013	0.112	0.987	0.985	0.093	0.994	0.075	0.274	0.927	0.936	0.207	0.965
VMA-UKSB	0.011	0.103	0.989	0.987	0.086	0.995	0.040	0.199	0.961	0.961	0.158	0.962

Tablo 3.27. Emirdağ istasyonu SYİ-3 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.960	0.980	0.072	0.450	0.766	0.102	1.381	1.175	-0.475	0.126	0.943	0.083
ADD-USBÇS	0.962	0.981	0.070	0.448	0.765	0.596	0.134	0.367	0.856	0.886	0.297	0.866
AMA-USBÇS	0.348	0.590	0.664	0.780	0.463	0.796	0.235	0.485	0.749	0.818	0.410	0.760
VMA-USBÇS	1.182	1.087	-0.143	0.333	0.881	0.685	0.191	0.437	0.796	0.847	0.330	0.817
YSA	1.082	1.040	-0.046	0.385	0.847	0.008	1.009	1.004	-0.077	0.345	0.837	0.095
ADD-YSA	0.165	0.406	0.841	0.885	0.320	0.842	0.136	0.369	0.855	0.885	0.307	0.864
AMA-YSA	0.327	0.572	0.684	0.791	0.448	0.811	0.219	0.468	0.766	0.829	0.390	0.789
VMA-YSA	0.085	0.291	0.918	0.934	0.239	0.921	0.065	0.254	0.931	0.936	0.202	0.948
GSR	1.034	1.017	0.000	0.410	0.820	0.060	0.951	0.975	-0.016	0.379	0.767	0.041
ADD-GSR	0.155	0.394	0.850	0.890	0.315	0.850	0.139	0.373	0.852	0.883	0.304	0.861
AMA-GSR	0.314	0.561	0.696	0.799	0.440	0.820	0.215	0.464	0.770	0.831	0.384	0.802
VMA-GSR	0.040	0.199	0.962	0.963	0.158	0.967	0.074	0.272	0.921	0.929	0.218	0.938
DVMR	0.952	0.976	0.079	0.454	0.728	0.096	1.071	1.035	-0.144	0.308	0.842	0.005
ADD-DVMR	0.145	0.381	0.860	0.896	0.293	0.860	0.124	0.352	0.868	0.893	0.262	0.871
AMA-DVMR	0.303	0.551	0.707	0.805	0.433	0.828	0.217	0.466	0.768	0.830	0.388	0.793
VMA-DVMR	0.081	0.285	0.921	0.936	0.226	0.922	0.059	0.242	0.937	0.941	0.194	0.948
UKSB	0.002	0.044	0.998	0.995	0.036	0.999	0.040	0.200	0.957	0.956	0.162	0.982
ADD-UKSB	0.010	0.098	0.991	0.987	0.080	0.991	0.090	0.300	0.904	0.917	0.246	0.936
AMA-UKSB	0.006	0.074	0.995	0.991	0.060	0.996	0.049	0.221	0.948	0.948	0.169	0.969
VMA-UKSB	0.037	0.193	0.964	0.965	0.183	0.996	0.089	0.299	0.905	0.918	0.239	0.934

Tablo 3.28. Emirdağ istasyonu SYİ-6 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.917	0.958	0.109	0.464	0.739	0.150	1.095	1.047	-0.070	0.329	0.854	0.123
ADD-USBÇS	0.987	0.993	0.042	0.427	0.779	0.670	0.293	0.541	0.714	0.787	0.457	0.723
AMA-USBÇS	0.304	0.551	0.705	0.800	0.440	0.714	0.275	0.524	0.731	0.798	0.429	0.736
VMA-USBÇS	0.303	0.551	0.706	0.801	0.444	0.834	0.202	0.449	0.803	0.843	0.361	0.848
YSA	1.021	1.011	0.008	0.409	0.784	0.011	1.192	1.092	-0.164	0.277	0.831	0.166
ADD-YSA	0.119	0.345	0.884	0.910	0.265	0.885	0.249	0.499	0.757	0.814	0.416	0.761
AMA-YSA	0.279	0.529	0.729	0.815	0.409	0.750	0.249	0.499	0.757	0.814	0.411	0.757
VMA-YSA	0.219	0.468	0.788	0.850	0.380	0.856	0.188	0.434	0.816	0.852	0.334	0.852
GSR	1.030	1.015	0.000	0.404	0.781	0.116	1.025	1.012	-0.001	0.368	0.781	0.101
ADD-GSR	0.121	0.347	0.883	0.909	0.272	0.883	0.238	0.488	0.767	0.820	0.414	0.773
AMA-GSR	0.295	0.543	0.713	0.805	0.429	0.727	0.264	0.514	0.742	0.804	0.427	0.742
VMA-GSR	0.192	0.439	0.813	0.865	0.353	0.870	0.186	0.432	0.818	0.853	0.337	0.856
DVMR	0.642	0.801	0.377	0.613	0.503	0.424	0.926	0.962	0.096	0.423	0.749	0.108
ADD-DVMR	0.112	0.335	0.891	0.914	0.250	0.893	0.213	0.462	0.792	0.836	0.405	0.810
AMA-DVMR	0.299	0.547	0.709	0.803	0.433	0.722	0.294	0.542	0.713	0.786	0.454	0.714
VMA-DVMR	0.192	0.438	0.814	0.865	0.338	0.874	0.228	0.478	0.777	0.827	0.387	0.804
UKSB	0.006	0.080	0.994	0.989	0.069	0.997	0.107	0.327	0.896	0.906	0.230	0.903
ADD-UKSB	0.011	0.106	0.989	0.985	0.083	0.990	0.110	0.331	0.893	0.904	0.271	0.902
AMA-UKSB	0.008	0.091	0.992	0.987	0.083	0.997	0.177	0.421	0.827	0.859	0.333	0.836
VMA-UKSB	0.038	0.194	0.963	0.963	0.182	0.996	0.164	0.404	0.840	0.868	0.315	0.884

Tablo 3.29. Emirdağ istasyonu SYİ-12 tahmin model performanslarının karşılaştırması

Modeller	EĞİTME						TEST					
	OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
USBÇS	0.984	0.992	0.107	0.433	0.798	0.145	0.822	0.907	-0.044	0.321	0.792	0.013
ADD-USBÇS	1.003	1.001	0.090	0.424	0.760	0.551	0.390	0.625	0.504	0.644	0.521	0.721
AMA-USBÇS	0.507	0.712	0.540	0.683	0.538	0.620	0.244	0.494	0.690	0.759	0.432	0.732
VMA-USBÇS	0.749	0.866	0.320	0.555	0.728	0.848	0.061	0.246	0.923	0.919	0.182	0.941
YSA	0.880	0.938	0.201	0.487	0.738	0.202	1.030	1.015	-0.309	0.169	0.834	0.206
ADD-YSA	0.179	0.423	0.838	0.868	0.317	0.842	0.145	0.381	0.816	0.842	0.307	0.895
AMA-YSA	0.343	0.585	0.689	0.774	0.476	0.702	0.315	0.562	0.599	0.702	0.439	0.748
VMA-YSA	0.075	0.274	0.932	0.933	0.214	0.956	0.065	0.254	0.918	0.915	0.226	0.938
GSR	0.224	0.473	0.797	0.841	0.367	0.858	0.807	0.899	-0.026	0.331	0.682	0.127
ADD-GSR	0.087	0.295	0.921	0.925	0.231	0.922	0.224	0.474	0.715	0.775	0.380	0.770
AMA-GSR	0.361	0.601	0.672	0.763	0.504	0.682	0.279	0.528	0.646	0.731	0.409	0.677
VMA-GSR	0.049	0.222	0.955	0.951	0.188	0.972	0.042	0.204	0.947	0.938	0.186	0.950
DVMR	0.423	0.650	0.616	0.729	0.451	0.766	1.091	1.045	-0.387	0.125	0.926	0.258
ADD-DVMR	0.269	0.519	0.756	0.815	0.409	0.757	0.281	0.530	0.643	0.730	0.387	0.714
AMA-DVMR	0.220	0.469	0.800	0.843	0.292	0.812	0.283	0.532	0.641	0.728	0.429	0.774
VMA-DVMR	0.040	0.200	0.964	0.958	0.158	0.973	0.045	0.213	0.942	0.934	0.194	0.943
UKSB	0.000	0.003	1.000	1.000	0.001	1.000	0.087	0.295	0.890	0.894	0.259	0.907
ADD-UKSB	0.002	0.044	0.998	0.994	0.034	0.998	0.167	0.408	0.788	0.823	0.349	0.809
AMA-UKSB	0.027	0.164	0.976	0.968	0.130	0.981	0.122	0.349	0.845	0.862	0.286	0.905
VMA-UKSB	0.013	0.115	0.988	0.980	0.103	0.998	0.040	0.200	0.949	0.940	0.152	0.969

Tablo 3.26–3.29 arasında verilen Emirdağ istasyonuna ait tüm zaman ölçekleri için ele alınan tahmin modelleri performans kriterlerine göre değerlendirilmiştir. Tablo 3.26’da görüleceği üzere, Emirdağ istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,040$, $KOKH=0,199$, $NSE=0,961$, $OI=0,961$, $OMH=0,158$ ve $R^2=0,962$) göre; UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Tablo 3.27’de verilen Emirdağ istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,040$, $KOKH=0,200$, $NSE=0,957$, $OI=0,956$, $OMH=0,162$ ve $R^2=0,982$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.28’te verilen Emirdağ istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,107$, $KOKH=0,327$, $NSE=0,896$, $OI=0,906$, $OMH=0,230$ ve $R^2=0,903$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Tablo 3.29’da görüleceği üzere Emirdağ istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,040$, $KOKH=0,200$, $NSE=0,949$, $OI=0,940$, $OMH=0,152$ ve $R^2=0,969$) göre ise VMA-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür.

Sakarya, Ankara, Kütahya ve Emirdağ istasyonlarının tüm zaman ölçeklerine ait model performansları değerlendirildiğinde, bütün bu istasyonlarda UKSB derin öğrenme yöntemine ait bağımsız ya da VMA-UKSB hibrit tahmin modellerinin diğer makine öğrenmesi ve ön işleme tekniklerine göre daha üstün sonuçlar verdiği görülmüştür. Bağımsız ve hibrit UKSB tahmin modelleri ile diğer yöntemlere ait sonuçların genellikle benzer doğrultuda eğitime ve test sonuçları verdiği belirlenmiştir. Ele alınan 10 adet istasyonun 4’ünde elde edilen bu benzer sonuçlardan dolayı kalan diğer 6 adet istasyonun sadece UKSB derin öğrenme yöntemine ait bağımsız ve hibrit modelleri için tahmin çalışmalarına devam edilmiştir. Bolu, Geyve, Ilgın, Polatlı, Sivrihisar ve Yunak istasyonlarının her bir zaman ölçeğindeki UKSB tahmin modelleri sırasıyla verilmiş olup sonuçları değerlendirilmiştir. Tablo 3.30’da Bolu istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.30. Bolu istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
SYİ-1	UKSB	0.011	0.106	0.988	0.986	0.087	0.994	0.016	0.125	0.985	0.982	0.086	0.989
	ADD-UKSB	0.013	0.115	0.986	0.984	0.093	0.992	0.131	0.362	0.872	0.904	0.302	0.916
	AMA-UKSB	0.015	0.122	0.985	0.983	0.105	0.994	0.051	0.225	0.951	0.956	0.173	0.952
	VMA-UKSB	0.008	0.088	0.992	0.989	0.072	0.996	0.048	0.220	0.953	0.957	0.171	0.959
SYİ-3	UKSB	0.004	0.066	0.996	0.992	0.053	0.997	0.103	0.321	0.898	0.909	0.288	0.957
	ADD-UKSB	0.004	0.065	0.996	0.992	0.051	0.996	0.201	0.449	0.801	0.844	0.377	0.874
	AMA-UKSB	0.005	0.070	0.995	0.991	0.055	0.995	0.156	0.395	0.846	0.873	0.333	0.906
	VMA-UKSB	0.044	0.210	0.955	0.958	0.202	0.997	0.127	0.357	0.874	0.892	0.285	0.898
SYİ-6	UKSB	0.050	0.223	0.944	0.947	0.186	0.986	0.516	0.718	0.594	0.703	0.606	0.812
	ADD-UKSB	0.003	0.057	0.996	0.992	0.045	0.997	0.488	0.698	0.616	0.717	0.593	0.855
	AMA-UKSB	0.004	0.066	0.995	0.990	0.051	0.995	0.445	0.667	0.650	0.738	0.547	0.779
	VMA-UKSB	0.006	0.075	0.994	0.989	0.060	0.996	0.428	0.654	0.663	0.746	0.484	0.818
SYİ-12	UKSB	0.000	0.005	1.000	0.999	0.002	1.000	0.584	0.764	0.589	0.688	0.722	0.898
	ADD-UKSB	0.018	0.135	0.977	0.971	0.117	0.993	0.580	0.762	0.591	0.689	0.607	0.850
	AMA-UKSB	0.001	0.028	0.999	0.996	0.023	0.999	0.712	0.844	0.498	0.632	0.684	0.769
	VMA-UKSB	0.007	0.081	0.992	0.985	0.069	0.994	0.478	0.691	0.664	0.736	0.566	0.914

Tablo 3.30'dan görüleceği üzere, Bolu istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,016, KOKH=0,125, NSE=0,985, OI=0,982, OMH=0,086 ve $R^2=0,989$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer tüm modellerin tahmin performansları da oldukça iyidir. Hibrit modeller içerisinde ise yine VMA-UKSB modeli diğer hibrit modellerden üstündür. Bolu istasyonu SYİ-3 zaman ölçeğinde elde edilen tahmin modeli test sonuçları değerlendirildiğinde; performans kriterlerine (OKH=0,103, KOKH=0,321, NSE=0,898, OI=0,909, OMH=0,288 ve $R^2=0,957$) göre en üstün model yine bağımsız UKSB tahmin modelidir. Bu zaman ölçeğinde; yalnızca VMA-UKSB hibrit modelindeki en düşük OMH=0,285 değeri bağımsız UKSB tahmin modelindeki performans kriterlerinden daha iyi bir sonuç vermiştir. Bolu istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,428, KOKH=0,654, NSE=0,663, OI=0,746, OMH=0,484 ve $R^2=0,818$) göre; VMA-UKSB hibrit modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde de ADD-UKSB hibrit modelindeki en yüksek $R^2=0,855$ değeri üstün çıkan model değerinden daha yüksektir. Bolu istasyonu SYİ-12

zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,478, KOKH=0,691, NSE=0,664, OI=0,736, OMH=0,566 ve $R^2=0,914$) göre; VMA-UKSB hibrit modeli en üstün sonuçları vermiştir. Tablo 3.31’de Polatlı istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.31. Polatlı istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OKH	KOKH	NSE	OI	OMH	R^2	OKH	KOKH	NSE	OI	OMH	R^2
SYİ-1	UKSB	0.012	0.111	0.987	0.983	0.098	0.996	0.039	0.199	0.966	0.964	0.146	0.986
	ADD-UKSB	0.007	0.081	0.993	0.989	0.062	0.993	0.054	0.233	0.953	0.955	0.183	0.960
	AMA-UKSB	0.014	0.119	0.985	0.981	0.102	0.995	0.041	0.203	0.964	0.963	0.146	0.974
	VMA-UKSB	0.003	0.057	0.997	0.993	0.043	0.997	0.054	0.233	0.953	0.954	0.175	0.967
SYİ-3	UKSB	0.004	0.059	0.996	0.993	0.049	0.998	0.032	0.178	0.968	0.962	0.138	0.969
	ADD-UKSB	0.010	0.100	0.990	0.987	0.075	0.991	0.039	0.197	0.961	0.956	0.154	0.975
	AMA-UKSB	0.017	0.129	0.983	0.981	0.109	0.994	0.033	0.182	0.967	0.960	0.151	0.968
	VMA-UKSB	0.006	0.075	0.994	0.991	0.060	0.995	0.067	0.259	0.933	0.934	0.198	0.948
SYİ-6	UKSB	0.001	0.034	0.999	0.996	0.025	1.000	0.213	0.462	0.829	0.865	0.357	0.885
	ADD-UKSB	0.052	0.227	0.946	0.953	0.184	0.976	0.132	0.363	0.894	0.908	0.287	0.898
	AMA-UKSB	0.003	0.057	0.997	0.993	0.046	0.997	0.294	0.543	0.764	0.823	0.461	0.899
	VMA-UKSB	0.015	0.121	0.985	0.982	0.104	0.994	0.090	0.300	0.928	0.932	0.231	0.968
SYİ-12	UKSB	0.064	0.253	0.930	0.929	0.233	0.989	0.503	0.709	0.667	0.757	0.581	0.884
	ADD-UKSB	0.004	0.067	0.995	0.988	0.050	0.997	0.523	0.723	0.654	0.749	0.561	0.841
	AMA-UKSB	0.001	0.035	0.999	0.994	0.030	0.999	0.378	0.615	0.750	0.809	0.510	0.850
	VMA-UKSB	0.007	0.083	0.992	0.985	0.067	0.994	0.266	0.516	0.824	0.856	0.412	0.863

Tablo 3.31’den görüleceği üzere, Polatlı istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,039, KOKH=0,199, NSE=0,966, OI=0,964, OMH=0,146 ve $R^2=0,986$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer tüm modellerin tahmin performansları da oldukça iyidir. AMA-UKSB hibrit modelinin performans kriterleri, üstün çıkan bağımsız UKSB tahmin modeline çok yakın olup OMH=0,146 değerinde her iki modelin de aynı sonucu verdiği görülmüştür. Polatlı istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,032, KOKH=0,178, NSE=0,968, OI=0,962, OMH=0,138 ve $R^2=0,969$) göre; bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Yine burada da UKSB yöntemine ait diğer tüm modellerin tahmin performansları oldukça başarılıdır. ADD-UKSB hibrit modelinde elde edilen $R^2=0,975$ değeri ise bağımsız

UKSB hibrit modelin değerinden daha yüksektir. Polatlı istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,090, KOKH=0,300, NSE=0,928, OI=0,932, OMH=0,231 ve $R^2=0,968$) göre; VMA-UKSB hibrit tahmin modelinin en başarılı sonuçları verdiği görülmüştür. Bu zaman ölçeğinde diğer modellerin başarısı beklenenden biraz daha düşük kalmıştır. Polatlı istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,266, KOKH=0,516, NSE=0,824, OI=0,856, OMH=0,412 ve $R^2=0,863$) göre; VMA-UKSB hibrit tahmin modeli en başarılı sonuçları vermiştir. Bağımsız UKSB tahmin modelinde elde edilen $R^2=0,884$ değeri ise bu zaman ölçeğinde en yüksek değer olarak bulunmuştur. Tablo 3.32’de Geyve istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.32. Geyve istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OK H	KOKH	NSE	OI	OMH	R^2	OKH	KOKH	NSE	OI	OMH	R^2
SYİ-1	UKSB	0.012	0.109	0.988	0.984	0.091	0.995	0.057	0.240	0.942	0.954	0.198	0.977
	ADD-UKSB	0.008	0.091	0.992	0.988	0.070	0.992	0.048	0.219	0.952	0.960	0.169	0.973
	AMA-UKSB	0.013	0.112	0.987	0.984	0.085	0.991	0.044	0.210	0.955	0.963	0.154	0.961
	VMA-UKSB	0.004	0.066	0.996	0.992	0.050	0.996	0.032	0.178	0.968	0.972	0.147	0.987
SYİ-3	UKSB	0.003	0.050	0.998	0.995	0.039	0.998	0.111	0.333	0.883	0.902	0.255	0.948
	ADD-UKSB	0.039	0.198	0.962	0.966	0.176	0.991	0.059	0.243	0.938	0.940	0.196	0.948
	AMA-UKSB	0.009	0.094	0.991	0.989	0.073	0.993	0.136	0.369	0.856	0.884	0.305	0.930
	VMA-UKSB	0.026	0.160	0.975	0.975	0.142	0.995	0.083	0.288	0.913	0.922	0.230	0.941
SYİ-6	UKSB	0.001	0.028	0.999	0.997	0.025	1.000	0.106	0.325	0.863	0.884	0.279	0.943
	ADD-UKSB	0.021	0.144	0.980	0.978	0.135	0.998	0.146	0.383	0.810	0.849	0.328	0.954
	AMA-UKSB	0.002	0.039	0.999	0.996	0.032	0.999	0.219	0.468	0.716	0.789	0.406	0.936
	VMA-UKSB	0.005	0.074	0.995	0.991	0.058	0.995	0.252	0.502	0.674	0.763	0.445	0.929
SYİ-12	UKSB	0.002	0.046	0.998	0.993	0.040	0.999	0.402	0.634	0.522	0.666	0.508	0.779
	ADD-UKSB	0.015	0.121	0.985	0.978	0.111	0.998	1.028	1.014	-0.223	0.237	0.923	0.729
	AMA-UKSB	0.003	0.052	0.997	0.992	0.047	1.000	0.458	0.676	0.456	0.627	0.567	0.743
	VMA-UKSB	0.024	0.155	0.976	0.970	0.140	0.996	0.283	0.532	0.664	0.752	0.476	0.881

Tablo 3.32’den görüleceği üzere, Geyve istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,032, KOKH=0,178, NSE=0,968, OI=0,972, OMH=0,147 ve $R^2=0,987$) göre; VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer bağımsız ve hibrit tüm modellerin tahmin performansları da oldukça başarılıdır. Geyve

istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,059, KOKH=0,243, NSE=0,938, OI=0,940, OMH=0,196 ve $R^2=0,948$) göre; ADD-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Yine bu zaman ölçeğinde de UKSB yöntemine ait diğer tüm modellerin tahmin performansları oldukça başarılıdır. Bağımsız UKSB tahmin modelinde elde edilen $R^2=0,948$ değeri ise ADD-UKSB hibrit modelinin değeri ile aynı sonucu vermiştir. Geyve istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,106, KOKH=0,325, NSE=0,863, OI=0,884, OMH=0,279 ve $R^2=0,943$) göre; bağımsız UKSB tahmin modelinin en üstün sonuçları verdiği görülmüştür. ADD-UKSB hibrit tahmin modelinde ise en yüksek $R^2=0,954$ değeri elde edilmiştir. Geyve istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,283, KOKH=0,532, NSE=0,664, OI=0,752, OMH=0,476 ve $R^2=0,881$) göre; hibrit VMA-UKSB tahmin modeli en başarılı sonuçları vermiştir. Başta ADD-UKSB hibrit modeli olmak üzere diğer UKSB tahmin modellerinin tahmin performansları bu zaman ölçeğinde çalışmanın geneline bakıldığında oldukça zayıf kalmıştır. Ayrıca bu zaman ölçeğinde bahsedilmesi gereken önemli bulgulardan biri de zaman ölçeği arttıkça test tahmin sonuçlarına ait model performanslarının düştüğüdür.

Tablo 3.33'te Sivrihisar istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.33. Sivrihisar istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OKH	KOKH	NSE	OI	OMH	R ²	OKH	KOKH	NSE	OI	OMH	R ²
SYİ-1	UKSB	0.007	0.081	0.993	0.989	0.063	0.995	0.036	0.191	0.966	0.966	0.108	0.973
	ADD-UKSB	0.010	0.100	0.989	0.986	0.087	0.997	0.033	0.181	0.970	0.969	0.118	0.974
	AMA-UKSB	0.006	0.077	0.994	0.990	0.056	0.994	0.044	0.210	0.959	0.961	0.117	0.960
	VMA-UKSB	0.003	0.051	0.997	0.994	0.039	0.998	0.032	0.180	0.970	0.969	0.140	0.977
SYİ-3	UKSB	0.013	0.112	0.987	0.984	0.095	0.994	0.046	0.215	0.957	0.955	0.176	0.966
	ADD-UKSB	0.008	0.089	0.992	0.989	0.071	0.992	0.076	0.276	0.929	0.935	0.185	0.935
	AMA-UKSB	0.010	0.101	0.990	0.987	0.081	0.993	0.051	0.226	0.953	0.952	0.160	0.957
	VMA-UKSB	0.033	0.181	0.967	0.968	0.162	0.994	0.105	0.324	0.903	0.917	0.271	0.937
SYİ-6	UKSB	0.001	0.026	0.999	0.998	0.021	1.000	0.159	0.399	0.870	0.894	0.309	0.901
	ADD-UKSB	0.003	0.055	0.997	0.994	0.042	0.997	0.234	0.483	0.810	0.855	0.407	0.812
	AMA-UKSB	0.004	0.061	0.996	0.993	0.046	0.996	0.174	0.417	0.858	0.886	0.326	0.862
	VMA-UKSB	0.005	0.067	0.995	0.992	0.053	0.997	0.100	0.317	0.918	0.926	0.253	0.922
SYİ-12	UKSB	0.019	0.136	0.983	0.977	0.127	0.998	0.194	0.440	0.807	0.833	0.312	0.822
	ADD-UKSB	0.007	0.085	0.993	0.987	0.062	0.994	0.276	0.525	0.725	0.778	0.422	0.799
	AMA-UKSB	0.000	0.020	1.000	0.998	0.016	1.000	0.176	0.420	0.825	0.845	0.370	0.855
	VMA-UKSB	0.016	0.128	0.984	0.978	0.110	0.997	0.174	0.417	0.827	0.847	0.322	0.853

Tablo 3.33'ten görüleceği üzere, Sivrihisar istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,032, KOKH=0,180, NSE=0,970, OI=0,969, OMH=0,140 ve R²=0,977) göre; VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer bağımsız ve hibrit tüm modellerin tahmin performansları yine oldukça başarılı olup VMA-UKSB hibrit modelinin sonuçlarına yakındır. En düşük OMH=0,108 değeri bağımsız UKSB tahmin modelinde elde edilmiştir. Sivrihisar istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,046, KOKH=0,215, NSE=0,957, OI=0,955, OMH=0,176 ve R²=0,966) göre; bağımsız UKSB tahmin modelinin en üstün sonuçları verdiği görülmüştür. Yine bu zaman ölçeğinde de UKSB yöntemine ait diğer tüm modellerin tahmin performansları oldukça başarılıdır. AMA-UKSB hibrit tahmin modelinde elde edilen en düşük OMH=0,160 değerinin, bağımsız UKSB modelinin değerinden daha düşük olduğu görülmüştür. Sivrihisar istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,100, KOKH=0,317, NSE=0,918, OI=0,926, OMH=0,253 ve R²=0,922) göre; VMA-UKSB hibrit tahmin modelinin en

üstün sonuçları verdiği görülmüştür. Sivrihisar istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,174, KOKH=0,417, NSE=0,827, OI=0,847, OMH=0,322 ve $R^2=0,853$) göre; hibrit VMA-UKSB tahmin modeli yine en başarılı sonuçları vermiştir. $R^2=0,853$ en yüksek değeri ile AMA-UKSB hibrit tahmin modelinde, en düşük OMH=0,253 değeri ise bağımsız UKSB tahmin modelinde elde edilmiştir. Bu istasyondan elde edilen model sonuçlarına göre de zaman ölçeği arttıkça tahmin başarısı düşmektedir. Tablo 3.34'te Ilgın istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.

