

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

**HİDROLOJİK ZAMAN SERİLERİNİN YENİ HİBRİT
YÖNTEMLERLE TAHMİNİ**

**Hazırlayan
Levent LATİFOĞLU**

**Danışman
Prof. Dr. Tefaruk HAKTANIR**

Doktora Tezi

**Kasım 2017
KAYSERİ**

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

**HİDROLOJİK ZAMAN SERİLERİNİN YENİ HİBRİT
YÖNTEMLERLE TAHMİNİ**

(Doktora Tezi)

**Hazırlayan
Levent LATİFOĞLU**

**Danışman
Prof. Dr. Tefaruk HAKTANIR**

**Kasım 2017
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.

Levent LATİFOĞLU

YÖNERGEYE UYGUNLUK SAYFASI

“Hidrolojik Zaman Serilerinin Yeni Hibrit Yöntemlerle Tahmini” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.



Tezi Hazırlayan

Levent LATİFOĞLU



Danışman

Prof. Dr. Tefaruk HAKTANIR

İnşaat Mühendisliği Ana Bilim Dalı Başkanı

Prof. Dr. Fatih ALTUN



Prof. Dr. Tefaruk HAKTANIR danışmanlığında **Levent LATİFOĞLU** tarafından hazırlanan **“Hidrolojik Zaman Serilerinin Yeni Hibrit Yöntemlerle Tahmini”** adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **İnşaat Mühendisliği** Anabilim Dalında **Doktora** tezi olarak kabul edilmiştir.

10.11.2017

JÜRİ:

Başkan: Prof. Dr. Tefaruk HAKTANIR

Üye :Prof. Dr. Ahmet Alper ÖNER

Üye :Doç. Dr. Mehmet Ali HINIS

Üye :Doç. Dr. Mehmet ÖZGER

Üye :Yrd. Doç. Dr. Hatice ÇITAKOĞLU

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulunun 28/11/2017 tarih ve 2017/51-06 sayılı kararı ile onaylanmıştır.

28.11.2017
Enstitü Müdürü
Prof. Dr. Mehmet AKKURT

TEŞEKKÜR

Tezi tamamlamam konusunda gerekli motivasyonu sağlayan, desteğini hiçbir zaman esirgemeyip bitirmeme sebep olan tez danışmanım Sayın Prof. Dr. Tefaruk HAKTANIR'a çok teşekkür ederim.

Maddi ve manevi olarak yardımlarını esirgemeyen, her daim yanımda olan eşim Fatma LATİFOĞLU'na teşekkür ederim.

Levent LATİFOĞLU

Kayseri, Kasım 2017

HİDROLOJİK ZAMAN SERİLERİNİN YENİ HİBRİT YÖNTEMLERLE TAHMİNİ

Levent LATİFOĞLU

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Doktora Tezi, Ekim 2017

Danışman: Prof. Dr. Tefaruk HAKTANIR

ÖZET

Su bilimi olarak bilinen hidroloji; suyun yerküre üzerindeki dağılımını, fiziksel, kimyasal ve biyolojik özelliklerini inceleyen uygulamalı bir bilimdir. İnsan için hayati öneme sahip olan su kaynaklarının planlanması, projelendirilmesi ve işletilmesi hidrolojik çalışmaların başında gelmektedir. Gelecekte meydana gelecek hidrolojik olayların modellenmesi ve tahmini hidrolojik çalışmalar için oldukça büyük öneme sahiptir. Hidrolojik çalışmalarda temel olarak kullanılan bilgiler; yağış, su seviyesi ve akış debisi gibi hidrolojik verilerdir. Geçmişte gözlenmiş verilerin doğru analizi, gelecektekilerin tahminini kolaylaştırmaktadır. Hidrolojik veriler ölçüm alınan yerlerin coğrafik, iklimsel ve bitki deseni farklılıklarına göre farklı istatistiksel özellikler sergilemektedir. Bu nedenle verilerin ön analizi ölçüm yerinin işleyişi hakkında önemli bilgiler verebilmektedir. Bu çalışmada hidrolojik değişkenlerin tahmini için literatürde mevcut yöntemlere yenilikler getirilerek hibrit yöntemler oluşturulmuş ve bunların tahmin performansı mevcut yöntemlerinkilerle karşılaştırılmıştır. Çalışmada, hidrolojik verilerin tahmini için literatürde mevcut yöntemler olarak, lineer yaklaşımlar üzerine kurulu modellerden Özbağımlı (ÖB), Özbağımlı Hareketli ortalama (ÖBHO) modelleri ve yapay zeka teknikleri arasında yer alan nonlineer modellerden Yapay Sinir Ağları (YSA) modelleri kullanılmıştır. Hidrolojik verilerin tahmininde; yenilikçi yaklaşım olarak, Ampirik Kip Ayırımı (AKA) ve Tekil Spektrum Analizi (TSA) yöntemlerini ön işlem olarak kullanan AKA-YSA ve TSA-YSA hibrit modelleri ortaya konmuştur. Sunulan modellerin performansları, verilere ön işlem yapılmadan elde edilen tahmin sonuçları ile karşılaştırılmıştır. Tahmin çalışması için günlük, aylık ortalama akım miktarını gösteren debi ve su seviyesi yüksekliğini gösteren hidrolojik değişkenler kullanılmıştır. Çalışmanın sonucunda hidrolojik verilerin tahmininde hibrit modellerin performansının yüksek olduğu ortaya konmuştur.