Tablo 3.34. Ilgın istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OKH	KOKH	NSE	OI	OMH	R^2	OKH	KOKH	NSE	OI	OMH	R^2
SYİ-1	UKSB	0.004	0.064	0.995	0.992	0.052	0.997	0.027	0.163	0.974	0.974	0.100	0.986
	ADD-UKSB	0.023	0.152	0.973	0.973	0.128	0.990	0.080	0.283	0.922	0.937	0.228	0.950
	AMA-UKSB	0.006	0.080	0.993	0.989	0.062	0.995	0.067	0.260	0.934	0.946	0.188	0.967
	VMA-UKSB	0.007	0.085	0.992	0.988	0.067	0.996	0.047	0.217	0.954	0.959	0.177	0.956
SYİ-3	UKSB	0.005	0.068	0.995	0.991	0.057	0.996	0.058	0.240	0.941	0.946	0.194	0.963
	ADD-UKSB	0.013	0.116	0.986	0.982	0.103	0.997	0.070	0.265	0.928	0.937	0.212	0.932
	AMA-UKSB	0.017	0.131	0.982	0.979	0.117	0.996	0.068	0.260	0.931	0.939	0.168	0.940
	VMA-UKSB	0.018	0.135	0.981	0.978	0.121	0.996	0.099	0.315	0.898	0.918	0.237	0.901
SYİ-6	UKSB	0.001	0.038	0.998	0.995	0.030	1.000	0.075	0.274	0.848	0.874	0.238	0.865
	ADD-UKSB	0.003	0.056	0.997	0.993	0.046	0.997	0.042	0.206	0.914	0.919	0.161	0.922
	AMA-UKSB	0.017	0.129	0.982	0.978	0.117	0.997	0.198	0.445	0.597	0.717	0.360	0.794
	VMA-UKSB	0.028	0.168	0.969	0.967	0.150	0.995	0.081	0.285	0.835	0.866	0.234	0.913
SYİ-12	UKSB	0.010	0.099	0.990	0.984	0.074	0.991	0.065	0.255	0.793	0.831	0.215	0.890
	ADD-UKSB	0.006	0.077	0.994	0.988	0.056	0.996	0.114	0.338	0.636	0.731	0.273	0.803
	AMA-UKSB	0.171	0.414	0.831	0.869	0.329	0.848	0.073	0.271	0.766	0.814	0.209	0.793
	VMA-UKSB	0.002	0.045	0.998	0.994	0.034	0.998	0.047	0.217	0.850	0.869	0.163	0.862

Tablo 3.34'ten görüleceği üzere, Ilgın istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,027, KOKH=0,163, NSE=0,974, OI=0,974, OMH=0,100 ve $R^2=0,986$) göre; bağımsız UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer bağımsız ve hibrit tüm modellerin tahmin performansları yine oldukça başarılıdır. Ilgın istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,058, KOKH=0,240, NSE=0,941, OI=0,946, OMH=0,194 ve $R^2=0,963$) göre; bağımsız UKSB tahmin modelinin en üstün sonuçları verdiği

görülmüştür. Yine bu zaman ölçeğinde de UKSB yöntemine ait diğer tüm modellerin tahmin performansları oldukça başarılıdır. En düşük OMH=0,168 değeri ile AMA-UKSB hibrit tahmin modelinde elde edilmiştir. İlgin istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,042, KOKH=0,206, NSE=0,914, OI=0,919, OMH=0,161 ve $R^2=0,922$) göre; ADD-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Bu zaman ölçeğinde sadece AMA-UKSB hibrit tahmin modelin performansları düşük kalmıştır. İlgin istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,047, KOKH=0,217, NSE=0,850, OI=0,869, OMH=0,163 ve $R^2=0,862$) göre; hibrit VMA-UKSB tahmin modelinin en başarılı sonuçları verdiği görülmüştür. Burada $R^2=0,890$ en yüksek değeri UKSB tahmin modelinde elde edilmiştir. Tablo 3.35'te Yunak istasyonuna ait tüm zaman ölçekleri için tahmin modellerinin performansları verilmiştir.


Tablo 3.35. Yunak istasyonuna ait her bir zaman ölçeği için tahmin model performanslarının karşılaştırması

Zaman ölçeği	Modeller	EĞİTME						TEST					
		OKH	KOKH	NSE	OI	OMH	R^2	OKH	KOKH	NSE	OI	OMH	R^2
SYİ-1	UKSB	0.005	0.074	0.994	0.991	0.056	0.995	0.026	0.160	0.974	0.969	0.103	0.984
	ADD-UKSB	0.010	0.101	0.989	0.986	0.078	0.989	0.065	0.254	0.936	0.939	0.206	0.942
	AMA-UKSB	0.012	0.111	0.986	0.984	0.083	0.989	0.061	0.248	0.939	0.942	0.200	0.952
	VMA-UKSB	0.026	0.161	0.971	0.973	0.147	0.996	0.078	0.279	0.923	0.930	0.219	0.942
SYİ-3	UKSB	0.003	0.059	0.997	0.993	0.046	0.997	0.044	0.210	0.949	0.946	0.166	0.962
	ADD-UKSB	0.038	0.195	0.964	0.966	0.177	0.993	0.059	0.243	0.931	0.933	0.209	0.947
	AMA-UKSB	0.017	0.131	0.984	0.981	0.116	0.996	0.053	0.230	0.939	0.938	0.162	0.946
	VMA-UKSB	0.013	0.115	0.987	0.984	0.089	0.993	0.028	0.167	0.967	0.961	0.138	0.979
SYİ-6	UKSB	0.001	0.033	0.999	0.996	0.028	1.000	0.125	0.354	0.874	0.890	0.254	0.876
	ADD-UKSB	0.008	0.087	0.993	0.988	0.073	0.996	0.246	0.496	0.752	0.811	0.405	0.806
	AMA-UKSB	0.019	0.137	0.982	0.978	0.121	0.994	0.261	0.511	0.737	0.801	0.404	0.782
	VMA-UKSB	0.020	0.141	0.981	0.977	0.119	0.994	0.271	0.520	0.727	0.795	0.438	0.797
SYİ-12	UKSB	0.000	0.010	1.000	0.999	0.009	1.000	0.055	0.235	0.927	0.919	0.179	0.958
	ADD-UKSB	0.004	0.065	0.996	0.991	0.053	0.996	0.171	0.414	0.772	0.808	0.326	0.878
	AMA-UKSB	0.013	0.113	0.988	0.981	0.107	0.998	0.141	0.375	0.813	0.835	0.296	0.819
	VMA-UKSB	0.011	0.103	0.990	0.983	0.085	0.995	0.116	0.341	0.846	0.858	0.251	0.917

Tablo 3.35'ten görüleceği üzere, Yunak istasyonu SYİ-1 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine (OKH=0,026, KOKH=0,160, NSE=0,974, OI=0,969, OMH=0,103 ve $R^2=0,984$) göre; bağımsız UKSB hibrit tahmin


modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde UKSB yöntemine ait diğer bağımsız ve hibrit tüm modellerin tahmin performansları yine oldukça başarılıdır. Yunak istasyonu SYİ-3 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,028$, $KOKH=0,167$, $NSE=0,967$, $OI=0,961$, $OMH=0,138$ ve $R^2=0,979$) göre; VMA-UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Yine bu zaman ölçeğinde de UKSB yöntemine ait diğer tüm modellerin tahmin performansları oldukça başarılıdır. Yunak istasyonu SYİ-6 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,125$, $KOKH=0,354$, $NSE=0,874$, $OI=0,890$, $OMH=0,254$ ve $R^2=0,876$) göre; UKSB hibrit tahmin modelinin en üstün sonuçları verdiği görülmüştür. Yunak istasyonu SYİ-12 zaman ölçeği için tahmin modellerine ait test sonuçlarında performans kriterlerine ($OKH=0,055$, $KOKH=0,235$, $NSE=0,927$, $OI=0,919$, $OMH=0,179$ ve $R^2=0,958$) göre; yine bağımsız UKSB tahmin modelinin en başarılı sonuçları verdiği görülmüştür.

Sakarya havzasında yer alan 10 adet istasyona ait SYİ kuraklık tahmin modellerinin performans kriterlerine göre sonuçları elde edilerek sırasıyla tablolar halinde verilmiştir. Bu aşamada ise her bir zaman ölçeği için en iyi test sonuçlarını veren tahmin modellerine ait saçılma ve zaman serisi grafikleri elde edilmiştir. Çok fazla istasyon ve zaman ölçeği incelendiğinden dolayı burada yalnızca üç büyük istasyon olan Sakarya, Ankara ve Kütahya istasyonlarına yer verilmiştir. Şekil 3.10'da Sakarya istasyonunun her bir zaman ölçeği için elde edilen en iyi model sonuçlarına ait saçılma ve zaman serisi grafiği verilmiştir.




Şekil 3.10. Sakarya istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait saçılma ve zaman serisi grafikleri

Şekil 3.10'dan görüleceği üzere, Sakarya istasyonunun her bir zaman ölçeğinde UKSB derin öğrenme yöntemine ait bağımsız ya da hibrit kuraklık tahmin modelleri oldukça üstün performanslar göstermiştir. Test sonuçlarına göre, Sakarya istasyonunun SYİ-1 zaman ölçeğinde bağımsız UKSB modelinin tahmin performansı oldukça başarılıdır. UKSB tahmin modelinden elde edilen tahmin değerleri ile hesap değerlerine göre çizilen doğrusal regresyon çizgisi, 1:1 doğrusal eğriyi ($y=x$ (45°)) çok yakından kesmektedir. Aynı şekilde hesap edilen SYİ-1 değerleri ile tahmin edilen SYİ-1 değerlerine ait zaman serisi grafiğinde veriler büyük bir oranda çakışmaktadır. SYİ-3 zaman ölçeğinde ise VMA-UKSB hibrit tahmin modeli oldukça iyi bir tahmin performansı göstermiştir. Doğrusal regresyon çizgisi yine doğrusal eğriyi güçlü bir şekilde kesmekte olup SYİ-3 hesap değerleri ile tahmin değerlerine ait zaman serisi yüksek bir oranda çakışmaktadır. Zaman ölçeği arttıkça modellerin tahmin performansları biraz düşse de yine de SYİ-6 ve SYİ-12 zaman ölçeklerinde sırasıyla bağımsız UKSB ve VMA-UKSB hibrit modellerinden üstün tahmin başarıları elde edilmiştir. Hem SYİ-6 hem de SYİ-12 zaman ölçeğinde hesap edilen kuraklık değerleri ile tahmin edilen kuraklık değerleri zaman serisi grafiklerinde büyük bir oranda çakışmaktadır. Şekil 3.11'de Ankara istasyonunun her bir zaman ölçeği için en iyi sonucu veren modellere ait saçılma ve zaman serisi grafikleri verilmiştir.



Şekil 3.11. Ankara istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait saçılma ve zaman serisi grafikleri

Şekil 3.11’de verilen grafiklerden görüleceği üzere, Ankara istasyonunun her bir zaman ölçeğinde Sakarya istasyonunda olduğu gibi yine UKSB derin öğrenme yöntemine ait bağımsız ya da hibrit kuraklık tahmin modelleri oldukça üstün performanslar göstermiştir. Test sonuçlarına göre, Ankara istasyonunun SYİ-1 zaman ölçeğinde bağımsız UKSB modelinin tahmin performansı oldukça üstündür. Burada, doğrusal regresyon çizgisi, 1:1 doğrusal eğriyi ($y=x$ (45°)) güçlü bir şekilde kesmektedir. Aynı şekilde hesap edilen SYİ-1 değerleri ile tahmin edilen SYİ-1 değerlerine ait zaman serisi grafiğinde veriler çok büyük bir oranda çakışmaktadır. Bu da tahmin modelinin üstün başarısını göstermesi açısından önemli bir göstergedir. SYİ-3 zaman ölçeğinde bağımsız UKSB tahmin modeli oldukça iyi bir tahmin performansı göstermiştir. Doğrusal regresyon çizgisi yine doğrusal eğriyi güçlü bir şekilde kesmekte olup SYİ-3 hesap değerleri ile SYİ-3 tahmin değerleri zaman serisi grafiğinde yüksek oranda çakışmaktadır. SYİ-6 zaman ölçeğinde tahmin performansları biraz düşmüş olsa da VMA-UKSB hibrit modelinin kuraklık tahmin performansı yine de oldukça başarılıdır. Diğer zaman ölçekleri ile kıyaslandığında doğrusal regresyon çizgisi, doğrusal eğriden biraz daha fazla sapmış olmasına rağmen zaman serisi grafiğinde hesaplanan kuraklık değerleri ile tahmin edilen kuraklık değerleri bazı noktalarda birbirlerinden uzak geçmiştir. Yine SYİ-12 zaman ölçeğinde de VMA-UKSB hibrit modeli test sonuçlarına göre en iyi sonucu vermiş olup doğrusal regresyon çizgisi, doğrusal eğriyi çok güçlü bir şekilde kesmektedir. Bu zaman ölçeği için verilen zaman serisi grafiğinden de görüleceği üzere test veri setinin büyük bir kısmında hesap edilen kuraklık değerleri ile tahmin edilen kuraklık değerleri aynı çizgiyi takip etmektedir. Şekil 3.12’de Kütahya istasyonunun her bir zaman ölçeği için en iyi sonucu veren modellere ait saçılma ve zaman serisi grafikleri verilmiştir.




Şekil 3.12. Kütahya istasyonu her bir zaman ölçeği için en iyi sonucu veren modellere ait saçılma ve zaman serisi grafikleri

Şekil 3.12’de verilen saçılma ve zaman serisi grafiklerinden görüleceği üzere, Kütahya istasyonunun her bir zaman ölçeğinde Sakarya ve Ankara istasyonlarında olduğu gibi yine UKSB derin öğrenme yöntemine ait bağımsız ya da hibrit kuraklık tahmin modelleri oldukça üstün performanslar göstermiştir. Tahmin modellerinden elde edilen test sonuçlarına göre, Kütahya istasyonunun SYİ-1 zaman ölçeğinde bağımsız UKSB modelinin tahmin performansının yine oldukça başarılı olduğu görülmüştür. Burada da, doğrusal regresyon çizgisi 1:1 doğrusal eğriyi çok güçlü bir şekilde kesmektedir. Aynı şekilde hesap edilen SYİ-1 değerleri ile tahmin edilen SYİ-1 değerlerine ait zaman serisi grafiğinde veriler çok büyük bir oranda çakışmaktadır. SYİ-3 zaman ölçeğinde VMA-UKSB hibrit tahmin modeli oldukça iyi bir tahmin performansı göstermiştir. Doğrusal regresyon çizgisi yine doğrusal eğri ile güçlü bir şekilde kesişmiş olup zaman serisi grafiğinde SYİ-3 hesap değerleri ile SYİ-3 tahmin değerleri yüksek bir oranda çakışmaktadır. SYİ-6 zaman ölçeğinde bağımsız UKSB tahmin modeli, SYİ-12 zaman ölçeğinde ise VMA-UKSB hibrit tahmin modeli en iyi sonucu vermiştir. Kütahya istasyonunda zaman ölçeği arttıkça modellerin tahmin performansları diğer zaman ölçeklerine kıyasla biraz düşmüş olsa da yine de SYİ-6 ve SYİ-12 zaman ölçeklerinde başarılı tahminler elde edilmiştir. Diğer zaman ölçekleri ile kıyaslandığında SYİ-6 ve SYİ-12 zaman ölçeklerinde doğrusal regresyon çizgisi, doğrusal eğriden az da olsa sapma göstermiş olup hesaplanan kuraklık değerleri ile tahmin edilen kuraklık değerleri zaman serisi grafiğinde bazı noktalarda birbirlerinden uzak geçmiştir.

Sakarya, Ankara ve Kütahya istasyonlarına ait saçılma ve zaman serileri grafiklerinden de anlaşılabileceği üzere bu kuraklık tahmin çalışmasında bağımsız UKSB ve VMA-UKSB hibrit modellerinin tahmin performansları oldukça başarılıdır. Burada yer verilmeyen diğer istasyonlarda da benzer sonuçlar elde edilmiştir.


Performans kriterlerine ek olarak modellere ait test sonuçlarını bir arada görebilmek ve karşılaştırmasını yapabilmek amacıyla Taylor diyagramlarından faydalanılmıştır. Hesap edilen kuraklık değerleri ile modellerden elde edilen kuraklık tahmin değerlerinin standart sapma, korelasyon katsayısı ve merkezlenmiş kök ortalama karesel farkı istatistiksel kriterlerine göre Taylor diyagramları üzerinden karşılaştırmaları yapılmıştır. Taylor diyagramlarında; Sakarya, Ankara, Kütahya ve Emirdağ istasyonları için yöntemlerin her birinde en iyi sonucu veren bağımsız ya da hibrit modeller, geri kalan istasyonlarda ise UKSB yönteminin bağımsız ve hibrit modelleri bir arada

değerlendirilmiştir. İstasyonların yalnızca SYİ-1 zaman ölçeği için Taylor diyagramları elde edilmiş olup tüm istasyonlara ait SYİ-1 Taylor diyagramları Şekil 3.13–3.22 arasında verilmiştir.




Şekil 3.13. Sakarya istasyonu SYİ-1 için her bir yönteme ait en iyi sonucu veren tahmin modellerine ait Taylor diyagramı

Şekil 3.13'ten görüleceği üzere Sakarya istasyonu SYİ-1 için elde edilen Taylor diyagramında, hesaplanan referans kuraklık değerlerine korelasyon katsayısı, standart sapma ve merkezlenmiş kök ortalama karesel farkı (RMSD) istatistiksel kriterlerine göre en yakın ve en uyumlu olan bağımsız UKSB tahmin modelidir. VMA-YSA hibrit modeli dışındaki diğer üç modelin referans noktasına neredeyse aynı uzaklıkta olduğu görülmüştür.




Şekil 3.14. Ankara istasyonu SYİ-1 için her bir yönteme ait en iyi sonucu veren modellere ait Taylor diyagramı

Şekil 3.14'te verilen Ankara istasyonu SYİ-1 Taylor diyagramında, hesaplanan referans kuraklık değerine en yakın ve en uyumlu olan model yine bağımsız UKSB tahmin modelidir. Bağımsız UKSB modeli standart sapma eğrisi ile çok güçlü bir şekilde kesişmiş olup ayrıca korelasyon katsayısı değeri de yüksektir. VMA-DVMR hibrit modeli standart sapma eğrisine çok yakın olmasına rağmen diğer kriterlerden dolayı bağımsız UKSB modelinden geride kalmıştır. VMA-GSR ile VMA-YSA modellerinin tahmin sonuçları da birbirine çok yakındır. ADD-USBÇS hibrit modeli tüm kriterlere göre performans olarak diğer modellerin gerisinde kalmıştır.




Şekil 3.15. Kütahya istasyonu SYİ-1 için her bir yönteme ait en iyi sonucu veren modellere ait Taylor diyagramı

Şekil 3.15'ten görüleceği üzere Kütahya istasyonu SYİ-1 Taylor diyagramında da bağımsız UKSB tahmin modeli, hesaplanan referans kuraklık değerine daha yakın ve daha uyumludur. Bağımsız UKSB modeli standart sapma eğrisinden uzaklaşmış olsa da yüksek korelasyon katsayısı ve düşük RMSD değerlerinden dolayı diğer modellere göre daha üstündür. Burada da yine VMA-GSR ile VMA-YSA modellerinin tahmin sonuçları birbirine çok yakındır.



Şekil 3.16. Emirdağ istasyonu SYİ-1 için her bir yönteme ait en iyi sonucu veren modellere ait Taylor diyagramı


Şekil 3.16’da verilen Emirdağ istasyonu SYİ-1 Taylor diyagramından görüleceği üzere VMA-UKSB tahmin modeli, hesaplanan referans kuraklık değerine daha yakın ve daha uyumludur. Diğer VMA’lı hibrit modellerin performansları ise birbirlerine oldukça yakın çıkmıştır. Bu dört model standart sapma eğrisine yakın olmalarına rağmen diğer kriterlere göre VMA-UKSB modelinin gerisinde kalmışlardır.



Şekil 3.17. Bolu istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı


Şekil 3.17’den görüleceği üzere Bolu istasyonu SYİ-1 Taylor diyagramında bağımsız UKSB tahmin modeli, diğer hibrit UKSB modellerine göre hesaplanan referans kuraklık değerine daha yakın ve daha uyumludur. VMA-UKSB ve AMA-UKSB modelleri ise

birbirine çok yakın sonuçlar vermiş olup VMA-UKSB modeli az da olsa referans noktasına daha yakındır. ADD-UKSB hibrit modeli ise bu zaman ölçeğinde tahmin performansı olarak diğer modellerin gerisinde kalmıştır.




Şekil 3.18. Polatlı istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı

Şekil 3.18’de verilen Polatlı istasyonu SYİ-1 Taylor diyagramında, bağımsız UKSB tahmin modelinin diğer hibrit UKSB modellerine göre yine hesaplanan referans kuraklık değerine daha yakın ve daha uyumlu olduğu görülmüştür. AMA-UKSB hibrit modeli burada ikinci en iyi sonucu veren model olmuştur. ADD-UKSB ve VMA-UKSB modelleri, RMSD eğrisini aynı noktada kesmiş olup sonuçları ise oldukça yakındır.




Şekil 3.19. Geyve istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı

Şekil 3.19’da verilen Geyve istasyonu SYİ-1 Taylor diyagramında görüleceği üzere, VMA-UKSB hibrit tahmin modelinin diğer UKSB tahmin modellerine göre hesaplanan referans kuraklık değerine daha yakın ve daha uyumlu olduğu görülmüştür. Geyve istasyonunun bu zaman ölçeğindeki tüm tahmin modelleri oldukça başarılıdır. UKSB ve ADD-UKSB modellerinin performansları ise birbirine çok yakındır.




Şekil 3.20. Sivrihisar istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı

Şekil 3.20’den görüleceği üzere, Sivrihisar istasyonu SYİ-1 Taylor diyagramında VMA-UKSB hibrit tahmin modeli, diğer UKSB modellerine göre hesaplanan referans kuraklık değerine daha yakın konumdadır. Sivrihisar istasyonunun bu zaman ölçeğindeki tüm tahmin modellerinin performansları yüksek olup diyagramdan görüleceği üzere birbirlerine de oldukça yakındırlar.



Şekil 3.21. Ilgın istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı


Tablo 3.21’de verilen Ilgın istasyonu SYİ-1 Taylor diyagramında bağımsız UKSB tahmin modeli, diğer hibrit UKSB modellerine göre hesaplanan referans kuraklık değerine daha yakın ve daha uyumludur. Bağımsız UKSB tahmin modeli, standart sapma eğrisi dikkate alındığında ADD-UKSB ve VMA-UKSB hibrit modellerinin gerisinde kalmıştır.



Şekil 3.22. Yunak istasyonu SYİ-1 için UKSB yöntemine ait en iyi sonucu veren modellere ait Taylor diyagramı


Şekil 3.22’de verilen Yunak istasyonu SYİ-1 Taylor diyagramında görüleceği üzere bağımsız UKSB tahmin modeli, diğer hibrit UKSB modellerine göre hesaplanan referans kuraklık değerine daha yakın ve daha uyumludur. UKSB’nin diğer hibrit modelleri, referans değerine hemen hemen aynı uzaklıkta bulunmaktadır.

Çalışmada, tahmin modellerinden elde edilen test sonuçlarına ait performans kriterlerinin daha kolay karşılaştırılabilmesi amacıyla radar grafikleri de kullanılmıştır. İstasyonların SYİ-12 zaman ölçeğindeki en iyi test sonucunu veren tahmin modellerinin ve bu modellerden elde edilen performans kriterlerinin bir arada gösterildiği radar grafikleri Şekil 3.23–3.27 arasında sırasıyla verilmiştir.




Şekil 3.23. Sakarya ve Ankara istasyonları SYİ-12 için en iyi test sonucunu veren beş modele ait radar grafikleri

Şekil 3.23'te verilen radar grafiğinden görüleceği üzere, Sakarya SYİ-12 zaman ölçeği için tüm performans kriterleri dikkate alındığında VMA-UKSB hibrit modeli en iyi tahmin sonuçlarını vermiş olup R^2 ve OMH kriterleri hariç olmak üzere VMA-GSR hibrit modeli onu takip etmektedir. Ankara SYİ-12 zaman ölçeğinde de tüm performans kriterlerine göre yine VMA-UKSB hibrit modeli en üstün tahmin performansına sahiptir. Bu modelin ardından ise OMH kriteri hariç olmak üzere VMA-YSA hibrit modeli gelmektedir.