Anahtar Kelimeler: Hidrolojik veri, Tahmin, Ön İşlem, Hibrit Modeller, YSA, AKA, TSA, AKA-YSA, TSA-YSA

FORECASTING OF HYDROLOGICAL VARIABLES USING NEW HYBRID METHODS

Levent LATİFOĞLU

Erciyes University, Graduate School of Natural and Applied Sciences
Civil Engineering Division

Doctor of Philosophy Thesis, October 2017

Thesis Supervisor: Prof. Dr. Tefaruk HAKTANIR

ABSTRACT

Hydrology, known as water science, is an applied science dealing with the circulation of water on earth, studying its physical, chemical, biological and statistical features. The planning, design and management of water resources, which are vitally important for survival of mankind, are among major hydrologic studies. Modeling and robust prediction of future hydrologic events are of great significance for hydrologic studies. Such variables as rainfall, streamflow, and water surface elevation are some of major information needed in hydrologic studies. Correct analyses of past occurrences of these data make it easier to predict those to take place in the future. Depending on their geographical, climatic, and plant pattern peculiarities, the hydrologic data reveal spatially different statistical features. Hence, prior analysis of the observed data is necessary because it provides essential information about the regime at that location. In this study, hybrid methods have been developed by introducing innovations to the existing methods, and their performance has been compared with the latter. As existing methods in relevant literature for prediction of hydrologic variables, the linear Özbağımlılı (ÖB) and Özbağımlılı Hareketli ortalama (ÖBHO) models, and also the nonlinear Artificial Neural Networks (ANN) model are used in the study. As a new approach, the hybrid models of EMD-ANN and SSA-ANN are developed, which use the Empirical Mode Decomposition (EMD) and the Singular Spectrum Analysis (SSA) schemes as a means of preliminary analysis of the observed data, respectively, and next apply the ANN method to such processed data. The performances of these two hybrid models have been compared with those of the mentioned existing methods. Monthly and daily streamflows and water surface elevations data have been used in these comparison analyses. In conclusion, it has been observed that the performances of the proposed hybrid models are more successful than those of the above-mentioned linear and nonlinear models.

Keywords: Hydrologic data, Estimation, Preliminary analysis, Hybrid models, ANN, EMD, SSA, EMD-YSA, SSA-YSA

İÇİNDEKİLER

HİDROLOJİK ZAMAN SERİLERİNİN YENİ HİBRİT YÖNTEMLERLE TAHMİNİ

BİLİMSEL ETİĞE UYGUNLUK.....	Hata! Yer işareti tanımlanmamış.
YÖNERGEYE UYGUNLUK SAYFASI	i
KABUL ONAY	: Hata! Yer işareti tanımlanmamış.
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR VE SİMGELER	x
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ.....	xvi
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Genel Bilgiler.....	4
1.2. Literatür Çalışması.....	6

2. BÖLÜM

MATERYAL VE YÖNTEM

2.1. Hidrolojik Verilerin Tahmini için Klasik Yaklaşımlar	18
2.1.1. Özbağımlı Hareketli Ortalama Modelleme	18
2.1.1.1. ÖBHO Model Parametrelerinin Belirlenmesi için Yule-Walker Eşitliği.....	19
2.1.2. Özbağımlı Modelleme	21
2.2. Hidrolojik Verilerin Tahmini için Hibrit Yaklaşımlar.....	22

2.2.1 Hidrolojik Verilerin Ön İşlenmesi	23
2.2.1.1. Ampirik Kip Ayrışım (AKA) Yöntemi	23
2.2.1.2. Tekil Spektrum Analiz (TSA) Yöntemi	26
2.2.2. Hidrolojik Verilerin Tahmini için Yapay Sinir Ağları	29
2.2.2.1 Yapay Sinir Ağlarının Genel Özellikleri	30
2.2.2.2 Yapay Sinir Ağlarının Tarihçesi	33
2.2.2.3. Yapay Sinir Hücresi	35
2.2.2.4. Yapay Sinir Ağının Yapısı	37
2.2.2.5. Yapay Sinir Ağlarında Öğrenme	37
2.2.2.6. Çok Katmanlı Yapay Sinir Ağları.....	39
2.2.2.6.1. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Kuralı	39
2.2.2.6.2. Levenberg Marquardt Algoritması.....	40
2.3. Tahmin Çalışmasında Kullanılan Hidrolojik Veriler	42
2.3.1. Kızılırmak Nehri Yamula İstasyonuna ait Hidrolojik Veriler	42
2.3.2. Meriç Havzası Şeytan Deresine ait Hidrolojik Veriler	44
2.3.3. Eğirdir Gölüne ait Hidrolojik Veriler	46
2.4. Tahmin Çalışmasında Kullanılan Performans Değerlendirme Kriterleri	47

3. BÖLÜM

BULGULAR

3.1. Kızılırmak Nehri Yamula İstasyonuna ait Hidrolojik Verilerin Tahmin Çalışması.....	49
3.1.1. ÖBHO ve ÖB Modeli Kullanarak Veri Tahmini	49
3.1.2. Yapay Sinir Ağları Modeli Kullanarak Veri Tahmini.....	57
3.1.3. Ampirik Kip Ayrışım-Yapay Sinir Ağları Modeli Kullanarak Veri Tahmini	69
3.1.4. Hidrolojik Verilerin Tahmini için Tekil Spektrum Analizi, Ampirik Kip Ayrışım Yöntemi ve Yapay Sinir Ağları	89

3.1.5. Tekil Spektrum Analizi-Yapay Sinir Ağları Modeli Kullanarak Veri tahmini.....	91
3.2. Meriç Havzası Şeytan Deresine ait Hidrolojik Verilerin Tahmin Çalışması.....	103
3.3. Eğirdir Gölüne ait Su Seviyesini Gösteren Hidrolojik Verilerin Tahmin Çalışması.....	136

4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER.....	150
KAYNAKLAR	155
ÖZGEÇMİŞ.....	166

KISALTMALAR VE SİMGELER

ABK	: Akaike Bilgi Kriteri
ADD	: Ayrık Dalgacık Dönüşümü
AKA	: Ampirik Kip Ayrışımı
ANBS	: Adaptif Nöro Bulanık Sistem
ART	: Adaptif Rezonans Teorisi modelleri (ART)
BİAS	: Yanlılık
CD	: Determinasyon Katsayısı
ÇKAYSA	: Çok Katmanlı Algılayıcı Yapay Sinir Ağları
DD	: Dalgacık Dönüşümü
DGASA	: Dalgacık tabanlı Genetik Algoritmali Yapay Sinir Ağları
DNB	: Dalgacık Nöro Bulanık
DSİ	: Devlet Su İşleri
DVR	: Destek Vektör Regresyonu
DYSA	: Dalgacık Tabanlı Yapay Sinir Ağları
EA	: Evrimsel Algoritma
EF	: Etkinlik
ES	: Evrimsel Strateji
FD	: Fourier Dönüşümü
GA	: Genetik Algoritma
GP	: Genetik Programlama
GRSA	: Genelleştirilmiş Regresyon Sinir Ağları
İBGYSA	: İleri Beslemeli Geri Yayılımlı Sinir Ağları
İMF	: İçsel Mod Fonksiyon
KDM	: Karar Destek Makinaları
KOM	: Kendi kendini organize eden model (KOM)
KÖBHO	: Kesirsel Özbağımlı Hareketli Ortalama
LM	: Levenberg Marquardt

LZD	: Yapay Sinir Ağları
MAE	: Ortalama Mutlak Hata
MÖBHO	: Mevsimsel Özbağımlı Hareketli Ortalama
MSE	: Ortalama Karesel Hata
ÖB	: Özbağımlı
ÖBHO	: Özbağımlı Hareketli Ortalama
ÖBİHO	: Özbağımlı İntegralli Hareketli Ortalama
ÖRT	: Özörgütlemeli Radyal Taban
PÖB	: Peryodik Özbağımlı
PÖBHO	: Peryodik Özbağımlı Hareketli Ortalama
PSA	: Probabilistik Sinir Ağları
R	: Korelasyon Katsayısı
R²	: Belirginlik Katsayısı
RC	: Rekonstrüktif Bileşen
RTFSA	: Radyal Taban Fonksiyonlu Sinir Ağları
SYSA	: Stokastik Yapay Sinir Ağları
TDA	: Tek Değerli Ayrışım
TSA	: Tekil Spektrum Analizi
VKM	: Vektör Kuantizasyon Modelleri (VKM)
YSA	: Yapay Sinir Ağları

TABLolar LİSTESİ

Tablo 2.3.1.	32 yıllık gözlenmiş aylık akım verilerine ait hidrolojik değişkenlerin istatistiksel parametreleri	43
Tablo 2.3.2.	35 yıllık gözlenmiş günlük akım verilerine ait hidrolojik değişkenlerin istatistiksel parametreleri	45
Tablo 2.3.3.	44 yıllık gözlemlenmiş aylık su seviyesi değerlerinin istatistiksel parametreleri	47
Tablo 3.1.1.	Yamula istasyonunda aylık akımların tahmini için ÖB (12) Modelinin tahmin performans sonuçları	51
Tablo 3.1.2.	Yamula istasyonunda aylık akımların tahmini için ÖBHO (26, 27) modelinin tahmin performans sonuçları	54
Tablo 3.1.3.	Yamula istasyonunda aylık akımların tahmini için kullanılan YSA modelinden elde edilen tahmin performans parametreleri	58
Tablo 3.1.4.	Yamula istasyonunda aylık akımların tahmini kullanılan iki ara katmanlı YSA modelinden elde edilen tahmin performans parametreleri	64
Tablo 3.1.5.a.	Yamula istasyonunda aylık akımların tahmini için 1 giriş-1 çıkışlı AKA-YSA modelin ile tahmin edilen IMF lerin eğitim ve test performans değerleri	74
Tablo 3.1.5.b.	Yamula istasyonunda aylık akımların tahmini için 1 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri	75
Tablo 3.1.6.a.	Yamula istasyonunda aylık akımların tahmini için 2 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri	78
Tablo 3.1.6.b.	Yamula istasyonunda aylık akımların tahmini için 2 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri	78
Tablo 3.1.7.a.	Yamula istasyonunda aylık akımların tahmini için 3 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri	80