Şekil 3.24. Kütahya ve Emirdağ istasyonları SYİ-12 için en iyi test sonucunu veren beş modele ait radar grafikleri

Şekil 3.24'te verilen radar grafiğinden görüleceği üzere, Kütahya SYİ-12 zaman ölçeği için tüm performans kriterleri dikkate alındığında VMA-UKSB hibrit modeli en iyi tahmin sonuçlarını vermiştir. VMA-UKSB hibrit tahmin modelini, R^2 performans kriteri hariç olmak üzere VMA-USBÇS hibrit modeli izlemektedir. Emirdağ SYİ-12 zaman ölçeğine ait radar grafiğinde yine VMA-UKSB hibrit modelinin tahmin performansının yüksek olduğu görülmektedir. Onu takip eden model ise OMH performans kriteri hariç VMA-GSR hibrit modelidir.




Şekil 3.25. Bolu ve Polatlı istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri

Şekil 3.25'te verilen Bolu SYİ-12 zaman ölçeğine ait radar grafiğinden görüleceği üzere, tüm performans kriterleri dikkate alındığında VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Bu modeli, R^2 performans kriteri hariç olmak üzere ADD-UKSB hibrit modeli takip etmektedir. Bu zaman ölçeğinde AMA-UKSB hibrit tahmin modelinin performansı zayıf kalmıştır. Polatlı SYİ-12 zaman ölçeğine ait radar grafiği incelendiğinde, R^2 performans kriteri hariç diğer performans kriterlerine göre VMA-UKSB hibrit tahmin modeli en başarılı sonuçları vermiştir. VMA-UKSB hibrit modelinden sonra ise yine R^2 performans kriteri hariç olmak üzere, AMA-UKSB hibrit modeli gelmektedir. R^2 performans kriterinde ise bağımsız UKSB tahmin modeli en başarılı sonuçları vermiştir.



Şekil 3.26. Geyve ve Sivrihisar istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri

Şekil 3.26’da verilen Geyve SYİ-12 zaman ölçeğine ait radar grafiğinden görüleceği üzere, tüm performans kriterleri dikkate alındığında VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. Bu zaman ölçeğinde ADD-UKSB hibrit tahmin modeli, tüm performans kriterlerine göre UKSB modelleri içerisinde en başarısız model olmuştur. Yine Şekil 3.26’dan görüleceği üzere, Sivrihisar SYİ-12 zaman ölçeğine ait radar grafiğinde altı performans kriterinin dördünde en iyi sonuçları VMA-UKSB hibrit tahmin modeli vermiştir. R^2 performans kriterine göre AMA-UKSB hibrit modeli, OMH performans kriterine göre ise bağımsız UKSB modeli en iyi tahmin sonucunu vermiştir. Sivrihisar SYİ-12 zaman ölçeğinde, VMA-UKSB ile AMA-UKSB hibrit modellerinin tahmin performansları birbirine oldukça yakındır.



Şekil 3.27. Ilgın ve Yunak istasyonları SYİ-12 için UKSB yöntemine ait modellerin test sonuçlarını gösteren radar grafikleri

Şekil 3.27’de verilen Ilgın SYİ-12 zaman ölçeğine ait radar grafiğinden görüleceği üzere, R^2 performans kriteri hariç tüm kriterlerde VMA-UKSB hibrit tahmin modeli en üstün sonuçları vermiştir. R^2 performans kriterine göre ise en başarılı sonuçlar bağımsız UKSB tahmin modeline aittir. Yine Şekil 3.27’de verilen Yunak SYİ-12 zaman ölçeğine ait radar grafiğinden görüleceği üzere, tüm performans kriterleri dikkate alındığında bağımsız UKSB tahmin modeli en üstün sonuçları vermiştir. Yunak SYİ-12 zaman ölçeği için UKSB yöntemine ait tüm modellerin tahmin performanslarının yüksek olduğu söylenebilir.

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

4.1. Tartışma

2023 yılı Ocak ayında yayınlanan Dünya Ekonomik Forumu Küresel Risk Raporunda; önümüzdeki 10 yılda dünyanın karşılaştacağı en büyük on tehlikeden altısının küresel iklim değişikliği ve buna bağlı olarak ortaya çıkacak olan çevreyi ilgilendiren sorunlar olduğu belirtilmiştir. Canlı-cansız ekosisteminin en önemli döngüsü diyebileceğimiz hidrolojik çevrimde küresel iklim değişikliğine bağlı olarak son dönemlerde normal koşullara göre önemli derecede sapmalar gözlenmektedir. Bu sapmalar ile bağlantılı olarak meydana gelen kuraklık olayları da geniş bölgelerde etkisini artırmış ve en çok tartışılan konulardan biri haline gelmiştir. Yağışların azalmasına bağlı olarak su arz-talep dengesinin bozulması ile birlikte ortaya çıkan kuraklık, iklim koşullarının su kaynaklarına, tarım ve canlı hayatına etkilerini ortaya çıkartan ve çok önem verilmesi gereken tehlikeli bir doğal afettir. Ayrıca kuraklığın tespiti, izlenmesi ve öngörülmesi de oldukça zor bir süreçtir. Bundan dolayı kuraklık olayını hem küçük ölçeklerde hem de küresel ölçekte doğru ve güvenilir bir şekilde tespit etmek oldukça önemlidir. Bilim ve teknolojideki gelişmeler dikkate alınarak kuraklığa etki eden parametrelerle kuraklık durumu arasındaki ilişki doğru bir şekilde ortaya konulmalıdır. Ayrıca bir bölgedeki kuraklığın gelecekteki muhtemel durumunun güvenilir bir şekilde öngörülebilmesi, kuraklığa yönelik projeksiyonların geliştirilebilmesi için de oldukça önemlidir.

Bu çalışmada ele alınan meteorolojik kuraklık, karmaşık kuraklık sürecinin ilk aşaması olduğundan bölgesel olarak kuraklığın genel gidişatı ile ilgili bizlere çeşitli fikirler sunabilmektedir. Bu doğrultuda, Türkiye'nin kuzeybatısında yer alan ve önemli nehir havzalarından biri olan Sakarya havzasındaki istasyonlara ait kısa dönem meteorolojik kuraklıklar tahmin edilmeye çalışılmıştır. Çalışma alanı olarak Sakarya havzasının

seçilme nedeni; yarı kurak bir iklim bölgesinde yer almasından dolayı kuraklığa meyilli olması, kişi başına düşen su miktarından dolayı su stresi yaşaması ve havzada daha önceden bu kapsamda bir kuraklık tahmin çalışmasının olmamasıdır. Havzayı temsilen 10 adet meteoroloji istasyonu seçilmiştir. Bu istasyonların özellikle uzun dönem verilerinin olmasına dikkat edilmiş olup gözlem aralığında eksik veri bulunmaması, ölçüm kayıtlarının güncel olması ve havzayı temsilleri de seçilmelerindeki etkenlerdendir. Kısa dönem kuraklık tahmini yapıldığından dolayı bu istasyonlar için 1, 3, 6 ve 12 aylık zaman ölçekleri dikkate alınmıştır. Kuraklık indisi olarak sadece yağış değişkenine bağlı olarak hesaplanabilen ve ülkemizin iklim koşullarına iyi uyum sağladığı bilinen [4, 204], Standartlaştırılmış Yağış İndeksi (SYİ) kullanılmıştır. Bu çalışmada; SYİ'nin Palmer Kuraklık Şiddet İndisi (PKŞİ) ve Standartlaştırılmış Yağış-Evapotranspirasyon İndisi (SYEI) gibi diğer meteorolojik kuraklık indislerinin yerine kullanılma sebepleri yalnızca yağış verisine bağlı olması, farklı zaman ölçekleri için değerlendirilebilmesi ve hesap kolaylığıdır. PKŞİ, su dengesinde yağış açığına bağlı olarak evapotranspirasyon, akışlar ve nem miktarındaki sapmaları dikkate alan bir indis olup karmaşık bir yapıdadır [33]. SYEI'de ise yağış değişkeni ile birlikte potansiyel evapotranspirasyon (PET) değişkeni de ele alınmaktadır. PET hesabı için gerekli olan sıcaklık, rüzgâr hızı, güneş radyasyonu, bağıl nem gibi parametrelerden dolayı bu kuraklık indisi de karmaşık bir yapıdadır [35]. Ayrıca SYEI'nin bazı kurak bölgelerde uygulanabilirliği sınırlı olmaktadır [205].

İstasyonlara ait ham yağış verilerine, %95 güven aralığında kalacak şekilde Standart Normal Homojenlik Testi (SNHT), Genişletilmiş Dickey-Fuller Testi (GDFT), Von-Neumann Homojenlik Testi (VNT) ve Mann-Whitney u Testi (MWT) uygulanmıştır. Bu dört teste ait istatistiksel sonuçlara göre, kurulan H_0 hipotezleri kabul edilmiş olup istasyon verilerinin tamamı homojen, durağan ve bağımsız çıkmıştır. Çalışmada kullanılan yağış verilerinde şüpheli bir durum söz konusu olmadığından dolayı bu çalışmada istasyonlara ait yağış verilerinin homojen hale getirilmesine gerek kalmamıştır. Hidrometeorolojik zaman serilerine dayalı tahmin modellerinden doğru ve güvenilir sonuçlar elde edilebilmesi için homojenlik testlerinin yapılması gerekir.

Ele alınan istasyonlara ait uzun dönem aylık yağış verilerinden SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık zaman serileri elde edilmiştir. Çalışmada SYİ kuraklık değerlerinin hesabı, hem fazla istasyonun seçilmesi hem de fazla zaman ölçeğinden dolayı DrinC

yazılımı kullanılarak oldukça pratik bir şekilde yapılmış olup işlem yükü ve zamandan tasarruf sağlanmıştır. Kullanılan yazılımın kalibrasyonu için manuel hesaplamalardan da faydalanılmış olup yazılımdan elde edilen verilerin güvenilir olduğu bulunmuştur.

DrinC yazılımı ile elde edilen SYİ kuraklık değerleri, SYİ-1 ve SYİ-12 zaman ölçekleri için değerlendirilmiştir. SYİ-3 ve SYİ-6 zaman ölçeklerindeki kuraklık değerlerinin değerlendirilmesi yapılmamıştır. Çünkü bu iki zaman ölçeğinde benzer kuraklık sınıflarının olduğu ve birbirini tekrar ettiği görülmüştür. SYİ-1 zaman ölçeğinde havzada yer alan istasyonların tamamında %68,18 ile %70,51 arasında değişen yüzdelerde normale yakın SYİ kuraklık sınıfı görülmüştür. %1,42 ile %3,53 arasında değişen yüzdelerde aşırı kurak, %0,76 ile %2,08 arasında değişen yüzdelerde ise aşırı nemli kuraklık sınıfı görülmüştür. Yine SYİ-12 zaman ölçeğinde havzada yer alan istasyonların tamamında %57,38 ile %70,49 arasında değişen yüzdelerde normale yakın SYİ kuraklık sınıfı görülmüştür. SYİ-12 zaman ölçeğinde Sakarya, Emirdağ, Polatlı ve Yunak istasyonlarında aşırı kurak bir yıl olmamıştır. Diğer istasyonlarda ise %1,92 ile %6,82 arasında değişen yüzdelerde aşırı kurak yıllar olmuştur. Aynı şekilde Kütahya, Bolu ve Ilgın istasyonlarında aşırı nemli bir yıl görülmemiştir. Diğer istasyonlarda ise %1,92 ile %4,88 arasında değişen yüzdelerde aşırı nemli yıllar yaşanmıştır.

SYİ-1, SYİ-3, SYİ-6 ve SYİ-12 kuraklık değerlerinin farklı gecikme zamanlarından (t , $t-1$, $t-2$, $t-3$, ...vb.) hangisinin optimum gecikme zamanı olarak modellerde ele alınacağını belirlemek ve kuraklık zaman serilerindeki otokorelasyon varlığını araştırmak amacıyla Sakarya istasyonunun her bir SYİ zaman ölçeğine otokorelasyon fonksiyonu uygulanmıştır. Her bir zaman ölçeği için tüm gecikme zamanları %95 güven aralığındaki otokorelasyon katsayısının alt ve üst sınırları içerisinde kalmış olup otokorelasyon varlığı söz konusu değildir. Ayrıca tüm zaman ölçeklerinde 10 gecikme zamanına kadar olan gecikmelerin, tahmin modellerinde girdi değişkenleri olarak kullanılabileceği sonucuna ulaşılmıştır. Optimum gecikme zamanı ise Ayrık Dalgacık Dönüşümü (ADD) analizleri sonucunda nihai olarak belirlenmiştir. Bu çalışmaya benzer nitelikteki birçok çalışmada [82, 93, 206] otokorelasyon varlığı araştırılmamış olup zaman serilerinin tahmini ile ilgili analizlerde dikkate alınması gereken optimum gecikme zamanının genellikle deneme yanılma yoluyla belirlendiği görülmüştür.

SYİ kuraklık zaman serilerinin Ayırık Dalgacık Dönüşümü (ADD), Ampirik Mod Ayırıştırma (AMA) ve Varyasyonel Mod Ayırıştırma (VMA) ön işleme teknikleri ile alt bantlarına ayrılmasına yönelik analizler bu çalışmanın en önemli uygulamalarındandır. Tahmin modellerinde girdi değişkeni olarak kullanılacak olan SYİ kuraklık verileri, ele alınan ön işleme teknikleri aracılığı ile alt bantlarına ayrılmış olup verilerin sıkıştırılarak boyutunun azaltılması, gereksiz bilgilerin temizlenmesi, özellik ve özneteliklerin ortaya çıkarılması, veri birleştirmesi ve dönüştürmesi gibi faydalar sağlanmıştır.

Bu çalışmada ele alınan ADD ön işleme tekniği, detaylı ve geniş bir perspektifte kuraklık verilerine uygulanmıştır. ADD tekniği, belli başlı ölçek ve öteleme katsayıları üzerinden ayırıştırma işlemini gerçekleştirdiğinden SDD'e göre hem daha nitelikli alt seriler elde etmekte hem de zaman ve işlem yükünden tasarruf sağlamaktadır. Bu nedenle ADD tercih edilmiştir. Çalışmanın tamamında dikkate alınan optimum gecikme zamanının, uygun dalgacık ailesinin ve dalgacık bant seviyelerinin belirlenmesi amacıyla Sakarya istasyonunun her bir zaman ölçeğinde ADD-USBÇS hibrit tahmin modeli kullanılmıştır. USBÇS makine öğrenmesi yönteminin dalgacık dönüşümünde kullanılmasının sebebi, yöntemin hızlı ve güvenilir bir şekilde analizler yapmasıdır [91]. Dalgacık dönüşümünün en önemli hususlarından biri veriye uygun dalgacık ailesinin seçilmesidir. Orijinal veriyi alt bantlarına ayırıştırma yeteneği yüksek olan bir dalgacık ailesi seçildiğinde model performansı da önemli ölçüde artmaktadır. Bu tez çalışmasında; sekiz farklı dalgacık ailesi kullanılmış olup bu dalgacık ailelerinin kuraklık zaman serilerini alt bantlarına ayırıştırma yetenekleri araştırılmıştır. Literatür incelendiğinde [86, 87]; genellikle Haar, Daubechies, Morlet ve Meksika şapkası gibi tek bir dalgacık ailesine göre zaman serileri alt bantlarına ayrılmaktadır.

ADD-USBÇS hibrit tahmin modelinden elde edilen test sonuçları OMH ve R^2 performans kriterlerine göre karşılaştırıldığında; Sakarya istasyonu SYİ-1, SYİ-3 ve SYİ-6 zaman ölçeklerinde Meyer'in Ayırık Yaklaşımı (Discrete Approximation of Meyer-dmey) dalgacık ailesi, SYİ-12 zaman ölçeğinde ise Symlets (sym3) dalgacık ailesinin en üstün sonuçları verdiği görülmüştür. Özellikle dmey dalgacık ailesinin, bu çalışmada ele alınan kuraklık zaman serileri ile yüksek bir uyum yakaladığı ve alt bantlarına ayırma işleminde oldukça başarılı olduğu görülmüştür. Birçok hidrometeorolojik çalışmada [207, 208] dalgacık dönüşümü ile ilgili analizlerde yaygın bir şekilde kullanılan Haar dalgacık ailesi bu çalışmada en başarısız dalgacık ailesi

olarak bulunmuştur. Ayrıca literatür incelendiğinde, dney dalgacık ailesinin bu çalışmada olduğu gibi yüksek bir başarı gösterdiği başka bir hidrometeorolojik çalışmaya rastlanmamıştır. Yine dalgacık dönüşümünün önemli hususlarından biri olan dalgacık bant seviyesi ile ilgili olarak 3, 4, 5, 6 ve 7 olmak üzere beş farklı bant seviyesinin ayırıştırma kapasitesi araştırılmıştır. Dalgacık ailesinde olduğu gibi bant seviyeleri için çok sayıda alternatif değerlendirilmiştir. Yine Sakarya istasyonu için ADD-USBÇS hibrit tahmin modelinden elde edilen test sonuçlarına ait OMH ve R^2 performans kriterlerine göre; SYİ-1, SYİ-3 ve SYİ-12 zaman ölçeklerinde 3. dalgacık bant seviyesi, SYİ-6 zaman ölçeğinde ise 4. dalgacık bant seviyesi en başarılı sonuçları vermiştir. ADD ön işleme tekniği ile belirlenen tahmin modellerinde kullanılacak olan bir diğer model parametresi ise optimum gecikme zamanıdır. Otokorelasyon fonksiyonu aracılığı ile daha önceden uygun gecikme zamanları aralığı (10 gecikmeye kadar) belirlenmişti. Nihai optimum gecikme zamanını belirlemek amacıyla yine Sakarya istasyonunun her bir zaman ölçeği için ADD-USBÇS hibrit tahmin modelinde analizler yapılmıştır. Modelden elde edilen test sonuçları OMH ve R^2 performans kriterlerine göre değerlendirildiğinde; her bir zaman ölçeğinde de 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) üstün bir başarı göstermiştir. Burada, giriş sayısı 1'den 4'e kadar giderken model performansları artmış ancak 4'ten sonra ele alınan 5 ve 6 giriş sayısı için performanslar çok değişmemiş bazı zaman ölçeklerinde de azalmıştır. Çalışmada, t orijinal kuraklık verisi olmak üzere; t, t-1, t-2, t-3 girdi değişkenleri ve t+1 çıktı değişkeni olarak belirlenmiş olup tüm tahmin modellerinde bu yapı kullanılmıştır.

Dalgacık dönüşümü ile optimum gecikme zamanı, en uygun dalgacık ailesi ile dalgacık bant seviyeleri belirlendikten sonra diğer ön işleme teknikleri olan AMA ve VMA teknikleri ile yine kuraklık zaman serileri alt bantlarına ayrılmıştır. Bu tez çalışması; ADD, AMA ve VMA ön işleme tekniklerinin hidrometeorolojik zaman serilerinde bir arada kullanıldığı ilk tez çalışmasıdır. Literatür incelemesine göre [86, 87, 93, 122, 209]; hidrometeorolojik zaman serilerinde veri ön işlemesi için en çok tercih edilen yöntem olan dalgacık dönüşümü başta olmak üzere genellikle tek ya da iki farklı yöntemin ele alındığı görülmüştür. Bu çalışmada, tahmin modellerinin performanslarını artırabilmek amacıyla bu denli kapsamlı bir veri ön işlemesi üzerinde durulmuştur. Ayrıca daha çok haberleşme, elektronik, biyomedikal ve tıp gibi alanlarda kullanılan AMA ve VMA tekniklerinin kuraklık zaman serilerini alt bantlarına ayırıştırma

performansları da görölmek istenmiştir. Dalgacık dönüşümünde olduğu gibi Sakarya istasyonunun her bir zaman ölçeği için AMA ve VMA'lı USBÇS hibrit tahmin modelinde optimum bant seviyeleri belirlenerek alt bantlarına ayrılan kuraklık zaman serileri tüm istasyonlar için tahmin modellerinde kullanılmıştır. Hem AMA hem de VMA yönteminde 2D, 3D, 4D ve 5D olmak üzere dört farklı bant seviyesi üzerinden veriler alt bantlarına ayrılmıştır. AMA-USBÇS hibrit tahmin modelinden elde edilen test sonuçlarına ait KOKH ve R^2 performans kriterlerine göre; Sakarya istasyonunun her bir zaman ölçeğinde 2D bant seviyesi en başarılı sonuçları vermiştir. VMA-USBÇS hibrit tahmin modelinden elde edilen test sonuçlarına ait KOKH ve R^2 performans kriterlerine göre ise Sakarya istasyonunun SYİ-1, SYİ-3 ve SYİ-12 zaman ölçeklerinde 5D, SYİ-6 zaman ölçeğinde ise 4D bant seviyesi en başarılı sonuçları vermiştir. AMA tekniğinde bant seviyesinin artması performans kriterlerini iyileştirmemiş, VMA tekniğinde ise bant seviyesi arttıkça daha başarılı performans kriterleri elde edilmiştir.

Kuraklık zaman serileri ile ilgili tüm veri hazırlıkları tamamlandıktan sonra ön işleme teknikleri ile alt bantlarına ayrılan ve yeniden elde edilen SYİ kuraklık zaman serileri, tüm istasyonlar için bağımsız ve hibrit tahmin modellerinde eğitime ve test verisi şeklinde girdi değişkeni olarak kullanılmıştır. İstasyonlara ait veri setlerinin %75'i eğitime, %25'i ise test verisi olarak alınmıştır. Tahmin modellerinde; YSA, USBÇS, GSR, DVMR makine öğrenmesi yöntemleri ile UKSB derin öğrenme yöntemi kullanılmıştır. Bu yöntemler, özellikle hidrometeoroloji alanında yapılan daha önceki çalışmalarda gösterdikleri tahmin performanslarına göre seçilmiştir [86, 91, 93, 210, 211, 212]. Model gelişimde detaylı bir şekilde anlatıldığı üzere her bir makine ve derin öğrenme yöntemi için sayıca fazla, çok yönlü ve farklı kombinasyonlara imkân veren model parametreleri seçilmiştir.

USBÇS tahmin modellerinde genellikle 3 üyelik sayısına sahip gaussmf-constant fonksiyonları en başarılı sonuçları vermiştir. İterasyon sayısının artması ise model performanslarını önemli ölçüde artırmamıştır. Bunun aksine YSA tahmin modellerinde hem nöron sayısı hem de iterasyon sayısı arttıkça modellerden daha başarılı sonuçlar elde edilmiştir. YSA tahmin modellerinde, transfer ve aktivasyon fonksiyonu kombinasyonları içerisinde logsig-purelin fonksiyonları genel olarak daha başarılı sonuçlar vermiştir. DVMR tahmin modellerinde ele alınan çekirdek fonksiyonları içerisinde radyal tabanlı fonksiyon (rbf) ve Gauss fonksiyonları, polinom ve doğrusal

fonksiyonlarına göre daha üstün sonuçlar vermiş olup sonuçları birbirine çok yakındır. GSR tahmin modellerinde çok sayıda radyal tabanlı fonksiyon ve çekirdek fonksiyonu denenmiş olup çekirdek fonksiyonları bu yöntemle ait modellerde daha üstündür. Çekirdek fonksiyonları içerisinde de ard karesel üstel (ardsquaredexponential) fonksiyonu diğerlerine göre genelde daha üstün sonuçlar vermiştir. UKSB tahmin modellerinde ise hem nöron sayısı hem de döngü sayısı arttıkça tahmin başarısı artmaktadır. Öğrenme algoritmaları arasında ise Adam algoritması, SGDM ve RMSProp algoritmalarına göre daha üstün tahmin başarılarına ulaşmıştır.

Tüm yöntemlere ait analizlerin yapıldığı Sakarya, Ankara, Kütahya ve Emirdağ istasyonlarında en üstün tahmin modelleri, ya bağımsız UKSB modeli ya da VMA-UKSB hibrit modeli olarak bulunmuştur. Çalışmanın genelinde de, UKSB derin öğrenme yöntemine ait tüm bağımsız ve hibrit tahmin modelleri çok başarılı sonuçlar vermiştir. Ayrıca UKSB yöntemine ait tahmin modelleri, diğer USBÇS, YSA, GSR ve DVMR yöntemlerine ait modellere göre tahmin performansı bakımından üstünlük sağlamıştır. UKSB tahmin modellerine en çok yaklaşan modeller ise VMA-YSA, VMA-GSR ve ADD-YSA modelleri olmuştur. Ön işleme teknikleri içerisinde de VMA tekniği bu çalışmada öne çıkmış olup kuraklık zaman serilerini alt bantlarına ayırtırmada, literatürde oldukça yaygın kullanımı olan ADD ve diğer bir yöntem olan AMA'a göre daha başarılı sonuçlar vermiştir. VMA ön işleme tekniğinin diğer yöntemlerle beraber oluşturduğu hibrit modellerde de başarısı oldukça iyidir. Örneğin; Sakarya istasyonu SYİ-1 zaman ölçeğinde VMA-YSA hibrit modelinin test sonuçlarına ait performans kriterlerine ($OKH=0,060$, $KOKH=0,245$, $NSE=0,939$, $OI=0,946$, $OMH=0,200$ ve $R^2=0,940$) bakıldığında sonuçların oldukça iyi olduğu görülmüştür. Aynı zaman ölçeğinde YSA'nın diğer hibrit modellerine bakıldığında ise; ADD-YSA hibrit modelinin performans kriterlerinin ($OKH=0,148$, $KOKH=0,385$, $NSE=0,846$, $OI=0,887$, $OMH=0,301$ ve $R^2=0,851$) ve AMA-YSA hibrit modelinin performans kriterlerinin ($OKH=0,341$, $KOKH=0,584$, $NSE=0,646$, $OI=0,768$, $OMH=0,471$ ve $R^2=0,880$), VMA-YSA hibrit modelinin gerisinde kaldığı görülmüştür. Çalışmanın genelinde bu şekilde benzer sonuçlar görülmüştür. Daha önce bulgulara verilen ilgili tablolardan görüleceği üzere, ADD ile AMA teknikleri kendi içerisinde karşılaştırıldığında ise ADD tekniği daha başarılıdır. Bundan dolayı bu çalışmada, ADD

ve AMA tekniklerinin karşılaştırıldığı bazı çalışmalarla [86, 213] kıyaslandığında benzer ve tutarlı sonuçlara ulaşıldığı görülmüştür.