Tablo 3.1.7.b.	Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri.....	82
Tablo 3.1.8.a.	Yamula istasyonunda aylık akımlar serisi için 4 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri	83
Tablo 3.1.8.b.	Yamula istasyonunda aylık akımlar serisi için 4 giriş -1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri.....	84
Tablo 3.1.9.a.	Yamula istasyonunda aylık akımlar serisi için 5 giriş-1 çıkışlı AKA-YSA modeli ile tahmin IMF lerin eğitim ve test performans değerleri.....	86
Tablo 3.1.9.b.	Yamula istasyonunda aylık akımlar serisi için 5 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri.....	87
Tablo 3.1.10.	Yamula istasyonunda aylık akımlar serisi için IMFlerin toplamı sonucu elde edilen tahmin sonuçlarının performans değerleri.....	91
Tablo 3.1.11.	Yamula istasyonunda aylık akımlar serisi için 1, 2, 3, 4 ve 5 giriş-1 çıkışlı TSA-YSA modelinde alt bileşenlerin test performans değerleri.....	96
Tablo 3.1.12.	TSA-YSA modeli ile test sırasında elde edilen tahmin test performans değerleri	98
Tablo 3.1.13.	Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkış TSA-YSA modeli ile 1-6 ileri tahmin test performans değerleri.....	100
Tablo 3.1.14.	Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkış YSA modeli ile 1-6 ileri tahmin test performans değerleri.....	100
Tablo 3.1.15.	Yamula istasyonunda aylık akımlar serisi için verilerin tahmininde ÖB, ÖBHA, YSA, AKA-YSA, TSA-AKA-YSA, TSA-AKA modellerinin 1 ileri tahmin performans değerleri.....	101
Tablo 3.2.1.	Şeytan Deresi günlük akım hidrolojik zaman verilerinin YSA modeli ile tahmin sonuçları.....	105

Tablo 3.2.2.a. Şeytan Deresi günlük akım hidrolojik verilerinin <i>bir</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları.....	111
Tablo 3.2.2.b. Şeytan Deresi günlük akım hidrolojik verilerin <i>bir</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları ..	112
Tablo 3.2.3. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin <i>bir</i> ileri zamanlı tahminine ait performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile tahmin performans değerleri	114
Tablo 3.2.4.a. Şeytan Deresi günlük akım serisi verilerinin <i>iki</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları.....	116
Tablo 3.2.4.b. Şeytan Deresi günlük akım serisi verilerinin <i>iki</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları ..	117
Tablo 3.2.5. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin <i>iki</i> ileri zamanlı tahmin performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile <i>iki</i> ileri zamanlı tahmin performans sonuçları	119
Tablo 3.2.6. a. Şeytan Deresi günlük akım serisi için <i>üç</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları	121
Tablo 3.2.6.b. Şeytan Deresi günlük akım serisi için <i>üç</i> ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları.....	122
Tablo 3.2.7. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin <i>üç</i> ileri zamanlı tahmin performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile tahmin performans sonuçları.....	124
Tablo 3.2.8. a. Şeytan Deresi günlük akım serisi için <i>bir</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları	128
Tablo 3.2.8.b. Şeytan Deresi günlük akım serisi <i>bir</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları.....	128

Tablo 3.2.9.a.	Şeytan Deresi günlük akım serisi için <i>iki</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları	130
Tablo 3.2.9.b.	Şeytan Deresi günlük akım serisi için <i>iki</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları.....	130
Tablo 3.2.10. a.	Şeytan Deresi günlük akım serisi için <i>üç</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları.....	132
Tablo 3.2.10.b.	Şeytan Deresi günlük akım serisi için <i>üç</i> ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları.....	132
Tablo 3.2.11.	Şeytan deresine ait hidrolojik veri tahmininde YSA, AKA-YSA, TSA-AKA-YSA, TSA-AKA modellerinin <i>bir, iki ve üç</i> ileri tahmin performans değerleri	134
Tablo 3.3.1.	Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli kullanarak IMF bileşenlerine ayrıştırılmış verilerin tahmin sonuçları	139
Tablo 3.3.2.	Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri	141
Tablo 3.3.3.	Eğirdir Gölü aylık su seviyeleri için TSA-YSA modeli kullanarak ayrıştırılmış altbant verilerinin tahmin performans değerleri	143
Tablo 3.3.4.	Eğirdir Gölü aylık su seviyeleri için TSA-YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri	145
Tablo 3.3.5.	Eğirdir Gölü aylık su seviyeleri için YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri.....	146

ŞEKİLLER LİSTESİ

Şekil 1.1.	Hidrolojik Çevrim	5
Şekil 1.2.	Tez Çalışmasının Bölümleri	17
Şekil 2.1.	ÖBHO modele ait LZD sistem Giriş-Çıkış ilişkisi.....	19
Şekil 2.2.1.	Bir biyolojik sinir hücresinin yapısı	34
Şekil 2.2.2.	Yapay Sinir Hücresinin Yapısı	35
Şekil 2.2.3.	Sigmoid fonksiyonun grafiği	36
Şekil 2.2.4.	Bir YSA Örneği (Çok Katmanlı YSA).....	37
Şekil 2.3.1.	Kızılırmak Nehri Yamula İstasyonu.....	42
Şekil 2.3.2.	Meriç Havzası Şeytan Deresi	44
Şekil 2.3.3.	Eğirdir Havzası	46
Şekil 3.1.1.	Yamula İstasyonu'na ait normalize aylık akış verileri.....	50
Şekil 3.1.2.	ÖB Model derecesine ABK değerleri.....	51
Şekil 3.1.3.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve a. ÖB(12) modelinin elde edildiği veri seti ve tahmin verisi b. ÖB(12) modelinin uygulandığı veri seti ve tahmin verisi	53
Şekil 3.1.4.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve a. ÖBHO(26,27) modelinin elde edildiği eğitim veri seti ve tahmin verisi b. ÖBHO (26,27) modelinin uygulandığı test veri seti ve tahmin verisi	56
Şekil 3.1.5.	a,b,c,d. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve bir, üç, beş, ve on giriş bir ara katmanlı YSA modeli ile elde edilen tahmin verisi	62
Şekil 3.1.6.	a,b,c,d. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve bir, üç, beş ve on giriş iki ara katmanlı YSA modeli ile elde edilen tahmin verisi	68
Şekil 3.1.7.	Hidrolojik verilerin tahmini için AKA-YSA Modelinin şematik gösterimi	70
Şekil 3.1.8.	Yamula İstasyonunda a. Eğitim için kullanılan b. Test için kullanılan aylık akış verileri m^3/sn	71

Şekil 3.1.9.	a. Eğitim için Kullanılan b. Test için Kullanılan IMF bileşenleri	72
Şekil 3.1.10.	IMF bileşenlerine ayrılmış veriler ve 1 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF veriler.....	74
Şekil 3.1.11.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 1 giriş- 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri	76
Şekil 3.1.12.	Yamula istasyonunda aylık akımlar hidrolojik gözlem verisi ve 2 giriş- 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri.....	77
Şekil 3.1.13.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 2 giriş - 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri	79
Şekil 3.1.14.	Yamula istasyonunda aylık akımların tahmini için IMF bileşenlerine ayrılmış test verileri ve 3 giriş - 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler.....	81
Şekil 3.1.15.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 3 giriş - 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri	82
Şekil 3.1.16.	IMF bileşenlerine ayrılmış test verileri ve 4 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler.....	84
Şekil 3.1.17.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 4 giriş - 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler	85
Şekil 3.1.18.	IMF bileşenlerine ayrılmış test verileri ve 5 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler.....	87
Şekil 3.1.19.	Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 5 giriş 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler	88
Şekil 3.1.20.	IMF1 verisi ve TSA yöntemi ile yeniden yapılandırılan IMF1 verisi.....	90
Şekil 3.1.21.	Hidrolojik verilerin tahmini için TSA-YSA Modelinin şematik gösterimi	92
Şekil 3.1.22.	TSA yöntemi ile alt bantlara ayrıştırılmış a. Eğitim Verisi b. Test Verisi	94
Şekil 3.1.23.	Altbant bileşenlerine ayrıştırılmış test verileri ve 3 giriş- 1 çıkışlı TSA-YSA modeli ile tahmin edilen altbant verileri.....	97
Şekil 3.1.24	TSA-YSA modeli kullanılarak elde edilen tahmin verisi.....	99

Şekil 3.1.25.	Hidrolojik veri tahmininde ÖB, ÖBHA, YSA, AKA-YSa, TSA- AKA-YSa, TSA-AKA modellerinin performans değerleri.....	102
Şekil 3.2.1.	Şeytan deresine ait hidrolojik zaman verileri	103
Şekil 3.2.2.a.	Eğitim, b. Test için kullanılan hidrolojik gözlem verileri	104
Şekil 3.2.3.	Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli YSA modeli ile <i>bir</i> ileri zamanlı tahmin verileri.....	106
Şekil 3.2.4.	Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli YSA modeli ile <i>iki</i> ileri zamanlı tahmin verileri	107
Şekil 3.2.5.	Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli YSA modeli ile <i>üç</i> ileri zamanlı tahmin verileri	108
Şekil 3.2.6.a.	Eğitim için kullanılan 13 adet IMF bileşeni, b.Test için kullanılan 13 adet IMF bileşeni.....	110
Şekil 3.2.7.	Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli AKA-YSa modeli ile <i>bir</i> ileri zamanlı tahmin verileri.....	113
Şekil 3.2.8.	Şeytan Deresi günlük akım serisi için IMF2 verisi ve TSA yöntemi ile yeniden yapılandırılmış IMF2 verisi	114
Şekil 3.2.9.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve TSA- AKA-YSa modeli ile elde edilen bir ileri zamanlı tahmin grafiği	115
Şekil 3.2.10.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve dört girişli AKA-YSa modeli ile <i>iki</i> ileri model ile tahmin edilmiş verileri.....	118
Şekil 3.2.11.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve TSA- AKA-YSa modeli ile elde edilen <i>iki</i> ileri zamanlı tahmin grafiği.....	120
Şekil 3.2.12.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve dört girişli AKA-YSa modeli ile <i>üç</i> ileri zamanlı tahmin verileri	123
Şekil 3.2.13.	TSA yöntemi ile alt bantlara ayrıştırılmış a. Eğitim Verisi b. Test Verisi	127
Şekil 3.2.14.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve dört girişli TSA-YSa modeli ile <i>bir</i> ileri zamanlı tahmin verileri	129
Şekil 3.2.15.	Şeytan Deresi günlük akım serisi için gözlenmiş akımlar ve dört girişli TSA-YSa modeli ile <i>iki</i> ileri zamanlı tahmin verileri	131