Yukarıda belirtilen dört istasyonun tahmin modelleri incelendiğinde bağımsız USBÇS, YSA, GSR, DVMR tahmin modellerinin başarıları oldukça düşük kalmıştır. Yine Sakarya istasyonu SYİ-1 zaman ölçeğinden örnek vermek gerekirse; bağımsız USBÇS modelinin test sonuçlarına ait performans kriterleri ($OKH=1,566$, $KOKH=1,252$, $NSE=-0,628$, $OI=0,069$, $OMH=0,921$ ve $R^2=0,002$), bağımsız YSA modelinin test sonuçlarına ait performans kriterleri ($OKH=1,220$, $KOKH=1,105$, $NSE=-0,268$, $OI=0,263$, $OMH=0,876$ ve $R^2=0,164$), bağımsız GSR modelinin test sonuçlarına ait performans kriterleri ($OKH=1,013$, $KOKH=1,007$, $NSE=-0,053$, $OI=0,380$, $OMH=0,809$ ve $R^2=0,054$) ve bağımsız DVMR modelinin test sonuçlarına ait performans kriterleri ($OKH=1,247$, $KOKH=1,117$, $NSE=-0,296$, $OI=0,248$, $OMH=0,870$ ve $R^2=0,293$) oldukça zayıf ve kabul edilemez değerlere sahiptir. Bağımsız modeller içerisinde yalnızca bağımsız UKSB tahmin modellerinden kabul edilebilir ve başarılı sonuçlar elde edilmiştir. Bağımsız modellerin tahmin performansları da yine çalışmanın genelinde benzer sonuçlar vermiştir.

Sadece UKSB yöntemine ait bağımsız ve hibrit modellerin ele alındığı altı istasyonda da daha önceki istasyonlarda olduğu gibi test sonuçlarına ait performans kriterlerine göre yine bağımsız UKSB modeli ve VMA-UKSB hibrit modelinin büyük bir oranda diğer modellere üstünlük sağladığı görülmüştür. Bununla birlikte UKSB derin öğrenme yöntemine ait tüm modellerde test sonuçlarının performans kriterleri oldukça başarılıdır. Burada diğer dört istasyondan farklı olarak Geyve istasyonu SYİ-3 zaman ölçeği ve Ilgın istasyonu SYİ-6 zaman ölçeği için ADD-UKSB hibrit modeli en başarılı sonuçları vermiştir.

Bu çalışma, benzer nitelikteki diğer çalışmalarla [56, 57, 58, 61, 62, 64, 86, 87 ve 93] kıyaslandığında; hem veri ön işleme teknikleri hem de tahmin yöntemleri açısından daha kapsamlıdır hem de kuraklık tahmin modellerinden daha üstün sonuçlar elde edilmiştir.

Tüm bunlara ek olarak; bu çalışmada kabul edebileceğimiz en önemli sınır, kuraklık tahmininde meteorolojik değişken olarak sadece yağış değişkeninin ele alınması ve bundan dolayı sadece yağışa bağlı hesaplanabilen SYİ kuraklık indisinin

kullanılmasıdır. Ayrıca Sakarya havzasında yer alan istasyonların kuraklık tahminleri yapıldıktan sonra her bir zaman ölçeği için alansal kuraklık haritalarının elde edilmemesi de çalışmanın sınırlarındandır.

4.2. Sonuç ve Öneriler

Bu tez çalışmasında; Türkiye'nin kuzeybatısında yer alan ve önemli nehir havzalarından biri olan Sakarya havzasındaki 10 adet istasyonun uzun dönem aylık yağış verileri kullanılmıştır. Yağış değişkenine bağlı olarak kolaylıkla hesaplanabilen ve yaygın bir kullanımı olan Standartlaştırılmış Yağış İndeksi (SYİ) kuraklık değerleri 1, 3, 6 ve 12 aylık kısa zaman ölçekleri için elde edilmiştir. Heaplanan bu SYİ kuraklık zaman serileri; Ayrik Dalgacık Dönüşümü (ADD), Ampirik Mod Ayırıştırma (AMA) ve Varyasyonel Mod Ayırıştırma (VMD) ön işleme tekniklerine tabi tutularak alt bantlarına ayrılmış olup, böylece kuraklık zaman serileri yeniden elde edilmiştir. SYİ kuraklık zaman serileri; Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (USBÇS), Yapay Sinir Ağları (YSA), Gauss Süreç Regresyonu (GSR), Destek Vektör Makine Regresyonu (DVMR) ve Uzun-Kısa Süreli Bellek (UKSB) yöntemlerinin bağımsız ve hibrit modellerinde eğitime ve test verisi şeklinde girdi değişkeni olarak analiz edilmiştir. Analizler, MATLAB 2021b yazılımında geliştirilen kodlar aracılığı ile tamamlanmıştır. Böylece bağımsız ve hibrit modeller üzerinden istasyonların kısa dönem meteorolojik kuraklığı tahmin edilmiştir.

Çalışmada; Sakarya havzasını temsilen seçilen 10 adet istasyonun ham yağış verilerine homojenlik, durağanlık ve bağımsızlık testleri uygulanmıştır. İstasyonların ham yağış verilerine uygulanan testlere ait istatistiksel sonuçlara göre, istasyon verilerinin tamamı homojen, durağan ve bağımsız çıkmıştır. Yağış verileri ile ilgili herhangi bir tutarsızlık ya da şüpheli durum söz konusu değildir.

Havzayı temsilen seçilen 10 adet istasyonun aylık yağış verileri kullanılarak, DrinC yazılımı ile SYİ kuraklık değerleri elde edilmiştir. DrinC yazılımı, kuraklık indislerinin hesabını oldukça kolaylaştırmakta olup, işlem yükünden ve zamandan ciddi oranda tasarruf sağlayan bir yazılımdır. Standartlaştırılmış Yağış İndeksi (SYİ), Kuraklık Keşif İndisi (KKİ), Akım Kuraklık İndisi (AKİ) ve Onluklar indislerinin ele alındığı çalışmalarda DrinC yazılımının kullanılması önerilmektedir. Ayrıca bu yazılım ücretsiz olup tüm araştırmacılara, kamu kurum ve kuruluşlarına da açıktır.

Seilen bu 10 istasyonun mevcut durumdaki SYİ kuraklık sınıfı, normale yakın olarak bulunmuştur. İstasyonlarda görölen kuraklık sınıflarının oluşum yüzdeleri genel olarak benzer bir eğilimdedir. SYİ-1 ve SYİ-12 zaman ölçeklerinde aşırı nemli ya da aşırı kurak dönemler çok az görölmüştür. Havzadaki bu 10 istasyon için mevcut kuraklık durumunun homojen bir dağılımda olduđu söylenebilir.

SYİ kuraklık zaman serilerinde, dikkate alınan 10 gecikme zamanına kadar %95 güven aralığında otokorelasyon varlığı mevcut değildir.

Dalgacık dönüşümü ile orijinal SYİ kuraklık zaman serilerine ait veri seti, alt bantlarına ayrılarak daha kısa ve öz nitelikleri daha yüksek bir formda yeniden elde edilmiştir. Dalgacık dönüşümünde, Ayrık Dalgacık Dönüşümü (ADD) tekniğı uygulanmıştır. Dalgacık dönüşümü ile ilgili yapılan analizler sonucunda; SYİ-1, SYİ-3, SYİ-6 zaman ölçeklerinde, Meyer'in Ayrık Yaklaşımı (Discrete approximation of Meyer-dmey) dalgacık ailesinin kuraklık zaman serileri ile daha uyumlu olduđu ve alt bantlarına ayırmada üstün performans gösterdiği görölmüştür. SYİ-12 zaman ölçeğinde ise Symlets (sym3) dalgacık ailesi iyi bir performans göstermiştir. Ayrıca, bu çalışmada dalgacık dönüşümünde gecikme zamanının ve dalgacık bant seviyelerinin artması model performansını önemli ölçüde iyileştirmemiştir. Dalgacık dönüşümü analizleri sonucunda; 3 gecikme zamanı (t, t-1, t-2, t-3 girdi değişkeni) ve 3. bant seviyesi optimum değerler olarak bulunmuştur. Sadece SYİ-6 zaman ölçeğinde 4. bant seviyesi daha iyi bir performans göstermiştir.

Dalgacık dönüşümünde olduđu gibi Ampirik Mod Ayrıştırma (AMA) ve Varyasyonel Mod Ayrıştırma (VMA) ön işleme teknikleri, daha nitelikli bir veri seti oluşturmak amacıyla SYİ kuraklık zaman serilerine uygulanarak alt bantlarına ayrılmıştır. AMA tekniğinde 2D bant seviyesi, VMA tekniğinde ise 4D ve 5D bant seviyeleri iyi bir başarı göstermişlerdir. AMA tekniğinde bant seviyesinin artması ile birlikte model performansları iyileşmezken, VMA tekniğinde ise bant seviyesi arttıkça daha başarılı tahmin modelleri elde edilmiştir. VMA bant seviyesi, bu çalışmada 2D'den 5D'e kadar incelendiğinden dolayı, VMA tekniğinin ele alınacağı ileriki çalışmalarda bant seviyesinin daha fazla artırılması ile sonuçların nasıl değişebileceğı detaylıca araştırılmalıdır.

ADD, AMA ve VMA ön işleme tekniklerinin uygulanmadığı bağımsız USBÇS, YSA, GSR ve DVMR tahmin modelleri, çalışmada dikkate alınan performans kriterlerine göre oldukça zayıf tahmin performansları göstermişlerdir. Kuraklık zaman serilerinin ele alınacağı tahmin çalışmalarında bu makine öğrenmesi yöntemlerine dayalı modellerin ön işleme teknikleri ile desteklenmesi önerilmektedir.

Bu çalışmada; Uzun-Kısa Süreli Bellek (UKSB) derin öğrenme yöntemine ait bağımsız ve hibrit tahmin modelleri, çok başarılı sonuçlar vermiştir. Diğer bağımsız makine öğrenmesi modellerinin aksine bağımsız UKSB modellerinin tahmin performansları da oldukça üstündür. Veri ön işleme teknikleri uygulanmamasına rağmen hem eğitim hem de test sonuçlarına göre bağımsız UKSB modellerinin tahmin kapasitesi çok yüksektir. Bağımsız UKSB tahmin modellerinin bu başarısının, ön işleme tekniklerine olan ilgiyi azaltacağı düşünülmektedir. UKSB'nin hibrit modelleri içerisinde ise VMA-UKSB hibrit modeli diğer hibrit modellere göre daha üstündür. UKSB tahmin modellerinden elde edilen en olumsuz sonuç, veri sayısının azalması ile tahmin performansının düşmesidir. Ayrıca, UKSB yönteminde işlem yükü ve süresi diğer makine öğrenmesi yöntemlerine kıyasla daha fazladır.

VMA-YSA, VMA-GSR ve ADD-YSA hibrit tahmin modellerinin performansları, UKSB tahmin modellerine oldukça yakındır. Kuraklık tahmin çalışmalarında bu modellerin de mutlaka değerlendirilmesi önerilmektedir.

Çalışmada kullanılan ADD, AMA ve VMA ön işleme teknikleri arasında, VMA tekniği diğerlerine göre daha üstündür. VMA'nın hemen hemen her yöntemle uyumlu olduğu görülmüştür. ADD ile AMA teknikleri karşılaştırıldığında ise ADD tekniği daha başarılı sonuçlar vermiştir. Özellikle elektronik, haberleşme, biyomedikal ve tıp gibi alanlarda yaygın kullanılan VMA tekniğinin hidrometeorolojik değişkenlerin ele alındığı çalışmalarda kullanılması model performanslarının iyileştirilmesi adına önemlidir.

Kuraklığın tespiti, izlenmesi ve geleceğe yönelik öngörülerin yapılabilmesi için bilim ve teknolojik gelişmelerden yararlanılmalıdır. Son yıllarda hemen hemen tüm sektörlerde yaygın olarak kullanılan makine öğrenmesi ve derin öğrenme yöntemlerinin kuraklık analizlerinde de dikkate alınması gerekir. Bu çalışmada sadece yağış değişkenine bağlı olarak meteorolojik kuraklık analiz edilmiştir. Kuraklık analizlerinde kuraklığın en önemli değişkeni olan yağış parametresi ile birlikte diğer meteorolojik ve iklimsel

parametreler de kuraklık tahmin modellerine dâhil edilmelidir. Bu şekilde elde edilen modeller daha kompleks olacağından bu kuraklık modellerini çözebilmek için en uygun tekniklerin yapay zekâ ve yapay zekânın alt dallarında yer alan yöntemlerin olacağı aşikârdır. Özellikle son dönemin en gelişmiş öğrenme algoritmaları olan derin sinir ağları ve derin öğrenme algoritmaları yaygın bir şekilde kuraklık çalışmalarında dikkate alınmalıdır.



KAYNAKÇA

- [1] World Economic Forum, 2023. The Global Risks Report 2023, Geneva.
- [2] Tsakiris, G., Loukas, A., Pangalou, D., Vangelis, H., Tigkas, D., Rossi, G., Cancelliere, A., 2007. Drought characterization, 85–102. *In: Drought Management Guidelines Technical Annex.* (Eds: A. Iglesias, M. Moneo, A. Lopez-Francos) CIHEAM/ECMEDA Water, Zaragoza.
- [3] Heim, Jr R. R., 2002. A review of twentieth-century drought indices used in the United States. **Bulletin of the American meteorological Society**, **83** (8): 1149–1166.
- [4] Sırdaş, S., 2002. Meteorolojik Kuraklık Modellemesi ve Türkiye Uygulaması. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 237s.
- [5] Çevre ve Orman Bakanlığı Devlet Meteoroloji İşleri Genel Müdürlüğü, 2005. Klimatoloji-1. DMİ Yayınları 2005 (1), Ankara, 227s.
- [6] T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, 2023. (Web sayfası: <https://www.mgm.gov.tr/iklim/iklim.aspx?key=B>), (Erişim tarihi: Ocak 2023).
- [7] Türkeş, M., 2013. İklim değişiklikleri: Kambriyen’den Pleyistosene, Geç Holosen’den 21. Yüzyıl’a. **Ege Coğrafya Dergisi**, **22** (1): 1–25.
- [8] United Nations, 1992. United Nations Framework Convention on Climate Change, Rio de Janeiro.
- [9] Türkeş, M., 2006. Küresel iklimin geleceği ve Kyoto protokolü. **Jeopolitik**, **29**: 99–107.
- [10] ABD Ulusal Okyanus ve Atmosfer Yönetimi, 2023. (Web sayfası: <https://www.noaa.gov/>), (Erişim tarihi: Ocak 2023).
- [11] IPCC, 2014. Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, Pachauri, R. K., Meyer, L. A.,(eds.)]. Geneva, Switzerland, 151.

- [12] Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü, 2023. (Web sayfası: <https://meteoroloji.boun.edu.tr/iklimdegisimi.php>), (Erişim tarihi: Ocak 2023).
- [13] Kadioğlu, M., 2008. Kuraklık kıranı risk yönetimi, 277–300. *In: Afet Zararlarını Azaltmanın Temel İlkeleri*, (Eds: M. Kadioğlu, E. Özdamar). Japonya Uluslararası İşbirliği Ajansı (JICA) Türkiye Ofisi Yayınları No: 2, Ankara.
- [14] Partigöç, N. S., Soğancı, S., 2019. Küresel iklim değişikliğinin kaçınılmaz sonucu: kuraklık. **Dirençlilik Dergisi**, 3 (2): 287–299.
- [15] Sabancı Üniversitesi ve İstanbul Politikalar Merkezi, 2023. (Web sayfası: <https://ipc.sabanciuniv.edu/Content/Images/CKeditorImages/20200326-02030608.pdf>), (Erişim tarihi: Ocak 2023).
- [16] Satoh, Y., Yoshimura, K., Pokhrel, Y., Kim, H., Shiogama, H., Yokohata, T., Hanasaki, N., et al. 2022. The timing of unprecedented hydrological drought under climate change. **Nature Communications**, 13: 3287.
- [17] United Nations, 1997. Action Plan to Combat Desertification United Nations Conference on Desertification-UNCOD, Roma, Italy.
- [18] Svoboda, M. D., Fuchs, B. A., 2016. Handbook of drought indicators and indices. World Meteorological Organization (WMO), Geneva, Switzerland: 1–44.
- [19] World Meteorological Organization, 2022. Integrated Drought Management Programme (IDMP), Geneva, Switzerland.
- [20] Öztürk, K., 2002. Küresel iklim değişikliği ve Türkiye’ye olası etkileri. **Gazi Eğitim Fakültesi Dergisi**, 22 (1): 47–65.
- [21] Minarecioğlu, N., 2021. Kuraklığın Kızılırmak Havzasına Ait Yerüstü ve Yeraltı Su Kaynaklarına Etkisinin Araştırılması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 227s.
- [22] Yetmen, H., 2013. Türkiye’nin Kuraklık Analizi. Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Ankara, 194s.
- [23] Wilhite, D. A., 2000. Drought as a natural hazard: concepts and definitions. **Routledge Publishers**, 3–18.

- [24] Nagarajan, R., 2010. Drought assessment. **Springer**, 429.
- [25] Türkeş, M., 1990. Türkiye'de Kurak Bölgeler ve Önemli Kurak Yıllar. İstanbul Üniversitesi Deniz Bilimleri ve Coğrafya Enstitüsü, Doktora Tezi, İstanbul, 195s.
- [26] IPCC, 2021. Climate Change 2021: Report The Physical Science Basis. Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York.
- [27] Madadgar, S., AghaKouchak, A., Farahmand, A., Davis, S. J., 2017. Probabilistic estimates of drought impacts on agricultural production. **Geophysical Research Letters**, **44**: 7799–7807.
- [28] Wilhite, D. A., Buchanan, Smith, M., 2005. Drought as hazard: understanding the natural and social context, 3–29. *In*: Proceeding of Drought and Water Crises (Eds: D. A. Wilhite). Science, Technology, and Management Issues. CRC Press, Boca Raton, Florida.
- [29] Doğan, S., 2013. Konya Kapalı Havzası Kuraklık Karakterizasyonunun Zamansal Konumsal Analizi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Konya, 110s.
- [30] T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, 2023. (Web sayfası: <https://mgm.gov.tr/veridegerlendirme/kuraklik-analizi.aspx>), (Erişim Tarihi: Ocak 2023).
- [31] Özfidaner, M., 2020. Türkiye Ölçeğinde Yağış ve Akım Kuraklık İndeksi ile Kuraklık Analizi ve Kurak Olma Olasılıklarının Belirlenmesi. Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Adana, 277s.
- [32] Dracup, J. A., K. S. Lee, K. S., Paulson Jr, E. G., 1980. On the definition of droughts. **Water Resources Research**, **16** (2): 297–302.
- [33] Palmer, W. C., 1965. Meteorological drought. **Weather Bureau Research Paper**, **45**: 1–58.
- [34] McKee, T. B., Doesken, N. J., Kleist, J., 1993. The relationship of drought frequency and duration to time scales, 179–183. *Proceedings of the 8th Conference on Applied Climatology*, 1993, Boston.

- [35] Vicente-Serrano, S. M., Beguería, S., López-Moreno, J. I., 2010. A Multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. **Journal of Climate**, **23** (7): 1696–1718.
- [36] Willeke, G., Hosking, J. R. M., Wallis, J. R., Guttman, N. B., 1994. The national drought atlas. Institute for Water Resources Report 94-NDS-4, U.S. Army Corps of Engineers, Washington, 587.
- [37] Asrari, E., Masoudi, M., Afrough, E., 2011. Analyzing spatial and temporal pattern of humid, normal and drought years using percent of normal precipitation index (PNPI) in Fars province, Iran. **Journal of Applied Sciences in Environmental Sanitation**, **6** (3): 299–308.
- [38] Erinç, S., 1965. Yağış müessiriyeti üzerine bir deneme ve yeni bir indis. İstanbul: İstanbul Üniversitesi Coğrafya Enstitüsü Yayınları No:41.
- [39] Gibbs, W., Maher, J., 1967. Rainfall deciles as drought indicators. **Bureau of meteorology bulletin**, **48**: 29.
- [40] Wu, H., Hayes, M. J., Weiss, A., Hu, Q., 2001. An evaluation of the standardized precipitation index, the China-Z index and the statistical Z-score. **International Journal of Climatology**, **21**: 745–758.
- [41] Palmer, W. C., 1968. Keeping track of crop moisture conditions, nationwide: the new crop moisture index. **Weatherwise**, **21** (4), 156–161.
- [42] Juhasz, T., Kornfield, J., 1978. The crop moisture index: unnatural response to changes in temperature. **Journal of Applied Meteorology**, **17**: 1864–1865.
- [43] World Meteorological Organization (WMO) and Global Water Partnership (GWP), 2016. Handbook of Drought Indicators and Indices (Eds: M. Svoboda, B. A. Fuchs). Integrated Drought Management Programme (IDMP), Integrated Drought Management Tools and Guidelines Series 2, Geneva.
- [44] Laguardia, G., Niemeyer, S., 2008. On the comparison between the LISFLOOD modelled and the ERS/SCAT derived soil moisture estimates. **Hydrology and Earth System Sciences**, **12**: 1339–1351.
- [45] Nalbantis, I., Tsakiris, G., 2008. Assessment of hydrological drought revisited. **Water Resources Management**, **23** (5): 881–897.

- [46] Shukla, S., Wood, A. W., 2008. Use of a standardized runoff index for characterizing hydrologic drought. **Geophysical Research Letters**, 35.
- [47] Bloomfield, J. P., Marchant, B. P., 2013. Analysis of groundwater drought building on the standardised precipitation index approach. **Hydrology and Earth System Sciences**, 17: 4769–4787.
- [48] Shafer, B. A., Dezman, L. E., 1982. Development of a surface water supply index (SWSI) to assess the severity of drought conditions in snowpack runoff areas, 164–175. *Proceedings of 50th Annual the Western Snow Conference*, Colorado State University, Fort Collins, CO.
- [49] Shin, H. S., Salas, J. D., 2000. Regional drought analysis based on neural networks. **Journal of Hydrologic Engineering**, 5 (2): 145–155.
- [50] Kim, T. W., Valdes, J. B., 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. **Journal of Hydrologic Engineering**, 8 (6): 319–328.
- [51] Mishra, A. K., Desai, V. R., Singh, V. P., 2007. Drought forecasting using a hybrid stochastic and neural network model. **Journal of Hydrologic Engineering**, 12 (6): 626–638.
- [52] Karamouz, M., Rasouli, K., Nazif, S., 2009. Development of a hybrid index for drought prediction: case study. **Journal of Hydrologic Engineering**, 2009 (14): 617–627.
- [53] Karavitis, C. A., Alexandris, S., Tsismelis, D. E., Athanasopoulos, G., 2011. Application of the Standardized Precipitation Index (SPI) in Greece. **Water** 2011, 3: 787–805.
- [54] Chen, J., Jin, Q., Chao, J., 2012. Design of deep belief networks for short-term prediction of drought index using data in the Huaihe River Basin. **Mathematical Problems in Engineering**, 2012: 1–16.
- [55] Xie, H., Ringler, C., Zhu, T., Waqas, A., 2013. Droughts in Pakistan: A spatiotemporal variability analysis using the standardized precipitation index. **Water International**, 38 (5): 620–631.
- [56] Belayneh, A., Adamowski, J., Khalil, B., 2016. Short-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet transforms and

- machine learning methods. **Sustainable Water Resources Management**, 2: 87–101.
- [57] Mokhtarzad, M., Eskandari, F., Vanjani, N. J., 2017. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. **Environmental Earth Sciences**, 76: 729.
- [58] Agana, N. A., Homaifar, A., 2018. EMD-based predictive deep belief network for time series prediction: an application to drought forecasting. **Hydrology**, 5 (1): 18.
- [59] Poornima, S., Pushpalatha, M., 2019. Drought prediction based on SPI and SPEI with varying timescales using LSTM recurrent neural network. **Soft Computing**, 23 (18): 8399–8412.
- [60] Huang, C. Y., Zhang, Y. P., 2019. Drought prediction based on copula entropy and general regression neural network. **Applied Ecology And Environmental Research**, 17 (6): 14415–14424.
- [61] Dikshit, A., Pradhan, B., Huete, A.R., 2020. Spatial meteorological drought forecasting using deep learning for New South Wales, Australia. American Geophysical Union 2020.
- [62] Kaur, A., Sood, S. K., 2020. Deep learning based drought assessment and prediction framework. **Ecological Informatics**, 57: 101067.
- [63] Fadaei-Kermani, E., Ghaeini-Hessaroeiyeh, M., 2020. Fuzzy nearest neighbor approach for drought monitoring and assessment. **Applied Water Science**, 10: 130.
- [64] Mokhtar, A., Jalali, M., He, H., Al-Ansari, N., Elbeltagi, A., Alsafadi, K., Abdo, H. G., Sammen, S. S., Gyasi-Agyei, Y., Rodrigo-Comino, J., 2021. Estimation of SPEI meteorological drought using machine learning algorithms. **IEEE Access**, 9: 65503–65523.
- [65] Maity, R., Khan, M. I., Sarkar, S., Dutta, R., et al., 2021. Potential of Deep Learning in drought assessment by extracting information from hydrometeorological precursors. **Journal of Water and Climate Change**, 12 (6): 2774–2796.