Şekil 3.2.16.	Şeytan Deresi günlük akım serisi için gözlenmiş ve dört girişli TSA-YSA modeli ile üç ileri zamanlı tahmin verileri.....	133
Şekil 3.2.17.	Şeytan deresine ait hidrolojik verilerin tahmininde YSA, AKA-YSA, TSA-AKA-YSA ve TSA-YSA modellerinin bir, iki, üç ileri zamanlı tahmin performans parametrelerini gösteren; a. MSE değerleri b. MAE değerleri c. R değerleri d. R^2 değerleri	136
Şekil 3.3.1.	Eğirdir Gölüne ait su seviyesini gösteren veriler	137
Şekil 3.3.2.	Eğirdir Gölüne ait tahmin için kullanılan a. Eğitim ve b. Test verileri.....	137
Şekil 3.3.3.	AKA yöntemi ile IMF bileşenlerine ayrıştırılmış a. Eğitim b. Test verisi	138
Şekil 3.3.4.	Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli ile bir-altı ileri zamanlı tahmin verileri, a. Bir ileri zamanlı, b. İki ileri zamanlı, c. Üç ileri zamanlı d. Altı ileri zamanlı.....	140
Şekil 3.3.5.	TSA yöntemi kullanılarak altbant (RC) bileşenlerine ayrıştırılmış a. Eğitim Verisi b. Test Verisi.....	142
Şekil 3.3.6.	Eğirdir Gölü aylık su seviyeleri için gözlenmiş ve TSA-YSA modeli ile bir-altı ileri zamanlı tahmin verileri; a. Bir ileri zamanlı, b. İki ileri zamanlı, c. Üç ileri zamanlı d. Altı ileri zamanlı.....	144
Şekil 3.3.7.	Eğirdir Gölü aylık su seviyeleri için gözlenmiş ve YSA modeli ile bir-altı ileri zamanlı tahmin verileri, a. Bir ileri zamanlı, b. İki ileri zamanlı, c. Üç ileri zamanlı d. Altı ileri zamanlı.....	147
Şekil 3.3.8.	Eğirdir Gölü aylık su seviyelerinin tahmini için AKA-YSA, TSA-YSA ve YSA modellerinin performans parametrelerini gösteren a. MSE değerleri b. MAE değerleri c. R değerleri, d. R^2 değerleri.....	149

GİRİŞ

Su bilimi olarak da adlandırılan hidroloji; suyun zamansal ve mekansal olarak yeryüzündeki dağılımını, çevrimini, fiziksel ve kimyasal özelliklerini, çevreyle ve canlılarla karşılıklı ilişkilerini inceleyen bir bilimdir. Canlılığın devamı, tarımsal sulama ihtiyacı, elektrik üretimi gibi pek çok önemli alanlarda gereksinimi bulunan su kaynaklarının en ekonomik bir şekilde kullanımı, hidroloji bilimine olan ihtiyacın önemini ortaya koymaktadır. Hidrolojik çalışmaların başında gelen su kaynaklarından faydalanırken, suyun kontrol altına alınması, depo edilmesi ve kontrollü tüketilmesi konusundaki çalışmalarda hidrolojik verilerin önemi büyüktür. Yağış, su seviyesi ve akış debisi gibi değişkenler hidrolojide yaygın olarak kullanılan verilerdir [1-3].

Hidrolojik verilerin yeterli derecede ölçümünün bulunmaması durumunda, belirli süreli ölçümlere dayanan tahmin modellerinin kullanılması gerekmektedir. Bu modellerden elde edilecek tahminler ve gelecekte meydana gelecek hidrolojik olayların kestirimine hidrolojik tahmin denmektedir.

Su kaynaklarından en uygun şekilde faydalanabilmek ve işletebilmek için gelecek olayların doğru bir şekilde tahmini önemlidir. Hidrolojik veriler kullanarak gelecekte meydana gelecek olayların tahmini için, olaylarla ilgili kurulacak modellerde oldukça önemli olmaktadır [1-3].

Hidrolojik değişkenlerin zamana bağlı değişimini gösteren verilere zaman serileri adı verilmektedir. Hidrolojik olaylarla ilgili modellerin kurulması aşamasında bu verilere ihtiyaç duyulmaktadır. Genel olarak bu veriler değişkenlerin istatistiksel özellikleri ile ilişkili bilgi vermektedir. Bu verilerin ön işlem yapmadan ilk olarak periyodikliği, düzenliliği ve istatistiksel parametreleri değerlendirilebilir. Hidrolojik verilerin istatistiksel özellikleri ölçüm yerine ve ölçülen değişkene göre değişmektedir. Örneğin akış verileri ölçerken bir nehirden ölçülen debi bilgisini içeren zaman serisinin özelliği ile başka bir nehirden ölçülen debi bilgisi zaman serisi farklı özellikler gösterebilir. Bir

nehirden ölçülen debi bilgisinde, rastgele özellikler ortaya çıkarken, diğerinde periyodik salınımların olduğu deterministik özellikler ortaya çıkabilmektedir. Bu nedenle farklı yerlerden ölçülen zaman verilerinden, görünen kısmının dışında altında yatan salınımları ve işleyişi analiz edebilmek için bazı analiz yöntemleri kullanmak gerekebilmektedir [1-3].

Literatürde hidrolojik verilerin modellenmesi için farklı yaklaşımlar kullanılmaktadır. Bu modellerin pek çoğunda zaman verisi bir ön işlem uygulanmadan doğrudan tahmin edilmeye çalışılmıştır. Hidrolojik verilerin tahmini için genellikle Öz Bağımlı (ÖB) ve Öz Bağımlı Hareketli Ortalama (ÖBHO) tabanlı yöntemler yaygın olarak kullanılmıştır [4-11]. Son 40 yıldır yapay zeka tekniklerinin ilerlemesi nedeniyle bunlar hidrolojik modelleme ve tahmin çalışmalarında kullanılmaktadır. Literatürdeki ilgili çalışmalarıda hidrolojik veriler üzerinde ön işlem uygulanmadan tahmin edilmeye çalışılmıştır. Bazı çalışmalarda, Dalgacık Dönüşümü (DD) yöntemi kullanılarak veriler frekans bileşenine göre altbanta ayrıştırılarak altbant bileşenlerinin tahmini üzerine çalışılmıştır [12-20].

Gerçekleştirilen bu tez çalışmasında hidrolojik verilerin tahmini için lineer yaklaşımlar üzerine kurulu modellerden ÖB ve ÖBHO modelleri ve yapay zeka teknikleri arasında yer alan Yapay Sinir Ağları (YSA) modelleri kullanılmıştır. Ayrıca hidrolojik verilerin tahmininde yenilikçi yaklaşım olarak Ampirik Kip Ayrışımı (AKA) ve Tekil Spektrum Analizi (TSA) yöntemlerini içeren hibrit modeller kullanılarak, performansları analiz edilmiştir. Önerilen modellerde, hidrolojik verilerin tahmini için yeni yaklaşımlar olan TSA ve AKA yöntemleri ile hidrolojik veriler altbantlara ayrıştırılmış ve altbant sinyallerinin tahmini gerçekleştirilmiştir.

Tahmin çalışması için üç grup hidrolojik veri kullanılmıştır. 1. grup veriler; Yukarı Kızılırmak Havzası Kızılırmak nehri üzerine kurulu Yamula istasyonundan kaydedilen aylık ortalama akış miktarını gösteren debi (m^3/sn) verileridir. 2. grup veriler; Meriç havzası Şeytan Deresinden alınan günlük akım miktarını gösteren debi (m^3/sn) verileridir. 3. grup hidrolojik veriler ise Eğirdir havzasında Eğirdir Gölüne ait olup, aylık su seviyelerini (m.) gösteren verilerdir.

Tez çalışmasında yukarıda bahsedilen üç grup veri; salınım bileşenine göre zaman ekseninde ayrışım yapan AKA yöntemi ile altbantlarına ayrıştırılmıştır. Bu altbant

verilerinin tahmini için YSA yöntemi kullanılmıştır. Böylece AKA-YSA hibrit modeli elde edilmiştir. Ayrıca verideki ilişkisiz bileşenlere göre ayrışım yapan TSA yöntemi ile veri altbantlara ayrıştırılmıştır. Elde edilen altbant sinyalleri tahmin edilmiştir. Tahmin edilen altbant sinyallerinin toplamı ile tahmin verisi oluşturulmuştur. Hidrolojik verilerin tahmini için TSA-YSA modeli ortaya konmuştur. Böylece hidrolojik verilerin tahmini için hibrit yapıların performansı analiz edilmiş ve verideki ön işlemin tahmin performansına olan katkısının belirlenmesi amaçlanmıştır.

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Genel Bilgiler


Bütün canlıların ağırlıklarının önemli bir kısmını oluşturan su, yaşamın başladığı andan itibaren canlılar için hayat kaynağı olmuştur.

Yaşam için bu denli önemli olan suyu kullanabilmek için su kaynaklarından rasyonel ve planlı bir biçimde yararlanılması gerekir. Bu amaçla suyun kontrol altına alınması, depo edilmesi ve kontrollü tüketilmesi konusundaki çalışmalarda insanlık tarihi kadar eskidir. Eski çağlarda ampirik yöntemlerle yapılan bu çalışmalar günümüzde “Su Kaynaklarının Geliştirilmesi” adı altında bir mühendislik bilimi oluşturmaktadır [1,2].