- [66] Salimi, H., Asadi, E., Darbandi, S., 2021. Meteorological and hydrological drought monitoring using several drought indices. **Applied Water Science**, **11**: 2021.
- [67] Wu, X., Zhou, J., Yu, H., Liu, D., Xie, K., Chen, Y., Hu, J., Sun, H., Xing, F., 2021. The development of a hybrid Wavelet-ARIMA-LSTM model for precipitation amounts and drought analysis. **Atmosphere (Basel)**, **12**: 74.
- [68] Docheshmeh, G. A., Alizamir, M., Kisi, O., Elshafie, A., 2022. Drought modelling by standard precipitation index (SPI) in a semi-arid climate using deep learning method: long short-term memory. **Neural Computing and Application**, **34**: 2425–2442.
- [69] Filipović, N., Brdar, S., Mimić, G., Marko, O., 2022. Regional soil moisture prediction system based on Long Short-Term Memory network. **Biosystems Engineering**, **213**: 30–38.
- [70] Zhao, Y., Zhang, J., Bai, Y., Zhang, S., Yang, S., Henchiri, M., Seka, A. M., Nanzad, L., 2022. Drought monitoring and performance evaluation based on machine learning fusion of multi-Source remote sensing drought factors. **Remote Sensing** **2022**, **14** (24): 6398.
- [71] Tanoğlu, A., 1943. Türkiye'nin kuraklık indisleri. **Türk Coğrafya Dergisi**, **1**: 36–41.
- [72] Tümertekin, E., 1955. Türkiye’de buğday yetiştirme devresi ile kurak aylar arasındaki zaman münasebeti. **Türk Coğrafya Dergisi**, **13–14**: 107–124.
- [73] Erinç, S., 1957. Tatbiki Klimatoloji ve Türkiye İklimi. İTÜ Hidrojeoloji Enstitüsü.
- [74] Erdogan, F., 1989. Türkiye’de yaygın kuraklıklar. **TMMOB Meteoroloji Mühendisleri Odası Bülteni**, **2**: 14.
- [75] Türkeş, M., 1996. Spatial and temporal analysis of annual rainfall variations in Turkey. **International Journal of Climatology**, **16**: 1057–1076.
- [76] Kömüşçü, A. Ü., 1999. Using the SPI to analyze spatial and temporal patterns of drought in Turkey. **Drought Network News**, **11**: 7–11.

- [77] Sırdaş, S., Şen, Z., 2001. Application of the standardized precipitation index (SPI) to the Marmara region, Turkey. **Integrated Water Resources Management IAHS Publications**, 272.
- [78] Keskin, M. E., Terzi, Ö., Taylan, E. D., 2008. Göller Bölgesi Meteorolojik Kuraklık Analizi. TÜBİTAK Çevre, Atmosfer, Yer ve Deniz Bilimleri Araştırma Grubu, Proje No: 106-Y-300, Isparta, 85s.
- [79] Bacanlı, U. G., Firat, M., Dikbas, F., 2009. Adaptive neuro-fuzzy inference system for drought forecasting. **Stochastic Environmental Research and Risk Assessment**, **23** (8): 1143–1154.
- [80] Biçkici, A. B., Kahya, E., 2016. Long term PDSI drought forecasting using genetic programming: a case study in Konya province, Turkey. *Soft Computing Methods in Water Resources Engineering*, November 29, 2016, Nicosia, North Cyprus.
- [81] Katip, A., 2018. Meteorological drought analysis using artificial neural networks for Bursa city, Turkey. **Applied Ecology and Environmental Research**, **16** (3): 3315–3332.
- [82] Hezarani, A. B., 2018. Farklı Kuraklık Analiz Yöntemlerinin Yeşilirmak Havzasında İrdelenmesi. Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Samsun, 166s.
- [83] Başakın, E. E., Ekmekçioğlu, Ö., Özger, M., 2019. Makine öğrenmesi yöntemleri ile kuraklık analizi. **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, **25** (8): 985–991.
- [84] Başakın, E. E., Ekmekcioglu, Ö., Özger, M., 2020. Drought prediction using hybrid soft-computing methods for semi-arid region. **Modeling Earth Systems and Environment**, **7**: 2363–2371.
- [85] Katipoğlu, O. M., 2020. Fırat Havzasındaki Meteorolojik ve Hidrolojik Kuraklıkların Analizi. Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Erzurum, 291s.
- [86] Özger, M., Başakın, E., E., Ekmekcioğlu, Ö., Hacısüleyman, V., 2020. Comparison of wavelet and empirical mode decomposition hybrid models in drought prediction. **Computers and Electronics in Agriculture**, **179**: 105851.

- [87] Altunkaynak, A., Jalilzadnezamabad, A., 2021. Extended lead time accurate forecasting of palmer drought severity index using hybrid wavelet-fuzzy and machine learning techniques. **Journal of Hydrology**, **601**: 126619.
- [88] Duvan, A., Aktürk, G., Yıldız, O., 2021. Meteorolojik kuraklığın zamansal ve alansal özelliklerine iklim değişikliğinin etkisi, Sakarya havzası örneği. **Mühendislik Bilim ve Araştırmaları Dergisi**, **3** (2): 207–217.
- [89] Mehr, A. D., Safari, M. J. S., Nourani. V., 2021. Wavelet packet-Genetic programming: a new model for meteorological drought hindcasting. **Teknik Dergi**, **32** (4): 11029–11050.
- [90] Sekendur, F., 2022. Standartlaştırılmış Yağış Evapotranspirasyon İndeksinin (SPEI) Farklı Evapotranspirasyon Metotlarıyla Hesaplanması ve Türkiye Ölçeğinde SPI ile Karşılaştırmalı Kuraklık Analizi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 126s.
- [91] Citakoglu, H., Coşkun, Ö., 2022. Comparison of hybrid machine learning methods for the prediction of short-term meteorological droughts of Sakarya Meteorological Station in Turkey. **Environmental Science and Pollution Research**, **29** (50): 75487–75511.
- [92] Latifoğlu, L., 2022. Derin sinir ağları modeli ile standardize yağış indeksi tahmini. **Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, **11** (4): 1006–1024.
- [93] Alkan, A., 2022. Optimizasyon teknikleri kullanılarak kuraklık hibrit tahmin modeli geliştirilmesi. Eskişehir Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Doktora Tezi, Eskişehir, 147s.
- [94] Danandeh, M. A., Ghiasi. A. R., Yaseen, Z. M., Sorman, A. U., Abualigah, L., 2022. A novel intelligent deep learning predictive model for meteorological drought forecasting. **Journal of Ambient Intelligence and Humanized Computing**, **1**: 3.
- [95] Baykal, T., Taylan, D., Terzi, Ö., 2023. Isparta ili için gelecekteki olası meteorolojik kuraklık değerlendirmesi. **Doğal Afetler ve Çevre Dergisi**, **9** (1): 90–100.

- [96] Orman ve Su İşleri Bakanlığı Devlet Su İşleri Genel Müdürlüğü, 2017. Sakarya Havzası Master Plan Nihai Raporu, Ankara.
- [97] Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü, 2018. Sakarya Havzası Taşkın Yönetim Planı Yönetici Özeti, Ankara.
- [98] Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü, 2022. Sakarya ve Susurluk Havzaları Kuraklık Yönetim Planının Hazırlanması Projesi. Sakarya Havzası Kuraklık Yönetim Planı, Stratejik Çevresel Değerlendirme Kapsam Belirleme Raporu, Ankara.
- [99] Büyükkaracıoğlu, N., 2019. Hidrolojik verilerin değişkenlik analizi ve uygulamaları. İksad Yayınevi, Ankara, 108s.
- [100] Tongal, H., 2012. Akarsu Akımlarının Nonlineerlik, Stokastiklik ve Belirsizlik Özelliklerinin Matematiksel Tabanlı Metotlarla İncelenmesi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Isparta, 212s.
- [101] Tosunoğlu, F., 2014. Türkiye’deki Meteorolojik ve Hidrolojik Kuraklıkların Atmosferik Salınımlarla Olan İlişkilerinin İncelenmesi. Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Erzurum, 164s.
- [102] Yalta, A. T., 2011. Zaman Serileri Ekonometrisine Giriş Durağanlık ve Durağan-Dışlılık. TOBB Ekonomi ve Teknoloji Üniversitesi.
- [103] Wijngaard, J. B., Klein Tank, A. M. G., Konnen, G. P., 2003. Homogeneity of 20th century european daily temperature and precipitation series. **International Journal of Climatology**, **23** (6): 679–692.
- [104] Karabörk, M. Ç., Kahya, E., Kömüşçü, A. Ü., 2007. Analysis of Turkish precipitation data: homogeneity and the Southern oscillation forcings on frequency distributions. **Hydrological Processes**, **21** (23): 3203–3210.
- [105] Katipoğlu, O. M., 2020. İstatistiksel homojenlik testleri ile akım verilerindeki değişim noktasının incelenmesi. *Munzur Zirvesi 2. Uluslararası Uygulamalı Bilimler Kongresi*, 31 Mayıs 2020, Tunceli.
- [106] Kahya, E., Arıkan, B. B., Akdeniz, E., 2016. Homogeneity analysis of precipitation series in Turkey. *ACE 2016, 12th International Congress on Advances in Civil Engineering*, 21-23 September 2016, İstanbul.

- [107] Bindak, R., 2014. Mann-Whitney u ile Student's t testinin I.tip hata ve güç bakımından karşılaştırılması: Monte Carlo simülasyon çalışması. **Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi**, 14: 5–11.
- [108] Yüce, M. İ., Aksoy, H., Önöz, B., Çetin, M., Eriş, E. D., Eşit, M., et al. 10. İklim değişikliğinin yağışlar üzerine etkisi: Kahramanmaraş ve Osmaniye örneği, 375–388. *Ulusal Hidroloji Kongresi*, 9 - 12 Ekim 2019, Muğla, Türkiye.
- [109] Al Najjar, H. S. H., 2021. Kuraklığın Gazze Kıyı Akiferine Etkisi ve Geleneksel Olmayan Su Kaynakları Kullanılarak Modellenmesi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya, 104s.
- [110] Alexandersson, H., 1986. A homogeneity test applied to precipitation data. **Journal of Climate**, 6 (6): 661–675.
- [111] Kang, H. M., Yusof, F., 2012. Homogeneity tests on daily rainfall series in Peninsular Malaysia. **International Journal of Contemporary Mathematical Sciences**, 7 (1): 9–22.
- [112] Mann, H. B., Whitney, D. R., 1947. On a test of whether one of two random variables is stochastically larger than the other. **Annals of Mathematical Statistics**, 18: 50–60.
- [113] Çıtakoğlu, H., 2014. L-Momentler Yöntemiyle İç Anadolu'daki Standard Süreli Ekstrem Yağışların Boyut-Süre-Tekerrür Değerlerinin Bölgeselleştirilerek Haritalanması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 441s.
- [114] Dickey, D. A., Fuller, W. A., 1979. Distribution of the estimators for autoregressive time series with a unit root. **Journal of the American Statistical Association**, 74 (366a): 427–431.
- [115] Yavuz, S., 2009. Hataları ardışık bağımlı (otokorelasyonlu) olan regresyon modellerinin tahmin edilmesi. **Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 23 (3), 123–140.
- [116] Sevüktekin, M., Nargeleçekenler, M., 2007. Ekonometrik Zaman Serileri Analizi EViews uygulamalı, Geliştirilmiş 2. Baskı. Nobel Yayın Dağıtım, Ankara.

- [117] Yarar, A., 2010. Susurluk Havzası Yağış Akış Verilerinin Modellenmesi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Konya, 195s.
- [118] Thom, H. C. S., 1958. A note on the Gamma distribution. **Monthly Weather Review**, **86** (4): 117-122.
- [119] Tigkas, D., Vangelis, H., Tsakiris, G., 2015. DrinC: A software for drought analysis based on drought indices. **Earth Science Information**, **8** (3): 697–709.
- [120] Garcia, S., Gallego, S. R., Luengo, J., Benitez, J. M., Herrera, F., 2016. Big data preprocessing: methods and prospects. **Big Data Analytics**, **1** (9).
- [121] Wu, X., Zhu, X., Wu, GQ., Ding, W., 2014. Data mining with big data. **IEEE Transactions on Knowledge and Data Engineering**, **26** (1): 97–107.
- [122] Duran, K., 2013. Rüzgar Karakteristiklerinin Dalgacık Dönüşümü ile Ortaya Konması. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 142s.
- [123] Altıntop, M. Y., 2016. Dalgacık Dönüşümü ve Destek Vektör Makineleri ile Tahmin: BIST Üzerine Bir Uygulama. Uşak Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Uşak, 231s.
- [124] Demren, E., 2015. Dalgacık Dönüşümünün Fourier Dönüşümü ile Karşılaştırılması ve Uygulama. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 157s.
- [125] Selçuk, F., 2005. Dalgacıklar yeni bir analiz yöntemi. **Bilkent Dergisi**, **3**: 12–15.
- [126] Terzi, Ö., Barak, M., 2014. Dalgacık-sinir ağı yaklaşımı ile yağış-akış tahmini: Kızılırmak Nehri örneği. **Tarım Bilimleri Dergisi**, **21** (2015): 546–557.
- [127] İkiz, M., 2006. Wavelet (dalgacık dönüşümü) ve Yapay Sinir ağı Kullanarak Ses Sinyalinden Konuşmacı Tespiti. Dicle Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Diyarbakır, 161s.
- [128] Graps, A., 1995. An introduction to wavelets. **IEEE Computational Science and Engineering**, **2** (2): 50–61.
- [129] Alp, H., 2009. Doğu Akdeniz Bölgesi Jeofizik Verilerine Dalgacık Analiz Yöntemi Uygulanarak Bölgenin Tektonik Yapısının Araştırılması. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 214s.

- [130] Alexandridis, A. K., Zapranis, A. D., 2014. Wavelet Neural Networks: with Applications in Financial Engineering Chaos, and Classification. John Wiley & Sons, New Jersey.
- [131] Chiann, C., Morettin, A. P., 1998. Wavelet analysis for time series. **Journal of Nonparametric Statistics**, **10**: 1–46.
- [132] Gürsakal, S., 2009. Finansal Zaman Serileri Analizine Frekans Boyutu Yaklaşımı: Dalgacıklar Yöntemi ve IMKB’de Bir Uygulama. Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Bursa, 224s.
- [133] Shao, X., Pang, C., Su, Q., 2000. A novel method to calculate the approximate derivative photoacoustic spectrum using continuous wavelet transform. **Fresenius' Journal of Analytical Chemistry**, **367** (6): 525–529.
- [134] Öner, İ. V., Yeşilyurt, M. K., Yılmaz, E. Ç., 2017. Wavelet analiz tekniği ve uygulama alanları. **Ordu Üniversitesi Bilim ve Teknoloji Dergisi**, **7** (1): 42–56.
- [135] Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J. M., 2002. Wavelet Toolbox for Use with MATLAB, User’s Guide. The Mathworks Inc.
- [136] Fugal, D. L., 2009. Conceptual Wavelets in Digital Signal Processing: An in-depth, Practical Approach for the Non-mathematician. Space and Signals Technical Publishing, San Diego, California.
- [137] Miner, N. E., 1998. An introduction to wavelet analysis. Sandia Report, NM, October 1–25, USA.
- [138] Yılmaz, Z., Bozkurt, M. R., 2013. Ayrık dalgacık dönüşümü kullanarak aritmilere ait özniteliklerin çıkarılması. *XIV. Akademik Bilişim Konferansı*, 23–25 Ocak 2013, Antalya.
- [139] MATLAB, 2023. Wavelet toolbox, wavelet families. (Web sayfası: <https://www.mathworks.com/help/wavelet/ug/wavelet-families-aADDITIONAL-discussion.html>), (Erişim tarihi: Ocak 2023).
- [140] Elfouly, F. H., Mahmoud, M. I., Dessouky, M. I. M., Deyab, S., 2008. Comparison between Haar and Daubechies wavelet transformation on FPGA technology. **International Journal of Computer Information, and Systems Science, and Engineering**, **2** (1): 96–101.

- [141] Gençay, R., Selçuk, F., Whitcher, B., 2005. Multiscale systematic risk. **Journal of International Money and Finance**, **24**: 55–70.
- [142] Nielsen, M., 2001. On the construction and frequency localization of finite orthogonal quadrature filters. **Journal of Approximation Theory**, **108** (1): 36–52.
- [143] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N. C., Tung, C. C., Liu, H. H., 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society of London Series A Mathematical Physical Engineering Sciences**, **454**: 903–995.
- [144] Mert, A., 2015. EEG sinyallerinin görgül kip ayrışım yöntemi ile analizi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 114s.
- [145] Özel, P., 2019. Çok Değişkenli Sinyal İşleme Teknikleri Kullanarak EEG ile Duygu Durum Analizi. İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü, Doktora Tezi, İstanbul, 142s.
- [146] Dragomiretskiy, K., Zosso, D., 2014. Variational mode decomposition. **IEEE Transactions on Signal Processing**, **62**: 531–544.
- [147] Mistry, D., Banerjee, A., 2014. Deblurred of image with Wiener filter in MATLAB. **Journal of Emerging Technologies and Innovative Research**, **1** (1).
- [148] Rehman, N., Aftab, H., 2019. Multivariate variational mode decomposition. **IEEE Transactions on Signal Processing**, **67** (23).
- [149] Şimşek B. Ö., Akan, A., Bozkurt, B., 2015. Fundamental frequency estimation for monophonical Turkish music by using VMD, 1022–1025. *23th Signal Processing and Communications Applications Conference (SIU)*, 16–19 May 2015, Malatya.
- [150] Lian, J., Liu, Z., Wang, H., Dong, X., 2018. Adaptive variational mode decomposition method for signal. **Mechanical Systems and Signal Processing** **107**: 53–77.

- [151] Özgür, S. B., 2021. Algoritmalar, yapay zeka, makine öğrenmesi, derin öğrenme ve uygulamaları: beşeri fayda üretiminin yazılımlar tarafından karşılanması. **Ekonomi ve Yönetim Araştırmaları Dergisi**, 10 (1): 1–29.
- [152] Mete, M. O., 2022. Coğrafi Bilgi Sistemleri Entegreli Makine Öğrenmesine Dayalı Toplu Taşınmaz Değerleme Modelinin Geliştirilmesi. İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Doktora Tezi, İstanbul, 168s.
- [153] Arf, C., 1959. Makine Düşünebilir Mi ve Nasıl Düşünebilir?, 91-103. *Atatürk Üniversitesi, Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitimi Yayınları Konferanslar Serisi*, Erzurum.
- [154] Bilgilioglu, S. S., 2018. Makine Öğrenmesi Teknikleri ile Mekansal Karar Destek Sistemlerinin Geliştirilmesi: Aksaray İli Örneği. Aksaray Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Aksaray, 90s.
- [155] Şahin, T., 2022. Dizel Makinanın Makina Öğrenmesi Yöntemi Kullanılarak Modellenmesi ve Karar-Destek Mekanizması Oluşturulması. İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Doktora Tezi, İstanbul, 112s.
- [156] McCulloch, W. S., Pitts, W. A. 1943. A logical calculus of the ideas immanent in nervous activity. **Buttetin of Mathematics and Biophysics**, 5: 115–133.
- [157] Sebe, N., Cohen, I., Garg, A., Huang, T. S., 2005. Machine Learning in Computer Vision: Computational Imaging and Vision. Springer, New York.
- [158] Aktaş, S., 2022. Lojistik Regresyon Analizi ve Makine Öğrenmesi Algoritmaları ile Prostat Kanseri Risk Faktörlerinin Belirlenmesi Üzerine Bir Çalışma. İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü, Doktora Tezi, İstanbul, 71s.
- [159] Alpaydın, E., 2010. Introduction to Machine Learning, 2nd ed., The MIT Press, London.
- [160] İnık, Ö., Ülker, E., 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. **Gaziosmanpaşa Bilimsel Araştırma Dergisi**, 6 (3): 85–104.
- [161] Şeker, A., Diri, B., Balık, H. H., 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. **Gazi Mühendislik Bilimleri Dergisi**, 3 (3): 47–64.

- [162] Bayrakdar, S., 2023. Derin Öğrenme ile Sosyal Ağlarda Radyolojik Görüntü ve Metin Tabanlı Medikal Kavram Tespiti. Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü, Doktora Tezi, Düzce, 90s.
- [163] Öztemel, E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul, 231s.
- [164] Özen, S. B., 2018. KASKİ Atık Su Arıtma Verilerinin Yapay Sinir Ağları ve Bulanık Mantık Yöntemleri ile Tahmin Edilmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 81s.
- [165] Sandy, D., Balkin, D. S., 1997. Using recurrent neural networks for time series forecasting. *1997 International Symposium on Forecasting, Working Paper Series*, Barbados.
- [166] Beale, H. M., Hagan, M. T., Demuth, H. B., 2017. Neural Network Toolbox TM User's Guide R2017a, In MathWorks. The MathWorks, Inc.
- [167] Tarkun, S., 2023. Elektrik Talebinin Zaman Serisi Analizi, Yapay Sinir Ağları ve Hibrit Yöntem ile Tahmini. Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Bursa, 149s.
- [168] Jang, J. S. R., 1993. ANFIS: Adaptive-Neural-Based Fuzzy Inference System. **IEEE Transactions on Systems Man and Cybernetics**, 23: 665–685.
- [169] Zadeh, L. A., 1965. Fuzzy sets. **Information and Control**, 8: 338–353.
- [170] Emiroğlu, İ., 1999. Ana Hatlarıyla Klasik Mantık. Asa, İstanbul, 368 s.
- [171] Kalaycı, D., 2022. PISA'da Başarılı Ülkelerin ve Türkiye'nin Ana Dili Öğretim Programlarının İncelenmesi ve Programların ANFIS ile Analizi. Gazi Üniversitesi Eğitim Bilimleri Enstitüsü, Doktora Tezi, Ankara, 266s.
- [172] Yılmaz, M., Arslan, E., 2005. Bulanık mantığın jeodezik problemlerin çözümünde kullanılması. *Harita ve Kadastro Mühendisleri Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu*, 23-25 Kasım 2005, İTÜ, İstanbul.
- [173] Mamdani, E. H., Assilian, S., 1975. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, 7 (1): 1–13.

- [174] Jang, J-S. R., Sun, C-T., Mizutani, E., 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, New Jersey, USA.
- [175] MATLAB, 2023. Fuzzy Logic toolbox, Mamdani and Sugeno fuzzy inference systems. (Web sayfası: <https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html>), (Erişim tarihi: Şubat 2023).
- [176] Sugeno, M., 1985. *Industrial Applications of Fuzzy Control*. Elsevier Science Publishing Company, New York.
- [177] Cortes, C., Vapnik, V., 1995. Support vector networks. **Machine Learning**, **20**: 293–297.
- [178] Lu, W. Z., Wang, W., Leung, A. Y. T., Lo, S. M., R., Yuen, R. K. K., et al. 2002. Air pollutant parameter forecasting using support vector machines, 630–635. *IJCNN 02, Proceedings of the 2002 International Joint Conference on Neural Networks*, 12–17 May 2002, Honolulu, HI, USA.
- [179] Çomak, E., 2008. Destek Vektör Makinelerinin Etkin Eğitimi için Yeni Yaklaşımlar. Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Konya, 125s.
- [180] Korkmaz, G., Eroğlu, E., 2020. Model karmaşıklığının kontrolü. **İktisadi ve İdari Yaklaşımlar Dergisi**, **2** (2): 146–162.
- [181] Smola, A. J., Schölkopf, B. A., 2004. Tutorial on support vector regression. **Statistics and Computing**, **14**: 199–222.
- [182] Arı, A., Önder, H., 2013. Regression models used for different data structures. **Anadolu Journal of Agricultural Sciences**, **28** (3): 168–174.
- [183] Erdoğan, E., B. Ç., 2019. Rüzgar Hız ve Enerji Verilerinin Tahmini için Kaotik Yaklaşımla Birlikte Destek Vektör Regresyonunun Kullanımı. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 87s.
- [184] Karal, Ö., 2018. Compression of ECG data by support vector regression method. **Journal of the Faculty of Engineering and Architecture of Gazi University**, **33** (2): 743–755.


- [185] Uçak, K., 2002. Destek Vektör Regresyonu ile PID Kontrolör Tasarımı. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 113s.
- [186] İnce, H., İmamoğlu, S. Z., 2016. Destek vektör regresyon ve ikiz destek vektör regresyon yöntemi ile tedarik seçimi. **Doğu Üniversitesi Dergisi**, 17 (2): 241–253.
- [187] Burges, C. J. C., 1998. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, 2: 121–167.
- [188] Göldoğan, E., 2017. Çeşitli Çekirdek Fonksiyonları ile Oluşturulan Destek Vektör Makinesi Modellerinin Performanslarının İncelenmesi: Bir Klinik Uygulama. İnönü Üniversitesi ve Mersin Üniversitesi Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Ortak Doktora Tezi, Malatya-Mersin, 103s.
- [189] Rasmussen, C. E., Williams, C. K. I., 2006. Gaussian Processes for Machine Learning. Massachusetts Institute of Technology, The MIT Press, London.
- [190] Aran, V., 2019. Flexible and Robust Control of Heavy Duty Diesel Engine Airpath Using Data Driven Disturbance Observers and GPR Models. Sabancı University Graduate School of Engineering and Natural Sciences, PhD Thesis, İstanbul, 115s.
- [191] Yüksel, S., Eroğlu, Ö., Yüksel, S., 2018. Araştırmalarda karar süreci ve bayes teoremi. **EJONS International Journal on Mathematic, Engineering and Natural Sciences**, 2 (6): 56–66.
- [192] Zambrano, J., Samuelsson, O., Carlsson, B., 2019. Machine learning techniques for monitoring the sludge profile a secondary settler tank. **Applied Water Science**, 9 (146).
- [193] Hochreiter, S., Schmidhuber, J., 1997. Long Short-Term Memory. **Neural Computation**, 9 (8): 1735–1780.
- [194] Yin, W., Kann, K., Yu, M., Schütze, H., 2017. Comparative study of CNN and RNN for natural language processing, arXiv Preprint arXiv:1702.01923.
- [195] Karataş, G., 2020. Derin Öğrenme Tabanlı Saldırı Tespit Sistemi. Marmara Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 159s.

- [196] Fan, H., Jiang, M., Xu, L., Zhu, H., Cheng, J., Jiang, J., 2020. Comparison of long short term memory networks and the hydrological model in runoff simulation. **Water** **12**: 2–15.
- [197] Latifoğlu, L., 2022. A novel combined model for prediction of daily precipitation data using instantaneous frequency feature and bidirectional long short time memory networks. **Environmental Science and Pollution Research**, **29**: 42899–42912.
- [198] Bakiler, H., 2023. Derin Ağ Tabanlı Özniteliklerle Gazların Sınıflandırılması ve Konsantrasyon Değerlerinin Regresyon Analizi. Başkent Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara, 124s.
- [199] Docheshmeh, G. A., Alizamir, M., Kisi, O., Elshafie, A., 2022. Drought modelling by standard precipitation index (SPI) in a semi-arid climate using deep learning method: long short-term memory. **Neural Computing and Applications**, **34**: 2425–2442.
- [200] Özeren, Y., 2022. Sakarya Havzasına Ait Su Kalitesi Parametrelerinin Yapay Zekâ Yöntemleri ile Modellenmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 92s.
- [201] Nash, J. E., Sutcliffe, J. V., 1970. River flow forecasting through conceptual models part I—a discussion of principles. **Journal of Hydrology**, **10**: 282–290.
- [202] Mattar, M. A., Alazba, A. A., Zin El-Abedin, T. K., 2015. Forecasting furrow irrigation infiltration using artificial neural networks. **Agricultural Water Management**, **148** (1): 63–71.
- [203] MATLAB, 2023. Gaussian Process Regression toolbox, GPR. (Web sayfası: <https://www.mathworks.com/help/stats/fully-independent-conditional-approximation-for-gpr-models.html>), (Erişim tarihi: Şubat 2023).
- [204] Topçu, E., 2022. Appraisal of seasonal drought characteristics in Turkey during 1925–2016 with the standardized precipitation index and copula approach. **Natural Hazards**, **112**: 697–723.
- [205] Shaowei, Z., Hongchao, Z., Pengcheng, R., Guangjie, X., Bangdong, L., Wencheng, D., Liying, W., 2013. Application of standardized precipitation


- evapotranspiration index in China. **Climatic and Environmental Research**, **18**: 617–625.
- [206] Latifoğlu, L., 2017. Hidrolojik Zaman Serilerinin Yeni Hibrit Yöntemlerle Tahmini. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 167s.
- [207] Maity, R., Suman, M., 2019. Predictability of hydrological systems using the wavelet transformation: application to drought prediction. **In Hydrology in a Changing World**, 109–137.
- [208] Zhu, S., Nyarko, M. H., Bonacci, O., 2021. Application of machine learning models in hydrology: Case study of river temperature forecasting in the Drava River using coupled wavelet analysis and adaptive neuro-fuzzy inference systems model. **Basics of Computational Geophysics**, **2021**: 399–411.
- [209] Coşkun, Ö., Citakoglu, H., 2023. Prediction of the standardized precipitation index based on the long short-term memory and empirical mode decomposition-extreme learning machine models: the case of Sakarya, Türkiye. **Physics and Chemistry of the Earth**, **131**: 103418.
- [210] Başakın, E. E., Ekmekcioglu, Ö., Çitakoglu, H., Özger, M., 2022. A new insight to the wind speed forecasting: robust multi-stage ensemble soft computing approach based on pre-processing uncertainty assessment. **Neural Computing and Application**, **34**: 783–812.
- [211] Citakoglu, H., 2015. Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. **Computers and Electronics in Agriculture**, **118**: 28–37.
- [212] Zhang, N., Dai, X., Ehsan, M.A., Deksisssa, T., 2020. Development of a drought prediction system based on long short-term memory networks (LSTM), 142–153. *17th International Symposium on Neural Networks ISNN 2020*, 4-6 December 2020, Caio, Egypt.
- [213] Roushangar, K., Chamani, M., Ghasempour, R., Azamathulla, H. M., Alizadeh, F., 2021. A comparative study of wavelet and empirical mode decomposition-based GPR models for river discharge relationship modeling at consecutive hydrometric stations. **Water Supply**, **21** (6): 3080–3098.

EKLER


EK 1. Diğer istasyonlara ait yağış grafikleri




Şekil 1. Emirdağ MGİ 1964-2012 dönemi yıllık toplam yağışlar grafiği




Şekil 2. Geyve MGİ 1960-2012 dönemi yıllık toplam yağışlar grafiği




Şekil 3. Ilgın MGİ 1968-2012 dönemi yıllık toplam yağışlar grafiği



Şekil 4. Polatlı MGİ 1965-2012 dönemi yıllık toplam yağışlar grafiği



Şekil 5. Sivrihisar MGİ 1960-2012 dönemi yıllık toplam yağışlar grafiği



Şekil 6. Yunak MGİ 1971-2012 dönemi yıllık toplam yağışlar grafiği

EK 2. Diğer istasyonlara ait aylık SYİ kuraklık değerleri izleme tabloları

Tablo 1. Ankara SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	-0.29	0.75	0.50	0.28	-0.79	0.36	0.50	-0.29	-0.04	0.34	-0.26	-0.44
1961 - 1962	-0.26	0.96	-0.70	-1.69	-0.53	2.03	-0.55	-1.20	0.74	0.15	-1.65	0.58
1962 - 1963	-0.15	1.46	1.05	-0.97	-0.89	-1.11	-0.87	0.37	1.74	0.29	-1.17	1.47
1963 - 1964	1.55	1.63	-0.26	1.23	1.86	-0.35	0.76	-1.20	1.67	0.21	-1.07	0.56
1964 - 1965	-2.27	1.01	0.32	-1.40	-0.24	0.79	-0.28	-0.32	0.10	-2.14	0.57	1.36
1965 - 1966	-1.05	1.51	0.06	0.23	0.50	-0.77	-0.21	-0.60	-1.51	-0.74	0.59	-0.21
1966 - 1967	0.65	-2.77	0.89	0.30	0.55	-0.65	0.94	0.96	0.15	-0.97	-0.43	0.16
1967 - 1968	0.03	-0.22	0.51	1.24	0.24	-0.99	-0.30	-0.07	-0.47	-0.70	0.16	0.03
1968 - 1969	1.71	-0.74	0.64	0.31	-0.22	0.95	0.24	0.57	1.16	0.40	1.09	1.27
1969 - 1970	1.23	1.11	0.53	0.90	0.69	-0.02	-0.53	-1.20	-0.54	-0.84	0.32	1.13
1970 - 1971	0.38	1.04	-0.22	-1.60	0.07	-0.63	1.45	-1.20	0.31	0.46	-0.10	0.08
1971 - 1972	0.02	-0.56	0.13	0.02	0.94	-0.20	-0.35	0.09	0.45	-0.48	1.00	0.35
1972 - 1973	-1.07	-0.53	-1.59	0.03	0.11	1.34	1.54	1.33	1.22	1.32	-0.52	-1.17
1973 - 1974	-1.30	-0.54	0.18	0.72	-1.10	0.79	0.51	-0.26	0.44	-1.56	-0.82	0.42
1974 - 1975	-1.93	-0.35	-0.68	-0.64	1.51	0.57	0.19	0.70	0.57	-0.45	-0.72	0.57
1975 - 1976	0.71	0.15	-1.13	1.18	1.40	1.19	-0.71	0.96	-1.30	-0.16	1.15	0.05
1976 - 1977	1.18	-0.74	-0.73	0.13	0.58	-0.11	-1.27	-0.60	0.38	1.54	-0.51	0.83
1977 - 1978	-0.45	-1.25	-0.56	0.34	-0.87	-0.75	-0.61	0.24	0.43	-0.91	-0.51	-0.59
1978 - 1979	0.42	0.51	-0.11	1.43	-1.65	-1.37	-1.52	-0.23	1.58	0.86	-3.09	0.84
1979 - 1980	1.79	-0.31	-1.32	-2.04	0.51	-0.64	-0.47	-0.68	-1.15	0.58	0.56	-0.38
1980 - 1981	1.44	-0.03	-0.22	0.59	0.65	-0.55	0.01	-0.07	-1.15	-1.50	1.22	-0.01
1981 - 1982	0.94	0.23	1.76	-0.68	0.21	-0.27	0.85	0.10	0.65	-0.45	1.06	1.02
1982 - 1983	-0.17	-1.50	-0.69	1.35	-1.00	0.41	0.60	2.45	-1.15	0.00	-2.07	-0.62
1983 - 1984	0.22	0.23	-1.63	0.02	0.80	0.35	1.65	1.10	-0.02	-0.13	2.42	-0.63
1984 - 1985	0.15	-0.40	-0.01	1.10	-0.73	-0.17	1.47	0.51	-1.51	-2.07	-0.25	-1.95
1985 - 1986	0.86	1.46	-1.27	0.28	0.08	-1.47	-0.38	-0.58	-1.51	1.09	0.86	-0.23
1986 - 1987	1.20	0.67	-1.43	-1.34	-0.29	0.91	-0.32	-1.05	0.23	-0.92	-0.16	0.99
1987 - 1988	1.42	-0.72	0.47	-0.12	0.20	0.20	0.56	-0.41	-0.70	-0.17	-0.04	0.88
1988 - 1989	-1.18	0.29	1.09	0.52	0.01	1.59	-1.02	-1.20	0.01	1.51	0.38	-1.01
1989 - 1990	-2.02	-1.11	-1.17	-2.19	0.84	-0.50	0.11	0.31	-0.54	1.24	1.85	-0.08
1990 - 1991	-0.72	-1.05	-0.51	1.85	0.14	-0.75	0.51	0.90	1.35	0.61	-0.67	0.17
1991 - 1992	-0.53	0.51	-1.55	0.84	0.73	0.18	-0.81	-0.19	-0.07	0.86	-0.85	0.82
1992 - 1993	-2.27	-2.01	0.54	-0.02	-3.63	0.71	1.18	0.77	-0.67	0.46	0.78	-0.04
1993 - 1994	-0.36	0.07	-0.89	-0.55	1.17	-0.86	-0.78	0.31	-1.01	-1.76	0.37	-0.23
1994 - 1995	-0.29	0.09	-1.19	-0.42	-0.28	-1.33	-0.55	-0.75	-0.26	0.30	1.39	-0.79
1995 - 1996	-0.14	-1.37	1.91	0.68	-0.63	0.86	3.41	-0.32	0.16	0.19	1.23	-0.70
1996 - 1997	-0.30	0.27	1.53	-0.18	1.05	-1.63	-0.64	0.89	1.65	0.76	-1.26	0.77
1997 - 1998	0.00	-0.83	-1.46	1.44	0.75	2.04	-1.21	1.15	-1.30	1.18	0.42	0.79
1998 - 1999	-1.52	0.81	0.35	0.95	0.56	0.51	0.57	-1.20	-0.10	0.31	0.45	0.49
1999 - 2000	-0.40	1.76	0.70	-1.40	-2.34	0.13	1.76	1.20	0.53	0.72	0.18	-0.01
2000 - 2001	0.38	0.45	0.16	1.06	-1.40	0.11	-1.65	0.96	-0.43	-0.13	-1.41	-0.31
2001 - 2002	-1.98	0.47	-0.26	-0.59	1.63	-1.84	-0.96	0.75	0.18	-1.94	1.32	1.86
2002 - 2003	-0.31	-1.27	-0.85	1.65	-0.29	-0.10	1.41	-0.02	1.48	-0.03	-0.44	-1.04
2003 - 2004	0.19	0.87	-2.19	0.93	-1.35	-1.84	-0.87	-1.05	0.29	0.27	-1.71	0.68
2004 - 2005	0.34	-0.76	-1.67	-0.11	-0.50	-0.23	-0.40	0.40	-0.65	-0.70	0.35	-1.58
2005 - 2006	-0.87	-0.22	1.17	1.14	1.13	0.19	0.15	-1.11	1.20	0.20	0.82	-1.16
2006 - 2007	-0.06	1.26	0.12	-0.49	-0.70	0.01	-1.02	-1.11	1.93	0.53	-0.44	-2.12
2007 - 2008	0.08	-0.89	-0.02	-0.77	-1.36	0.00	-0.71	0.22	-1.51	-0.49	1.37	0.18
2008 - 2009	-0.82	-1.89	0.72	-0.33	-0.04	-1.05	-1.65	-0.86	1.62	-0.23	0.67	-0.40
2009 - 2010	0.82	1.32	0.75	0.94	-0.94	-0.14	0.30	-0.96	0.03	-0.51	0.65	0.85
2010 - 2011	0.86	1.20	0.30	-0.13	-0.62	0.78	0.98	-0.96	-0.86	3.03	0.22	0.83
2011 - 2012	0.19	-0.39	0.82	0.33	0.80	0.42	0.05	0.82	-1.11	1.23	-1.04	0.01
2012 - 2013	1.61	0.64	0.23	-0.72	0.58	-1.79	-0.61	0.05	-0.53	-0.23	0.40	1.27
2013 - 2014	0.31	0.14	0.93	0.13	-1.11	-0.38	0.50	-0.64	-0.76	0.02	-0.39	-1.97
2014 - 2015	-0.18	-1.00	0.83	0.09	1.16	0.95	-0.13	1.71	1.57	0.68	0.01	0.18
2015 - 2016	0.60	0.31	1.90	-0.71	0.64	2.21	-0.54	1.00	-0.27	0.70	-0.26	-1.83
2016 - 2017	1.57	0.33	1.72	-1.02	0.16	-0.43	-1.65	2.11	0.68	-1.39	-0.21	0.43
2017 - 2018	-0.03	-1.60	0.56	-0.83	0.24	0.74	0.12	0.65	-0.44	0.33	0.59	0.24
2018 - 2019	0.62	0.20	1.69	-2.69	1.29	0.44	0.07	0.34	-0.45	1.05	-0.10	0.91
2019 - 2020	0.39	0.28	0.07	0.43	-0.41	0.36	1.35	1.12	-1.30	-0.99	-0.32	0.80
2020 - 2021	-0.69	1.35	-0.83	-0.79	0.70	1.81	-0.54	-1.20	-0.33	0.26	-1.61	-2.14

Tablo 2. Kütahya SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	1.08	0.24	1.27	0.33	-0.25	0.77	0.36	-0.49	0.03	0.27	-0.68	1.55
1961 - 1962	-0.27	0.49	-0.06	0.02	-1.98	0.70	-1.33	-0.79	0.37	0.46	-0.39	-0.10
1962 - 1963	-0.49	1.12	1.49	-0.27	-0.44	-0.96	-0.24	-1.22	1.17	0.43	-0.35	1.76
1963 - 1964	0.79	1.43	0.45	-0.23	1.64	0.66	0.63	-1.29	-0.58	0.88	-0.02	0.39
1964 - 1965	-1.87	-0.32	1.52	-1.33	-0.16	1.88	0.31	-0.64	0.82	-2.14	0.42	0.25
1965 - 1966	-0.40	1.78	0.16	1.77	2.43	-1.52	0.20	-1.16	-1.84	-1.09	1.28	0.02
1966 - 1967	1.30	-1.15	2.07	0.21	-0.07	0.13	0.19	1.11	-0.60	-1.48	-0.01	0.50
1967 - 1968	0.30	-0.13	0.28	0.29	-0.55	-1.58	1.36	-0.99	-0.43	-0.59	-0.59	0.52
1968 - 1969	1.72	-0.15	2.21	-0.95	-0.66	0.05	-1.07	0.38	0.01	0.27	-0.01	0.81
1969 - 1970	0.31	1.04	-0.17	0.54	-1.01	0.18	1.30	-1.29	-0.91	-1.75	0.24	1.41
1970 - 1971	0.72	1.86	2.01	-0.35	-0.44	-0.14	0.15	-1.29	0.64	0.48	0.11	0.25
1971 - 1972	0.07	-0.53	1.19	-0.44	0.53	0.31	1.71	0.73	0.54	0.68	0.86	0.27
1972 - 1973	-0.92	-0.88	-0.77	-0.37	0.54	1.17	1.39	0.78	0.58	1.52	-0.59	-2.06
1973 - 1974	-1.50	1.11	-0.33	0.53	-0.60	0.32	0.12	-0.42	-0.32	0.78	0.28	0.57
1974 - 1975	-0.85	0.69	-0.70	0.55	0.31	-0.11	-1.36	0.76	0.70	-0.10	-0.03	-0.01
1975 - 1976	-0.34	0.07	1.24	0.25	1.68	0.96	-1.39	1.16	0.48	-0.23	1.05	0.27
1976 - 1977	0.24	-0.50	-1.01	0.25	0.42	-0.10	0.57	0.16	-0.32	0.87	-1.19	0.97
1977 - 1978	-0.64	-0.75	-0.70	0.87	-1.12	0.08	0.26	-0.11	1.10	0.92	0.49	0.82
1978 - 1979	1.05	1.24	0.48	0.48	-0.05	-0.92	-1.39	-1.29	1.67	0.63	-1.07	0.06
1979 - 1980	1.78	-0.52	-1.22	-0.85	1.53	0.97	-0.69	-1.13	0.22	0.23	1.14	0.08
1980 - 1981	1.48	-0.80	0.93	0.28	-0.66	-0.22	-0.86	-0.88	1.31	0.19	1.15	1.28
1981 - 1982	0.98	0.54	0.26	-0.40	-0.20	0.66	-0.01	0.51	-0.31	0.46	0.67	1.41
1982 - 1983	-0.28	-0.42	-1.55	1.16	0.28	-0.70	0.26	-0.99	-0.27	-0.05	-1.89	-1.04
1983 - 1984	0.51	-0.05	-1.56	0.41	-0.17	-0.11	1.55	-0.84	-0.79	-0.42	2.21	-0.46
1984 - 1985	-0.02	0.27	0.67	1.66	-0.31	-1.94	0.57	1.23	-1.46	-2.08	0.08	-1.72
1985 - 1986	1.47	0.72	0.21	-0.49	-0.76	-0.54	-1.39	-0.20	-1.12	-0.51	0.77	-0.58
1986 - 1987	0.69	1.10	-2.32	-0.60	-0.74	0.15	-0.79	-0.47	0.59	-0.54	-1.28	1.40
1987 - 1988	1.36	-0.69	0.16	0.63	-0.11	0.07	0.16	0.60	-1.50	-0.42	0.53	-0.14
1988 - 1989	-1.48	0.54	0.00	0.48	0.48	0.46	-0.22	0.51	-0.48	1.18	1.05	-0.24
1989 - 1990	-1.57	-1.51	-1.49	-3.27	-0.07	-0.90	0.94	-0.71	-1.66	1.16	1.02	0.08
1990 - 1991	-1.78	-0.66	-1.25	0.60	-1.33	0.18	-0.04	0.60	0.72	0.42	-0.14	0.80
1991 - 1992	-0.05	0.08	-1.14	0.14	1.14	-0.17	0.78	0.95	-1.04	-0.21	-0.03	0.23
1992 - 1993	-2.41	-1.68	0.55	0.71	-2.12	0.97	1.63	0.24	-1.84	0.42	0.07	-0.80
1993 - 1994	-0.25	0.90	-0.96	-0.93	0.36	-0.83	-0.68	0.14	-0.65	-1.52	1.05	-0.03
1994 - 1995	-0.45	-0.16	0.05	-0.30	-1.16	-0.84	0.23	0.65	-1.35	0.97	0.45	-0.23
1995 - 1996	0.20	-1.95	0.87	0.43	-0.95	-0.15	0.95	-0.07	0.28	0.61	0.61	0.03
1996 - 1997	-0.03	0.20	0.88	-0.21	-0.66	-1.40	1.05	-0.84	1.12	-0.09	-0.70	0.48
1997 - 1998	-0.67	-1.19	-1.22	1.34	0.01	0.65	0.05	2.12	0.09	1.66	-0.61	0.30
1998 - 1999	-0.64	0.01	0.79	0.36	1.81	1.13	-0.94	-1.29	0.09	0.22	0.59	0.21
1999 - 2000	0.58	1.37	0.16	-1.28	-2.22	-0.29	1.35	0.72	0.03	-0.86	0.04	-1.10
2000 - 2001	0.22	1.07	0.35	1.94	0.34	-1.88	-0.34	1.11	0.18	-0.23	-1.21	-0.08
2001 - 2002	-1.48	-0.36	-0.36	0.53	0.19	-2.54	-0.48	0.24	-0.79	-1.89	2.44	2.21
2002 - 2003	0.16	-1.37	0.48	1.71	-0.98	-1.71	2.07	0.54	2.03	0.29	0.25	-0.53
2003 - 2004	-0.51	1.80	-1.16	1.25	-0.45	-1.27	-1.39	0.20	-0.34	0.75	-1.83	0.59
2004 - 2005	0.09	-0.46	-0.92	0.41	0.80	-1.08	-0.57	0.80	-1.66	-1.40	0.71	-1.26
2005 - 2006	-0.50	0.47	1.10	0.37	-0.15	-0.24	1.06	0.37	0.76	-1.06	0.45	-0.39
2006 - 2007	0.77	-0.10	-0.26	-2.91	-0.55	-0.55	-0.22	-1.29	1.45	1.34	-0.27	-1.88
2007 - 2008	-0.08	-1.69	-0.65	-0.84	0.15	0.80	-1.39	0.28	-0.26	0.26	1.71	-0.06
2008 - 2009	-2.84	-2.29	0.88	-0.81	-0.97	-0.63	-0.91	-0.07	1.41	-0.93	0.14	-0.67
2009 - 2010	0.34	1.81	0.22	0.28	0.57	-1.07	0.47	-0.51	0.99	-0.72	0.36	0.28
2010 - 2011	0.09	0.66	-0.42	-1.07	-0.94	0.93	-0.70	0.74	0.28	1.37	-0.84	-0.03
2011 - 2012	-0.15	-1.54	-1.10	1.18	1.42	1.30	-1.05	0.06	0.39	1.56	-3.74	0.40
2012 - 2013	1.85	0.63	0.31	0.31	0.61	-0.36	0.84	-0.50	-1.19	0.39	-0.49	0.58
2013 - 2014	0.15	0.21	0.32	-0.70	-1.01	0.48	0.52	-0.47	-1.14	0.51	-0.64	-1.90
2014 - 2015	-0.67	-1.17	-0.73	0.22	1.19	1.14	-0.39	-0.27	2.54	0.72	0.06	0.83
2015 - 2016	0.58	0.84	-0.66	0.51	1.69	2.02	-1.25	2.25	0.47	-0.05	-0.14	-2.10
2016 - 2017	1.37	-0.55	0.77	-0.78	0.18	0.61	-0.83	0.52	0.85	-1.89	0.07	-0.29
2017 - 2018	0.17	-1.22	-0.87	0.77	1.47	1.18	0.41	2.40	0.22	0.91	-0.20	-0.01
2018 - 2019	0.00	-0.15	1.07	-1.88	1.35	1.68	1.00	1.67	-0.66	1.18	-0.01	0.44
2019 - 2020	0.77	0.06	-1.30	-0.29	-0.59	1.18	0.39	-0.68	-0.73	-0.50	-0.52	-0.02
2020 - 2021	0.30	0.62	-0.56	-1.69	1.20	1.22	0.24	0.12	0.70	-0.54	-2.07	-2.14

Tablo 3. Bolu SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	1.94	0.31	0.66	-0.65	0.36	0.46	0.64	1.66	-0.35	-0.07	-1.30	0.25
1961 - 1962	-0.53	0.45	0.25	-0.35	-0.63	0.72	-0.33	-1.18	-0.02	0.44	0.69	-1.54
1962 - 1963	-1.80	0.68	0.31	0.17	-0.75	-1.95	-0.63	-1.35	0.62	0.93	-0.94	1.53
1963 - 1964	1.65	-0.64	0.46	0.48	0.84	-0.07	1.02	-1.17	0.61	-0.16	-0.20	1.37
1964 - 1965	-0.02	0.36	0.12	-0.62	-0.50	0.51	-1.05	0.66	1.12	-2.33	1.12	0.37
1965 - 1966	-1.83	0.82	0.44	0.79	0.37	-0.17	1.56	-0.06	-2.10	-1.08	0.60	-0.09
1966 - 1967	0.08	-2.30	1.19	0.21	0.23	-1.11	-0.16	0.98	-0.06	-0.75	-1.26	-0.42
1967 - 1968	-0.26	0.24	0.04	-0.06	1.05	-0.31	0.21	-1.02	0.37	-0.71	1.56	-0.43
1968 - 1969	2.23	-0.33	1.06	0.18	0.54	0.27	-1.25	0.39	1.91	-0.54	-0.24	0.23
1969 - 1970	-0.34	-0.16	-0.25	0.29	-0.43	0.72	-0.92	-1.35	-0.16	-1.61	-0.49	0.12
1970 - 1971	0.00	1.72	1.15	0.03	0.91	0.46	-0.25	0.76	-0.09	-0.24	-0.26	1.86
1971 - 1972	-0.32	-0.24	0.65	0.67	0.96	0.24	-0.05	-0.27	0.66	0.06	-0.20	2.35
1972 - 1973	-1.58	-2.04	-2.31	0.27	-0.37	1.99	0.62	1.33	1.34	0.97	-0.27	-1.95
1973 - 1974	-0.19	-0.41	0.27	0.40	-0.85	0.13	0.35	0.27	-1.09	-0.61	1.92	-0.61
1974 - 1975	-0.08	-0.92	-0.44	0.69	0.90	0.06	-1.15	0.87	0.86	-1.08	-0.30	-0.78
1975 - 1976	0.11	0.18	0.07	-0.04	3.09	0.46	-1.16	1.74	-0.55	-0.05	0.04	0.82
1976 - 1977	0.86	-0.61	-0.19	-0.80	1.21	-0.66	0.53	1.10	-0.22	0.29	-0.60	-0.13
1977 - 1978	-1.03	-1.10	-0.14	0.21	-1.54	-0.62	-1.07	-0.15	0.32	-0.47	0.25	-0.49
1978 - 1979	0.91	-0.06	-1.25	1.48	-0.43	-1.55	0.43	0.25	1.73	0.19	-2.71	0.71
1979 - 1980	1.09	0.15	-1.57	-0.51	0.80	0.16	1.22	0.01	-0.65	-0.66	1.12	-0.61
1980 - 1981	0.79	-0.44	1.11	0.32	0.15	-1.18	-1.88	-0.26	-0.01	-1.13	1.73	0.54
1981 - 1982	0.44	-0.15	1.63	-2.17	0.43	-1.67	-1.17	-0.82	0.45	0.07	0.21	1.76
1982 - 1983	0.04	-0.38	-1.02	0.07	0.35	-0.74	0.86	1.82	0.60	-0.77	-0.99	-1.49
1983 - 1984	1.50	-0.08	-1.48	-0.98	-0.61	0.34	1.77	0.08	0.36	0.64	1.45	-1.30
1984 - 1985	-0.08	-0.54	-0.13	0.84	-0.07	-0.74	0.42	1.02	-1.72	-1.43	0.46	-2.22
1985 - 1986	-0.53	1.91	-1.39	-0.11	-0.10	-0.37	-0.50	-0.89	-1.36	0.46	-0.49	1.76
1986 - 1987	1.00	0.04	-2.54	-0.62	-0.14	0.55	-0.18	-0.13	-1.13	-0.21	0.55	0.13
1987 - 1988	1.17	-1.37	-0.15	0.08	0.37	-0.40	0.65	0.13	-1.79	0.57	-0.32	1.07
1988 - 1989	-1.43	-0.33	0.65	-0.71	1.01	1.12	0.65	-0.20	-1.49	0.40	0.49	0.76
1989 - 1990	-2.03	-1.34	-1.08	-3.10	0.11	1.18	0.24	0.89	0.08	0.46	1.03	0.26
1990 - 1991	-1.13	-1.93	-2.06	0.88	-0.47	-0.30	-0.47	-0.64	1.06	0.62	0.05	0.10
1991 - 1992	-1.04	0.18	-0.85	-0.66	1.35	0.16	1.24	0.74	0.33	0.08	-0.20	0.32
1992 - 1993	0.25	-0.07	0.52	-0.47	-3.22	0.65	0.49	-1.35	-1.11	0.91	1.37	0.82
1993 - 1994	-1.33	-0.62	-0.76	-1.69	0.89	-0.99	-2.89	1.13	-0.60	-1.40	0.50	-0.58
1994 - 1995	-0.64	-0.16	-1.68	-0.96	-0.78	-1.37	-0.79	-0.52	-0.95	-0.08	1.39	0.72
1995 - 1996	0.33	-1.47	0.80	0.02	-1.03	0.63	1.35	0.20	0.31	0.00	0.99	-1.21
1996 - 1997	-0.16	-0.25	1.39	-0.36	0.11	-1.19	0.48	0.31	1.07	0.67	-0.96	-0.01
1997 - 1998	0.56	-0.27	0.14	2.45	-0.45	0.72	-0.01	2.02	-1.00	1.05	0.22	0.62
1998 - 1999	0.58	0.91	-0.52	0.96	2.76	0.52	-0.49	-1.35	0.70	0.52	0.14	-0.79
1999 - 2000	-1.28	1.44	-0.50	-0.58	-1.37	0.96	1.68	0.96	0.40	0.10	0.59	-0.94
2000 - 2001	-0.02	0.17	0.92	2.45	-0.74	0.01	0.43	1.16	-0.63	-0.20	-2.18	-1.36
2001 - 2002	-2.03	-0.16	0.74	-0.05	1.25	-1.59	-0.64	0.98	-0.22	-1.72	1.42	1.36
2002 - 2003	0.43	-0.41	-0.85	1.67	-0.29	-0.34	0.71	0.76	0.29	0.16	-0.19	-1.06
2003 - 2004	0.76	0.60	-1.31	-1.44	-0.53	-3.23	-1.88	-0.32	0.60	1.34	-1.21	0.58
2004 - 2005	-0.08	1.13	0.89	0.05	-0.57	0.76	0.36	0.88	-1.57	-1.06	0.28	-1.56
2005 - 2006	0.34	-0.10	0.99	0.90	-0.46	0.25	1.04	-0.49	0.15	0.29	0.81	-0.73
2006 - 2007	-0.68	0.64	0.05	-2.22	-0.74	-1.00	-0.59	-1.14	1.73	-0.78	-0.02	-1.07
2007 - 2008	2.43	-2.03	1.25	-0.95	0.65	-0.62	-1.12	0.41	-2.03	-1.04	0.82	-0.34
2008 - 2009	0.21	-0.51	0.87	-0.43	0.73	0.25	-0.23	-1.35	1.97	-0.69	0.75	0.05
2009 - 2010	0.31	0.53	1.25	0.29	-1.12	0.29	1.29	-0.92	0.95	-1.12	0.26	-0.21
2010 - 2011	-0.06	1.67	0.68	0.62	-0.42	1.44	0.70	-0.84	0.21	2.06	-1.10	0.45
2011 - 2012	0.59	0.68	1.12	0.22	-0.34	1.02	0.55	-0.28	0.56	0.91	0.73	-1.05
2012 - 2013	0.96	1.04	0.33	1.62	1.41	1.84	1.17	0.37	0.32	-1.15	-1.34	0.75
2013 - 2014	-1.26	0.63	0.68	-1.52	-0.82	0.66	-1.25	-0.56	0.71	0.78	0.24	-0.69
2014 - 2015	0.36	0.94	1.25	0.35	0.74	0.44	0.97	0.38	1.21	1.63	0.40	0.53
2015 - 2016	0.74	0.67	-0.56	0.73	-1.16	0.88	-2.19	-0.32	0.33	0.36	-1.76	-0.84

Tablo 4. Emirdağ SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1964 - 1965	-2.07	0.26	0.95	-1.44	-0.63	2.16	0.43	-0.69	0.59	-2.04	0.47	0.96
1965 - 1966	0.07	1.53	0.28	0.67	0.12	-1.16	-0.18	-1.02	-0.56	-0.72	0.52	-0.25
1966 - 1967	0.57	-2.38	1.22	0.33	1.24	0.22	0.35	-0.11	1.19	-1.51	-0.05	0.78
1967 - 1968	0.20	0.86	0.26	0.71	1.09	-0.39	0.12	-0.48	-0.24	-0.13	0.12	0.63
1968 - 1969	1.69	0.20	2.29	0.10	0.74	0.36	-1.30	0.74	1.15	0.25	0.36	0.91
1969 - 1970	1.23	0.86	0.71	1.43	0.26	-0.82	0.65	-1.00	0.25	-1.07	0.02	0.93
1970 - 1971	1.44	0.52	0.89	-1.37	-1.66	-0.05	1.02	0.86	0.05	1.26	-0.39	0.78
1971 - 1972	-1.01	1.06	1.31	0.88	0.82	0.84	-0.17	1.10	1.37	0.45	-0.11	0.78
1972 - 1973	0.04	-0.30	-0.73	0.06	-0.41	1.30	-0.10	1.17	0.53	0.75	-1.30	-1.74
1973 - 1974	-1.05	-1.18	0.12	0.28	-0.18	-1.54	0.44	0.18	0.23	-0.39	-0.90	0.11
1974 - 1975	0.40	0.00	0.35	-1.29	0.98	-0.97	-0.59	0.71	0.19	-1.05	-0.21	0.46
1975 - 1976	-0.39	0.63	-0.80	-0.70	1.68	1.02	-0.58	1.86	-1.26	-0.19	0.88	0.15
1976 - 1977	1.28	0.11	-0.12	0.66	1.53	-0.19	-0.68	0.11	-0.09	0.71	0.21	0.28
1977 - 1978	-0.78	-0.29	0.11	1.19	-1.06	-0.64	0.55	-0.93	1.11	0.50	-1.28	0.04
1978 - 1979	1.21	0.31	0.96	-0.10	-0.48	-1.65	-0.63	-1.38	0.65	0.90	-2.55	0.29
1979 - 1980	0.40	-1.49	-1.25	-0.46	2.51	1.20	0.16	-0.56	0.25	1.17	0.73	-0.77
1980 - 1981	0.96	-0.55	0.53	0.78	-0.35	-0.87	-1.30	0.13	0.89	0.09	0.57	-0.76
1981 - 1982	0.82	-0.29	-0.25	-0.01	-0.20	1.01	0.81	0.48	0.32	1.13	0.29	0.08
1982 - 1983	-0.55	-1.30	-0.98	0.78	0.70	0.67	0.57	0.40	-0.18	-0.25	-0.69	-1.79
1983 - 1984	0.11	0.43	0.66	-0.10	0.20	1.29	1.50	-0.27	-0.07	-0.35	1.58	-0.42
1984 - 1985	-0.76	0.12	0.69	1.49	-0.75	-0.39	2.81	-0.29	-1.09	-1.83	-0.04	-1.15
1985 - 1986	0.78	0.65	-0.34	-0.94	-0.20	-0.08	-1.30	0.59	-0.49	0.86	0.27	0.86
1986 - 1987	0.32	-0.20	-2.64	-2.23	0.12	0.59	-0.51	-0.91	-0.39	-0.13	-0.85	1.19
1987 - 1988	0.15	-0.22	0.17	0.65	-0.88	0.28	-0.18	-0.29	-1.26	-0.30	0.97	0.95
1988 - 1989	-1.31	0.61	0.61	0.90	-0.83	0.44	0.01	-0.08	-0.33	1.07	1.09	-1.68
1989 - 1990	-1.26	-2.34	-1.03	-3.19	0.29	-1.15	-0.10	-0.45	-1.53	0.89	1.70	-0.44
1990 - 1991	-1.68	-1.77	-2.64	0.15	-0.05	0.11	0.60	0.21	0.97	0.08	-0.40	0.33
1991 - 1992	0.19	0.40	-0.81	0.02	1.71	-1.19	0.29	2.32	-0.08	1.39	0.00	1.13
1992 - 1993	-2.49	-1.62	-0.33	-1.29	-0.40	0.43	2.00	-0.93	-1.47	0.55	-0.46	-0.61
1993 - 1994	0.13	-0.08	-2.09	-0.52	0.17	0.42	-0.27	0.63	-0.66	-2.03	0.61	-1.36
1994 - 1995	-0.13	-0.06	0.42	-0.16	-0.95	-1.15	0.62	0.73	0.22	0.22	1.08	-0.34
1995 - 1996	-0.77	-0.99	0.98	-0.93	-0.78	0.78	1.44	0.63	-1.06	0.36	1.58	-0.88
1996 - 1997	0.95	0.02	1.66	-1.16	0.94	-1.12	1.21	0.05	1.07	0.78	-1.66	-0.12
1997 - 1998	-0.35	-0.09	-0.99	0.37	-0.18	0.96	-0.43	3.30	-1.04	1.54	-0.06	-0.38
1998 - 1999	-0.39	-1.03	0.92	0.94	1.52	-0.19	-1.38	-1.38	0.30	0.45	0.26	0.82
1999 - 2000	-0.02	1.88	0.28	-0.31	-3.03	1.54	0.90	1.27	0.57	-0.47	-0.08	-1.15
2000 - 2001	1.46	1.35	0.28	1.14	0.23	0.03	-1.38	-0.74	0.04	0.27	-1.94	0.23
2001 - 2002	-2.23	0.43	0.30	0.46	-0.07	-1.66	-0.54	0.05	-0.97	-1.64	1.17	2.64
2002 - 2003	1.10	-0.75	-0.52	1.76	-0.80	-0.66	1.07	0.03	1.90	-0.27	-0.43	0.78
2003 - 2004	-0.53	2.29	-1.00	0.36	-0.72	-2.04	-1.38	-0.46	-0.03	0.00	-1.27	1.09
2004 - 2005	-0.01	-0.42	-1.15	0.12	0.18	0.38	-0.35	-0.40	-1.53	-1.68	0.75	-1.38
2005 - 2006	-0.20	0.74	1.11	1.27	0.28	1.03	0.64	-0.85	0.51	0.20	1.29	-1.63
2006 - 2007	1.12	0.75	-0.51	-0.82	0.54	0.68	-0.56	-1.38	1.73	1.28	-0.54	-2.32
2007 - 2008	1.09	-0.83	-0.21	-0.62	-1.89	1.29	-0.54	-0.54	-1.53	-0.27	1.73	0.74
2008 - 2009	-1.05	-0.43	0.12	-0.93	-0.64	-1.06	-1.38	-0.58	2.02	0.40	0.10	0.45
2009 - 2010	0.87	1.31	0.20	1.29	0.22	-1.27	0.60	-1.38	1.26	-0.35	0.58	0.72
2010 - 2011	0.14	0.86	-0.34	0.15	-1.12	0.88	-0.33	-0.77	-0.99	1.01	-1.07	0.85
2011 - 2012	0.72	0.57	0.71	-0.07	0.30	0.60	-0.96	-0.07	-1.02	0.70	-2.28	-0.66

Tablo 5. Polatlı SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1965 - 1966	-0.26	1.25	0.24	0.13	0.48	-1.35	-0.55	-0.96	-1.25	-0.71	0.73	0.84
1966 - 1967	0.85	-1.79	0.90	-0.24	0.24	0.16	1.30	-0.88	-1.12	-1.55	-0.32	0.51
1967 - 1968	-0.05	0.35	0.42	0.59	0.44	-0.91	0.53	-0.13	0.04	-0.63	-0.17	0.04
1968 - 1969	1.15	-0.48	0.66	0.43	-1.40	0.48	0.20	0.59	0.76	0.45	0.62	1.12
1969 - 1970	1.55	1.34	0.61	0.43	-0.01	0.00	-0.05	-1.17	-0.02	-0.84	0.20	1.46
1970 - 1971	0.73	0.71	-0.24	-1.60	-2.26	-0.74	-0.19	-1.37	0.17	0.64	-0.32	-0.41
1971 - 1972	-0.64	-0.28	0.50	-0.06	1.17	-0.45	-0.77	0.93	0.32	0.09	0.70	-0.37
1972 - 1973	-0.98	-0.85	-1.10	0.25	-0.18	2.01	1.44	0.72	0.49	1.54	-0.59	-1.77
1973 - 1974	-1.18	-0.25	-0.21	0.14	-0.68	0.27	0.67	0.27	-0.49	-0.77	-1.36	0.22
1974 - 1975	-1.37	-0.07	0.02	-0.81	1.27	0.70	0.23	0.74	0.94	-0.46	-0.61	0.27
1975 - 1976	0.50	-0.03	-0.10	0.73	1.99	1.95	-0.41	1.49	-1.08	0.00	0.70	-0.06
1976 - 1977	1.28	-1.37	-0.62	0.41	1.14	0.03	0.33	-0.72	-0.06	1.05	-0.49	0.68
1977 - 1978	0.31	-0.34	-0.13	0.20	-1.88	-0.17	0.24	1.51	0.96	-0.62	-0.62	-1.08
1978 - 1979	0.79	0.58	1.09	1.10	-0.08	-1.63	-1.76	-0.92	0.96	1.65	-2.47	0.69
1979 - 1980	1.48	-0.80	-1.00	-2.35	0.81	0.21	-0.29	-1.37	-0.12	0.29	0.60	-0.26
1980 - 1981	1.44	0.17	0.15	0.18	1.04	-0.53	-1.42	0.65	-0.88	-0.95	0.80	-1.36
1981 - 1982	1.10	0.47	0.27	-0.80	1.11	1.15	0.55	0.37	-0.38	0.20	0.83	1.01
1982 - 1983	-0.60	-0.97	-1.37	0.90	-0.33	-0.72	2.15	1.23	-0.01	-0.13	-2.70	-0.68
1983 - 1984	0.37	-0.27	-0.31	-0.10	0.06	0.10	0.57	0.32	-0.46	-0.36	2.00	-0.97
1984 - 1985	-0.51	-0.13	1.21	1.60	-0.77	-1.24	1.13	0.71	-1.25	-2.21	-0.27	-1.74
1985 - 1986	0.65	0.48	-0.21	-0.49	0.44	-0.10	-0.19	-0.64	-1.25	1.28	0.53	-0.37
1986 - 1987	1.05	0.88	-2.26	-1.75	-0.33	0.89	-1.87	-1.10	0.94	-1.07	-0.79	0.65
1987 - 1988	0.79	-0.70	-0.01	-0.43	0.03	0.01	-0.29	-0.10	-0.78	-0.31	-0.07	1.04
1988 - 1989	-0.94	0.13	1.14	0.98	-0.53	1.09	0.95	-1.00	-0.86	1.04	1.10	-0.95
1989 - 1990	-2.13	-1.84	-2.09	-2.37	-0.26	-0.78	0.25	-0.17	-0.68	0.94	1.58	-0.44
1990 - 1991	-0.63	-1.42	-1.22	1.46	0.45	0.04	-0.46	1.28	1.31	0.52	-0.47	0.40
1991 - 1992	-0.50	0.72	-1.47	1.26	1.00	0.03	0.12	0.39	0.75	0.55	0.04	1.03
1992 - 1993	-2.68	-1.38	-0.20	0.52	-1.93	0.16	1.45	-1.00	-1.18	0.87	0.28	-0.02
1993 - 1994	0.08	-0.45	-1.00	-0.66	0.74	0.20	-1.53	0.16	-1.08	-2.66	-0.01	-0.37
1994 - 1995	0.41	0.67	-0.51	-0.90	0.09	-1.07	-0.65	-0.18	1.16	0.43	1.15	-0.66
1995 - 1996	0.06	-1.48	2.40	0.20	0.03	0.71	0.73	0.23	0.39	0.50	1.14	-0.63
1996 - 1997	0.24	0.21	1.58	-0.75	0.24	-1.60	0.78	0.61	1.77	0.38	-1.51	0.83
1997 - 1998	-0.04	-0.33	-1.17	1.59	0.16	1.38	-1.09	2.37	-0.45	1.16	0.02	0.35
1998 - 1999	-1.19	0.73	0.46	0.44	1.89	0.33	0.19	-0.78	0.43	0.52	0.61	0.82
1999 - 2000	0.01	1.48	0.58	-0.79	-2.43	0.23	1.16	2.07	1.41	0.29	-0.14	-0.62
2000 - 2001	0.29	0.89	0.01	1.47	-1.74	0.60	0.12	-0.11	0.86	-0.68	0.05	0.85
2001 - 2002	-2.71	-0.05	-0.19	-0.93	1.18	-2.03	-0.60	-0.01	0.74	-2.21	1.11	2.02
2002 - 2003	-0.10	-0.87	-0.04	0.49	0.80	-0.54	0.86	0.15	1.27	-0.18	-0.25	-0.87
2003 - 2004	0.62	1.34	-0.15	1.13	-0.32	-1.97	-1.67	0.38	-0.51	0.54	-1.52	0.80
2004 - 2005	0.30	-0.53	-1.70	-0.10	-0.52	0.63	-0.24	1.21	-1.25	-1.55	0.39	-1.74
2005 - 2006	-0.89	0.58	1.89	1.58	-0.05	0.42	1.24	-0.92	0.11	-0.03	0.92	-1.52
2006 - 2007	0.31	2.12	-0.56	-1.43	0.62	0.49	-0.66	-1.37	1.94	0.62	-0.86	-2.63
2007 - 2008	0.41	-0.70	-0.34	-0.86	-1.11	0.07	-0.93	0.40	-1.25	0.31	1.41	0.94
2008 - 2009	-0.94	-1.40	0.60	-0.46	-0.17	0.22	-2.03	-1.05	1.32	-0.02	0.55	0.06
2009 - 2010	0.73	2.60	1.46	0.95	-0.36	-0.79	-0.89	-0.55	-0.28	-0.35	0.46	1.39
2010 - 2011	1.10	1.25	1.11	-1.10	-0.52	2.58	1.59	-1.37	-0.01	2.30	-0.11	1.23
2011 - 2012	0.27	-0.34	0.92	-0.06	0.69	0.15	0.56	0.26	0.52	0.66	-2.23	0.47

Tablo 6. Sivrihisar SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	0.78	0.93	1.63	0.55	0.03	0.49	-0.23	-0.53	0.43	-0.04	-0.87	0.29
1961 - 1962	0.04	1.65	-0.14	-0.88	-0.62	1.97	-0.22	-1.10	0.05	0.63	-1.48	0.19
1962 - 1963	-0.59	1.39	0.30	-0.10	0.40	-1.80	-0.69	0.01	1.17	0.11	-0.43	1.81
1963 - 1964	1.29	1.45	0.03	-0.08	0.90	0.77	1.83	-1.43	1.42	0.27	-1.07	-1.19
1964 - 1965	-2.22	0.72	1.82	-2.60	-0.24	1.36	-0.99	-0.34	0.89	-2.07	0.62	0.71
1965 - 1966	0.03	0.41	-0.15	1.01	-0.05	-1.34	0.24	-1.26	-1.57	-0.89	1.07	0.79
1966 - 1967	0.50	-2.02	1.30	0.03	-0.02	-0.35	1.43	-0.85	-0.41	-1.13	-0.72	0.90
1967 - 1968	-0.30	-0.61	-0.24	0.72	1.91	-1.78	-1.06	-0.28	-0.83	-0.44	0.04	0.04
1968 - 1969	1.78	0.03	1.30	-0.50	-1.03	1.83	0.45	0.53	1.08	0.55	0.28	1.19
1969 - 1970	1.79	1.13	0.85	0.19	0.18	0.33	0.27	-0.74	-0.34	-0.33	-0.06	1.61
1970 - 1971	0.85	0.93	0.14	-2.08	-1.69	0.10	0.96	-1.43	-0.04	0.23	-0.47	-0.24
1971 - 1972	-0.45	0.23	0.85	0.45	0.54	0.93	-0.72	-0.12	0.08	0.23	0.73	-0.43
1972 - 1973	-0.69	-0.72	-1.05	0.85	-0.11	0.94	0.98	0.89	0.55	1.13	-0.89	-2.46
1973 - 1974	-1.28	-1.17	-0.75	0.60	0.26	0.86	0.83	-0.30	0.53	-0.72	-0.88	0.24
1974 - 1975	-1.27	0.76	0.97	-0.60	0.32	0.60	-0.07	1.05	0.41	-0.38	-0.54	0.47
1975 - 1976	-0.15	-0.60	-0.24	0.43	2.35	1.82	-0.35	0.85	-1.41	-0.27	0.91	0.06
1976 - 1977	1.20	-0.95	-0.94	0.38	1.27	0.60	0.63	0.87	-0.27	1.14	-0.06	0.44
1977 - 1978	-0.37	0.72	-0.81	0.87	-1.78	-0.50	0.89	-0.87	0.55	-0.33	-0.70	-0.47
1978 - 1979	0.73	0.63	1.08	0.37	-0.05	-1.12	-1.13	-1.43	0.37	1.31	-2.37	0.37
1979 - 1980	1.28	-0.70	-1.23	-1.54	1.80	0.50	-0.51	-1.43	0.01	0.74	0.94	-0.91
1980 - 1981	0.97	0.10	0.56	0.70	0.64	0.07	-1.53	0.36	0.65	-0.74	0.54	-0.87
1981 - 1982	1.32	0.69	0.05	-0.32	0.06	-0.67	-1.11	0.52	-0.25	0.64	0.47	0.51
1982 - 1983	-0.64	-1.42	-1.01	1.03	-0.01	-0.07	0.11	0.84	-0.06	0.62	-1.26	-1.14
1983 - 1984	0.25	-0.11	0.25	-0.23	-0.85	0.21	0.61	-1.10	-0.88	-0.70	2.23	-0.30
1984 - 1985	-0.26	-0.30	1.23	2.40	-0.82	0.33	1.44	0.87	-1.41	-2.05	0.28	-1.36
1985 - 1986	0.77	0.93	-0.91	-0.80	-0.14	0.13	-0.58	0.87	-1.57	1.54	0.28	0.19
1986 - 1987	0.60	0.36	-1.85	-1.66	-0.58	0.20	-0.04	-0.19	1.07	-1.37	-0.92	0.62
1987 - 1988	0.55	-0.77	0.57	0.33	-0.51	0.23	1.52	-0.10	-0.57	0.25	-0.01	0.93
1988 - 1989	-1.44	0.17	0.63	0.89	-0.82	0.55	-0.75	-0.45	-0.21	0.76	1.08	-1.30
1989 - 1990	-1.82	-2.17	-2.04	-2.78	-0.49	-1.51	0.75	-0.74	-1.26	0.24	1.86	-1.15
1990 - 1991	-0.79	-1.66	-1.52	0.98	-0.27	0.23	2.15	1.29	0.77	0.28	-0.57	-0.13
1991 - 1992	-0.29	0.24	-1.23	0.83	1.10	-0.42	0.71	1.91	0.86	1.68	0.57	1.15
1992 - 1993	-3.12	-1.38	-0.09	-0.37	-1.49	0.16	1.16	0.07	-1.41	0.72	-0.10	-0.19
1993 - 1994	0.51	-0.52	-1.36	-0.32	0.70	0.25	-1.19	-0.79	-0.71	-2.05	0.38	-0.61
1994 - 1995	0.01	0.31	-0.08	-0.11	-0.03	-2.12	-0.29	-0.78	0.03	0.25	1.71	-0.61
1995 - 1996	-0.15	-2.16	1.38	-0.21	-1.19	-0.07	0.70	0.71	-0.56	0.16	1.22	-0.87
1996 - 1997	0.36	0.40	1.31	-0.55	0.85	-0.93	0.49	0.99	1.65	-0.08	-1.25	0.79
1997 - 1998	-0.57	-0.31	-1.09	0.90	0.19	-0.20	-0.80	1.78	-1.26	1.09	0.28	0.29
1998 - 1999	-0.28	0.60	1.58	1.37	1.56	-0.37	-0.33	-0.57	1.14	0.52	0.42	1.21
1999 - 2000	0.29	1.28	0.38	-0.31	-3.34	0.45	0.38	2.18	1.81	0.57	0.13	-0.62
2000 - 2001	0.57	0.58	-0.37	-0.24	-0.54	0.47	-1.01	0.70	0.14	-0.13	-1.21	0.06
2001 - 2002	-1.80	-0.35	-0.38	0.12	-0.08	-2.71	-0.11	1.83	-0.25	-1.82	1.85	2.34
2002 - 2003	0.66	-1.06	-0.15	1.59	0.22	0.15	0.38	1.57	1.39	0.26	-0.22	0.18
2003 - 2004	0.11	1.22	-1.61	1.23	-0.84	-1.64	-2.38	-1.01	-0.51	0.62	-1.52	0.85
2004 - 2005	-0.10	-0.72	-1.41	-0.18	0.00	0.63	-1.58	-0.65	-1.57	-1.32	0.57	-1.17
2005 - 2006	-0.43	0.31	1.16	0.93	0.36	-0.39	1.59	-0.87	0.20	-0.32	0.97	-1.62
2006 - 2007	0.58	0.96	-0.47	-1.17	0.44	0.85	1.35	-0.26	1.47	0.20	-0.89	-2.74
2007 - 2008	1.04	-0.74	-0.52	-0.88	-0.16	1.05	-0.38	0.74	-1.41	0.25	1.33	0.58
2008 - 2009	-1.08	-1.14	0.19	-0.85	-0.30	-1.39	-1.32	-0.31	1.54	0.52	0.21	-0.02
2009 - 2010	1.21	1.89	0.64	0.31	0.68	-0.69	-0.57	-0.49	0.97	0.16	0.19	0.50
2010 - 2011	0.29	1.00	0.15	0.09	-0.48	0.33	-0.93	0.18	0.27	1.75	-0.85	0.99
2011 - 2012	0.26	-0.27	1.33	-0.55	1.97	1.27	-1.35	-0.32	-0.77	0.82	-1.90	0.30

Tablo 7. Geyve SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1960 - 1961	0.53	-0.36	0.45	-0.49	0.87	-0.39	0.17	0.83	-0.52	-0.62	-1.30	0.19
1961 - 1962	-0.05	1.10	-0.45	-0.14	0.41	0.45	0.90	-0.76	0.77	-0.26	0.07	-2.09
1962 - 1963	-1.76	1.99	0.63	0.50	-2.11	-1.90	-0.09	-1.30	0.69	1.20	-0.45	1.39
1963 - 1964	1.91	-0.71	1.27	-0.11	0.86	-0.34	2.18	-0.79	1.33	0.15	-0.03	1.47
1964 - 1965	-1.25	1.18	-0.10	-0.15	0.21	-0.45	-0.57	1.19	1.26	-2.40	1.40	0.98
1965 - 1966	-1.75	1.21	-0.03	1.03	0.35	-0.87	1.42	-0.13	-1.66	-0.73	0.85	0.12
1966 - 1967	0.23	-2.13	1.29	0.15	-0.91	0.84	-0.20	0.84	-0.33	-1.72	-1.69	0.14
1967 - 1968	0.39	0.52	1.40	0.92	0.55	-0.26	-0.88	0.15	0.51	0.22	1.82	-0.06
1968 - 1969	1.51	-0.22	0.11	0.32	-1.32	-0.28	-2.55	1.88	2.54	-0.06	0.05	-0.70
1969 - 1970	1.03	0.01	-0.22	1.58	-0.80	0.70	-0.34	-1.30	-1.90	-2.40	-0.73	-0.43
1970 - 1971	-0.06	2.59	0.02	0.22	0.54	-0.52	-0.95	0.41	0.66	0.47	0.61	1.35
1971 - 1972	-0.99	-0.05	1.35	0.20	1.61	-0.35	0.16	0.84	0.01	0.63	-0.08	1.21
1972 - 1973	-0.88	-0.56	-1.17	0.08	0.00	2.61	0.71	1.75	0.99	0.51	-0.29	-1.66
1973 - 1974	-1.32	-0.35	-0.32	-0.21	0.05	0.48	-1.30	0.50	-0.42	0.20	1.03	0.50
1974 - 1975	0.38	0.28	0.51	-0.36	1.87	0.33	-1.26	2.11	-0.10	-1.66	-0.43	0.41
1975 - 1976	0.91	0.94	0.48	-0.64	2.06	0.14	-1.15	1.17	-0.27	0.26	0.03	0.50
1976 - 1977	0.32	-0.25	-1.99	-0.19	0.31	1.30	-0.12	0.89	-0.31	1.03	0.62	-0.26
1977 - 1978	-0.78	-1.55	0.88	0.05	-2.05	-0.38	-0.16	-0.50	-0.15	0.50	0.10	0.98
1978 - 1979	1.77	0.99	-0.02	0.62	-0.50	-1.29	-0.86	0.33	0.59	0.20	-2.05	0.52
1979 - 1980	0.88	-0.06	-0.75	-0.01	0.91	1.52	0.51	0.56	0.21	0.17	1.14	0.73
1980 - 1981	1.37	-0.84	0.55	-1.11	0.96	-0.50	-0.20	-0.08	0.09	-1.10	1.15	1.58
1981 - 1982	0.44	0.60	0.59	-1.86	1.10	-1.47	1.26	-0.60	0.97	0.02	-0.45	1.12
1982 - 1983	0.15	-0.03	-0.04	1.28	0.03	-0.55	1.13	0.55	-0.17	-0.27	-0.38	-0.29
1983 - 1984	0.24	0.81	-1.37	0.31	-0.31	-0.06	0.93	0.71	-0.25	1.13	1.32	-1.47
1984 - 1985	-0.34	0.23	-0.06	2.11	-0.67	0.61	1.50	0.71	-2.07	-1.08	-0.60	-2.32
1985 - 1986	0.26	0.26	-1.07	-1.08	-0.79	0.02	-0.30	-1.06	-1.56	0.74	0.30	-0.51
1986 - 1987	0.13	0.00	-3.08	-1.06	-0.01	0.19	-0.72	-1.30	-0.36	-0.08	-0.17	0.48
1987 - 1988	1.70	-1.02	0.99	-0.29	0.33	-0.86	-0.11	0.48	-1.84	0.80	0.18	0.26
1988 - 1989	-1.41	-0.12	-0.03	-0.06	0.13	1.00	0.83	-0.84	-0.39	0.72	0.74	-0.16
1989 - 1990	-1.42	-2.20	-2.43	-3.01	0.13	-0.68	0.53	-0.18	-0.27	1.25	1.76	0.32
1990 - 1991	-0.73	-0.41	-0.35	0.84	-0.46	-1.38	-0.60	-0.90	1.20	0.65	-0.03	-0.39
1991 - 1992	-0.49	0.37	-2.07	0.64	1.94	0.45	0.50	-0.66	0.69	-0.33	-0.48	0.73
1992 - 1993	-0.84	0.54	1.01	-0.21	-1.45	0.93	1.71	-1.20	-1.24	1.12	0.55	0.41
1993 - 1994	-0.64	-0.64	-0.72	0.21	0.71	-0.20	-0.67	0.38	-0.28	-2.03	1.15	-0.61
1994 - 1995	0.58	-0.36	-1.11	-0.61	-0.43	-0.16	-2.18	0.01	-1.79	-0.18	1.29	0.36
1995 - 1996	1.39	-2.30	2.06	0.58	-1.22	0.74	1.40	0.39	0.49	0.40	1.07	-1.72
1996 - 1997	-0.17	-0.16	1.12	0.36	0.14	-1.79	0.75	-0.28	1.31	0.60	-1.62	0.39
1997 - 1998	-0.36	0.32	0.21	2.17	-0.96	0.05	0.05	1.90	-0.76	1.59	-0.94	0.41
1998 - 1999	-0.56	0.40	0.42	-0.21	2.09	0.02	0.32	-1.30	0.63	0.43	0.16	-0.09
1999 - 2000	-0.76	0.84	-0.15	-0.01	0.10	3.64	-0.75	0.55	-0.04	-0.93	0.05	-1.73
2000 - 2001	1.13	0.10	0.61	1.63	0.40	0.53	0.07	0.19	0.11	1.34	-2.15	-1.00
2001 - 2002	-3.13	-0.30	-0.38	0.43	-0.25	-0.85	0.13	0.74	-0.40	-1.14	0.99	2.06
2002 - 2003	0.24	-1.52	-0.30	0.48	0.16	0.97	1.15	1.11	0.89	0.53	-0.82	-1.10
2003 - 2004	-0.30	1.75	-0.98	0.16	-1.84	-1.83	-0.59	-1.00	0.32	1.14	0.14	0.89
2004 - 2005	1.09	0.21	0.06	0.23	0.40	-0.12	-0.88	0.39	-1.36	-1.59	0.40	-1.87
2005 - 2006	0.09	0.43	0.11	0.15	-0.89	-0.23	1.62	-0.45	0.41	-0.55	1.07	-0.57
2006 - 2007	0.16	0.43	0.40	-3.44	-1.68	-0.38	-1.70	-1.13	1.11	-0.33	-0.59	-1.00
2007 - 2008	0.50	-1.77	0.77	-0.67	1.04	-0.50	-0.97	-0.37	-1.30	-0.65	0.09	0.07
2008 - 2009	-0.16	-0.36	0.99	-1.15	-0.31	-0.12	-0.77	-1.30	1.21	-0.32	-0.50	-0.42
2009 - 2010	0.31	1.02	0.40	-0.10	-0.33	-0.09	0.92	-0.85	0.60	-0.11	0.17	0.06
2010 - 2011	0.78	0.44	0.23	0.59	-0.35	0.90	-0.47	-1.11	0.62	2.10	-1.79	1.18
2011 - 2012	-0.07	-1.22	0.71	-0.02	-0.68	-0.28	0.40	0.07	0.82	0.79	-2.46	-0.19

Tablo 8. Ilgın SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1968 - 1969	-2.50	-2.00	-2.13	-2.10	-0.98	-0.05	-1.10	-0.30	1.39	0.06	0.49	0.60
1969 - 1970	0.99	1.41	1.06	0.55	0.60	-0.49	-0.24	-0.47	0.95	-0.95	0.56	0.57
1970 - 1971	0.95	-0.66	-0.90	-1.40	0.41	-0.22	-0.18	1.30	0.70	0.25	0.24	-0.54
1971 - 1972	-1.37	0.85	0.31	0.49	1.23	0.57	0.18	1.46	0.29	-0.61	0.22	-0.15
1972 - 1973	-1.32	0.56	-1.27	-0.18	-0.79	1.53	-0.09	0.81	-0.13	0.11	-1.08	-1.95
1973 - 1974	-1.84	-0.92	0.68	-0.71	0.49	-0.27	-0.81	-0.85	-1.21	-1.32	-0.67	0.13
1974 - 1975	-0.55	-1.41	-1.17	-1.01	-0.55	-0.79	0.17	0.59	0.62	-0.65	-0.75	0.19
1975 - 1976	-0.01	0.51	0.27	0.21	0.53	1.58	-0.73	0.24	-0.92	-0.23	0.35	-0.52
1976 - 1977	0.78	-0.65	-0.30	0.54	1.72	-0.91	-0.38	-0.37	-0.20	1.32	-0.18	1.61
1977 - 1978	0.33	-1.07	0.35	1.80	-1.69	0.44	-0.32	-1.21	0.98	0.46	-1.88	-0.24
1978 - 1979	1.49	-0.53	0.92	-0.32	-0.43	-1.22	-1.00	-1.21	1.10	1.10	-2.26	-0.26
1979 - 1980	0.52	-1.20	-0.71	-0.08	0.08	1.16	0.01	0.03	-0.03	1.45	0.84	-0.43
1980 - 1981	0.62	-0.87	-0.59	1.02	0.72	-0.04	-1.10	-0.33	0.20	0.04	0.15	-0.70
1981 - 1982	1.51	-0.19	-0.83	-1.34	0.52	1.00	0.89	-0.26	-0.21	-0.30	0.09	0.48
1982 - 1983	-0.47	-1.06	0.51	0.90	-0.23	0.86	1.61	0.98	0.00	-0.03	-0.98	-1.00
1983 - 1984	-0.05	0.53	1.01	-0.32	-0.07	-0.25	0.26	-0.45	0.25	-0.79	0.67	1.07
1984 - 1985	-0.42	-0.68	0.83	1.06	-0.21	0.45	0.49	1.14	-1.34	-1.91	-0.09	-1.26
1985 - 1986	0.46	1.07	-0.41	-0.03	0.70	-1.05	-0.03	0.38	-1.24	1.70	0.81	0.21
1986 - 1987	-0.32	0.43	-1.93	-0.12	0.31	-0.58	-0.44	1.60	1.86	-0.86	0.29	0.38
1987 - 1988	0.66	0.26	0.62	0.21	-0.46	1.22	1.28	-0.29	-1.34	-0.04	1.09	0.76
1988 - 1989	-1.47	0.66	0.39	1.97	-0.42	1.01	1.49	-1.13	-0.40	0.89	0.86	-0.93
1989 - 1990	0.61	-1.85	0.07	-1.97	0.81	-1.32	-0.61	-1.02	-1.34	0.73	1.68	0.16
1990 - 1991	-0.43	-0.35	-1.50	-0.63	1.16	-0.47	0.28	-1.16	1.03	0.00	-0.11	0.43
1991 - 1992	-0.24	0.49	-1.27	1.11	-0.03	-1.43	0.53	1.04	0.24	0.94	0.33	1.04
1992 - 1993	-1.73	-0.77	-0.30	-0.58	0.97	0.66	1.74	-0.17	-1.21	-0.98	0.47	0.73
1993 - 1994	0.28	-0.12	-0.58	-1.37	2.02	-0.58	-1.10	-1.02	-0.97	-2.00	0.03	-0.50
1994 - 1995	0.64	-0.75	1.08	-0.26	-1.05	-1.83	0.05	0.49	-0.53	0.50	1.21	0.41
1995 - 1996	0.05	0.56	0.70	1.58	0.41	-0.87	1.55	0.66	-0.53	0.45	1.95	-0.83
1996 - 1997	0.39	1.22	3.15	0.39	-0.74	0.17	1.61	1.00	0.90	0.43	-2.30	0.21
1997 - 1998	0.35	0.31	-0.58	1.18	0.10	1.90	-0.81	0.76	-0.04	1.44	-0.20	-0.43
1998 - 1999	-0.87	-1.22	1.97	0.25	-0.39	0.64	-1.10	-1.21	-0.20	0.41	-0.12	1.72
1999 - 2000	0.82	1.49	-0.32	-1.02	-1.42	1.22	1.25	1.71	0.25	0.14	-1.14	-0.97
2000 - 2001	1.12	1.71	0.70	-0.09	1.55	-0.62	-1.10	1.18	-0.64	0.34	-1.86	0.13
2001 - 2002	-1.57	-0.90	-0.30	0.10	1.49	-2.00	1.39	-0.07	0.55	-1.94	0.83	2.85
2002 - 2003	0.95	-0.40	0.77	1.35	-1.53	0.03	0.55	0.56	1.94	-0.72	-0.44	0.31
2003 - 2004	-0.23	1.88	0.73	0.82	-0.66	-0.36	-1.10	0.66	1.09	0.62	-0.60	0.32
2004 - 2005	-0.09	0.40	-0.45	0.49	-0.22	1.17	1.70	-0.55	-1.34	-1.66	0.57	-1.69
2005 - 2006	-0.89	0.67	-0.09	0.78	-0.11	-0.60	0.06	1.17	0.04	-0.25	1.30	-0.51
2006 - 2007	0.36	-0.53	0.05	0.50	0.59	0.00	0.14	-1.21	0.93	1.89	0.27	-3.16
2007 - 2008	1.38	0.59	0.32	-1.12	-2.57	-0.90	-0.71	0.70	0.28	-0.37	1.52	0.61
2008 - 2009	-1.53	0.08	-0.24	-1.28	-0.81	-0.69	0.19	-1.21	1.87	0.10	0.01	0.38
2009 - 2010	1.05	2.29	0.26	0.10	0.29	-0.81	-0.39	-0.61	0.07	0.26	0.71	0.14
2010 - 2011	1.19	0.06	-0.97	-0.19	-2.16	1.99	-0.39	0.48	-0.49	0.48	-1.67	1.06
2011 - 2012	0.85	0.31	0.29	-0.48	0.97	0.79	-1.00	-0.63	-1.08	0.97	-0.78	-0.16

Tablo 9. Yunak SYİ-1 kuraklık değerleri izleme tablosu

Yıllar	Aylar											
	1	2	3	4	5	6	7	8	9	10	11	12
1971 - 1972	-1.48	0.60	0.07	1.43	0.70	0.60	0.68	1.39	1.04	0.26	-0.22	1.01
1972 - 1973	-0.07	0.08	-1.33	-0.23	-0.19	0.96	1.20	0.26	0.68	0.67	-0.82	-2.49
1973 - 1974	-1.70	-1.16	1.02	0.33	0.41	-0.09	0.21	0.04	-0.95	-0.34	-0.62	0.02
1974 - 1975	0.07	-0.40	0.82	-1.03	0.54	0.07	0.09	1.37	0.45	-1.25	-0.46	0.34
1975 - 1976	-1.97	1.07	-0.68	-0.32	1.28	0.75	-0.45	0.70	-0.95	-0.46	0.08	0.40
1976 - 1977	1.47	0.64	-0.20	1.15	2.22	0.76	0.07	0.16	-0.05	1.17	0.42	0.54
1977 - 1978	0.68	0.65	1.02	0.82	-2.10	0.20	-0.92	-1.05	0.90	0.12	-1.22	0.39
1978 - 1979	1.48	0.40	1.45	0.05	-2.07	-0.35	-0.75	-1.05	0.83	1.13	-1.97	0.10
1979 - 1980	0.53	-1.08	-1.70	-0.71	1.22	0.58	-0.24	-0.45	-0.54	0.39	0.11	-0.30
1980 - 1981	0.74	-1.14	0.46	-0.35	1.49	-0.33	-1.17	-0.57	0.37	-0.31	0.16	-0.39
1981 - 1982	1.36	-0.08	0.11	-1.15	0.11	-0.97	-0.06	-1.05	-0.60	0.34	0.33	0.17
1982 - 1983	0.12	-0.93	-0.89	0.24	-1.11	0.48	0.88	0.66	-0.41	-0.24	-1.31	-0.68
1983 - 1984	0.43	0.95	0.10	0.19	0.20	1.25	0.08	1.45	-0.38	-0.51	1.43	-0.34
1984 - 1985	0.02	-1.08	0.38	2.64	0.23	-0.87	0.85	-1.05	-0.95	-1.97	-1.02	-1.72
1985 - 1986	0.37	0.61	-0.02	-1.26	-1.64	-0.17	-1.17	0.34	-0.95	1.89	0.48	-0.05
1986 - 1987	0.02	-0.52	-2.18	-0.97	0.17	0.35	-0.64	-0.70	-0.20	-0.96	-0.14	0.84
1987 - 1988	0.50	-0.30	0.55	0.24	0.06	0.30	0.78	0.72	-0.95	0.07	1.11	1.32
1988 - 1989	-1.19	1.53	0.66	0.97	-0.69	0.68	1.80	0.49	0.09	0.89	1.14	-0.82
1989 - 1990	-0.41	-1.66	-1.26	-1.65	-0.21	-0.04	-0.12	0.63	-0.83	0.54	1.63	-0.10
1990 - 1991	0.31	-0.72	-0.64	-0.63	0.57	0.14	-0.51	0.17	1.65	-0.34	-0.56	0.33
1991 - 1992	-0.40	0.79	-2.29	0.73	0.89	0.08	-0.32	1.29	-0.02	0.97	0.53	1.13
1992 - 1993	-1.39	-1.13	-0.68	-0.28	0.19	0.68	1.76	-0.50	-0.56	-0.01	0.33	0.00
1993 - 1994	0.60	-0.39	-1.45	-0.68	0.47	-0.01	-1.17	-0.88	-0.95	-1.94	0.36	-0.09
1994 - 1995	0.70	0.46	1.30	-0.25	-0.65	-1.79	0.38	0.26	0.86	0.22	0.72	0.06
1995 - 1996	-0.89	-0.78	0.64	0.48	-0.08	0.48	0.91	0.79	0.85	0.17	1.39	-0.26
1996 - 1997	0.74	0.48	1.83	0.23	-1.17	-0.51	1.44	0.57	1.30	1.25	-1.42	0.40
1997 - 1998	0.34	0.63	-0.83	1.51	0.57	2.32	-0.41	2.60	0.06	1.21	-0.29	-0.32
1998 - 1999	-1.10	-1.11	1.61	0.03	0.80	-1.87	-0.45	-1.05	0.11	0.37	0.16	1.00
1999 - 2000	-0.13	1.34	0.48	-0.71	-1.65	1.54	1.12	1.41	-0.34	-0.54	-0.69	-1.26
2000 - 2001	1.28	1.29	0.21	1.22	0.47	0.26	-1.17	0.12	0.06	0.30	-1.08	-0.39
2001 - 2002	-1.92	-1.22	0.51	-1.44	0.86	-3.12	-0.44	0.64	0.16	-1.92	0.77	3.14
2002 - 2003	1.09	-1.57	0.27	1.20	-0.63	-1.31	1.20	-0.23	1.47	-0.64	-0.49	0.44
2003 - 2004	0.09	2.29	-0.22	0.98	0.24	-0.96	-1.17	-0.51	0.76	0.12	0.05	0.62
2004 - 2005	-0.14	0.83	-1.05	-0.56	-0.27	0.71	0.99	0.34	-0.95	-1.77	0.54	-1.46
2005 - 2006	-0.79	-1.96	1.30	1.56	0.64	-1.33	0.50	-0.97	0.78	-0.12	1.42	-1.42
2006 - 2007	0.97	0.32	-0.41	-1.30	0.46	0.06	1.43	-0.65	1.93	1.45	-0.09	-2.20
2007 - 2008	0.69	-0.24	0.36	-0.66	-1.66	-0.22	-0.87	0.33	-0.91	0.18	2.17	0.79
2008 - 2009	-1.44	-0.14	-0.97	-1.22	-1.69	0.01	-1.06	-0.68	1.86	0.58	-0.10	0.05
2009 - 2010	0.56	1.62	0.63	0.31	0.32	-1.12	-0.75	-0.92	0.55	0.14	1.10	0.33
2010 - 2011	1.19	0.55	0.72	0.69	-0.45	0.88	0.94	-1.05	-0.60	0.73	-1.71	1.22
2011 - 2012	-0.11	0.44	0.46	-1.70	1.31	1.58	-1.04	-0.50	-0.80	0.38	-1.76	-0.29

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Ömer COŞKUN

Uyruğu: Türkiye (T.C)

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Doktora	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı	2023
Yüksek Lisans	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı	2017
Lisans	Erciyes Üniversitesi, İnşaat Mühendisliği Bölümü	2012
Lise	Sivas Şarkışla Anadolu Lisesi	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2021-Halen	DSİ 12. Bölge Müdürlüğü, Barajlar ve HES Şube Müdürlüğü	Baraj Proje, İhale ve Tatbikat Mühendisi (2,5 yıl)
2013-2021	DSİ 12. Bölge Müdürlüğü, Planlama Şube Müdürlüğü	Planlama Mühendisi (7,5 yıl)

YABANCI DİL

İngilizce

YAYINLAR

SCI, SSCI ve AHCI İndekslerine Giren Dergilerde Yayınlanan Makaleler

1. Coşkun, Ö., Citakoglu, H., 2023. Prediction of the standardized precipitation index based on the long short-term memory and empirical mode decomposition-extreme learning machine models: the case of Sakarya, Türkiye. **Physics and Chemistry of the Earth**, **131**: 103418.
2. Citakoglu, H., Coşkun, Ö., 2022. Comparison of hybrid machine learning methods for the prediction of short-term meteorological droughts of Sakarya Meteorological Station in Turkey. **Environmental Science and Pollution Research**, **29** (50): 75487–75511.

Diğer Dergilerde Yayınlanan Makaleler

1. Çıtakoğlu, H., Coşkun, Ö., 2021. Dalgacık dönüşüm modellenli yapay zekâ teknikleri kullanılarak Orta Anadolu Bölge İstasyonlarının yağış tahmini. **Harran Üniversitesi Mühendislik Dergisi**, **6** (1): 39–54.
2. Çıtakoğlu, H., Coşkun, Ö., 2020. Bahçelik Barajı ve ünitelerinin WEAP (Water Evaluation and Planning System) programı ile modellenmesi ve işletme çalışması. **Harran Üniversitesi Mühendislik Dergisi**, **5** (3): 213–226.

Hakemli Kongre / Sempozyum Bildiri Kitaplarında Yer Alan Yayınlar

1. Çıtakoğlu, H., Özeren, Y., Coşkun, Ö., 2019. Short time drought estimation of Sakarya basin station with wavelet model-adaptive neuro-fuzzy inference system, 190–197. *IWW'2019: International Conference on Image Processing, Wavelet and Applications*, 18 - 20 September 2019, Kocaeli, Türkiye, Kocaeli University.

Tezler

1. Coşkun, Ö., 2023. Sakarya Havzasındaki Kısa Dönem Meteorolojik Kuraklığın Hibrit Modeller ile Tahmin Edilmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 235s.

2. Coşkun, Ö., 2017. Zamantı Irmağı Alt Havzasındaki DSİ Projelerinin WEAP (Water Evaluation and Planning System) Programı ile Modellenmesi ve Bahçelik Barajı İşletme Çalışması Örneği. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 173s.