Yer kürede (yani yeryüzünde, yeraltında ve atmosferde) suyun çevrimini, dağılımını, oluşumunu, fiziksel, kimyasal ve biyolojik özelliklerini, çevreyle ve canlılarla karşılıklı ilişkilerini inceleyen temel uygulamalı disiplinler arası bilime hidroloji denir. Hidrolojide pek çok bilim dallarından faydalanılmaktadır. Bunlar; hidromekanik, coğrafya, meteoroloji, oşinografi, hidrojeoloji, istatistik, matematik, fizik, kimya gibi temel çalışma alanlarıdır. Hidroloji bilgisi su ile ilgili olaylarda karar verme aşamasında gerekli temel öğelerden biridir [3]. Suyun kullanılması, su miktarının kontrolü ve su kalitesinin kontrolü gibi su ile ilgili yapılan çalışmalar için yapılacak tesislerin planlanması, projelendirilmesi, inşaatı ve işletmeleri aşamalarında hidroloji bilimi oldukça önemlidir [1,2].

Tabiatta su miktarı kütlenin korunumu gereği denge halindedir. Su, tükenmez bir doğal kaynaktır. Yeryüzünde bir yılda düşen yağış, o yıl içerisinde buharlaşıp havaya dönen ve akarsular ile deniz ve okyanuslara akıtılan su miktarının toplamına eşit olması

sebebiyle su miktarı sabit olup zamanla değişmez. Katı, sıvı ve gaz halleri gibi çeşitli hallerde bulunan su yerkürenin çeşitli kısımlarında sürekli olarak devretmektedir. Suyun devrettiği yolların tümüne birden hidrolojik çevrim denmektedir. Atmosferde buhar halindeki su, yoğunlaşarak yağış şeklinde yeryüzüne düşmektedir. Karalar üzerine düşen suyun büyük bir kısmı zeminden ve su yüzeylerinden buharlaşma ve bitkilerden terleme yoluyla atmosfere geri dönmektedir. Bir kısmı bitkiler tarafından tutulmakta, bir kısmı ise yeraltına sızmaktadır. Geriye kalan su ise yerçekimi etkisiyle akarsulara ve denizlere ulaşmaktadır. Denizlere ulaşan su yeniden buharlaşarak atmosfere dönmektedir. Katı, sıvı ve gaz halinde bulunan su çeşitli yollar izleyerek Şekil 1.1.'de görüldüğü gibi döngü içerisinde bulunmaktadır [3,4].



Şekil 1.1. Hidrolojik Çevrim [4]

Doğada hidrolojik olaylar, miktar ve meydana gelme süreleri önceden kesin olarak tahmini imkânsız rastgele olaylardır. Hidrolojik olayların rastgele oluşunda, kararsız atmosferik hareketin önemi büyüktür. Bununla birlikte dünyanın güneş etrafında dönmesinin de bir sonucu olarak hidrolojik olaylar döngüsel ve stokastik olarak meydana gelmektedir [3,4].

Hidrolojik çalışmaların gerçekleştirilebilmesi için öncelikle gözlem ve ölçümlerin yapılabilmesi, verilerin işlenmesi, istatistiksel analiz tekniklerinin verilere uygulanması ve matematiksel modellerin kurulması gerekmektedir.

Gelecekte meydana gelecek hidrolojik olayların kestirimine hidrolojik tahmin denmektedir. Su ile ilgili olayların ne zaman sonra meydana geleceğinin bilinmesi gelecekteki su durumunun tahmini ile olmaktadır. Hidrolojik olayların gelecekteki miktarlarının bilinmesi, doğa karakterini ve davranışını analiz ve öngörmek için, ayrıca su kaynaklarından optimum olarak faydalanabilmek ve su yönetiminin desteklenmesi için, oldukça önemli olmaktadır. Hidrolojik tahminler evsel ihtiyaçlar için potansiyel su kaynaklarının mevsimsel değişimleri, sulama, hidroelektrik üretim, sel ve kuraklık gibi doğal felaketlerin incelenmesi, gerçek zamanlı tahminler için oldukça önemlidir.

Hidrolojik tahminler kısa, orta ve uzun vadeli olmak üzere üç şekilde gerçekleşmektedir. Kısa vadeli hidrolojik tahminler, 2 güne kadarki tahmin periyodunu kapsarken, orta vadeli hidrolojik tahminler, 2 ila 10 gün arasındaki periyodu kapsamaktadır. Uzun vadeli hidrolojik tahminler ise 10 günden sonraki süreci kapsamaktadır.

Hidrolojik tahmin yapılmasında, bir zaman serisi oluşturan hidrolojik olayların modellerinin kurulması ve analizlerinin yapılması önemli olmaktadır.

Bu tez çalışmasında, hidrolojik verilerin tahmin edilmesi konusu ele alınmıştır. Doğası gereği lineer olmayan ve durağan olmayan bu verilerin tahmini için uygun yöntemler araştırılarak AKA, TSA ve YSA yöntemleri ile tahmin çalışması yapılmıştır.

1.2. Literatür Çalışması

Hidrolojik veriler; su kaynaklarının geliştirilmesinde doğa karakterini ve davranışını analiz etmede ve öngörmekte önemli yer tutmaktadır. Bu veriler doğası gereği lineer olmayan ve durağan olmayan karakterdedir. Bu verilerin tahmini ve simülasyonu için günümüze kadar pek çok çalışma yapılmıştır. Yapılan çalışmalar ilk olarak lineer yaklaşımlar üzerine kurulu olup, parametrik Özbağımlı Hareketli ortalama (ÖBHO) ve Özbağımlı İntegralli Hareketli ortalama (ÖBİHO) gibi modeller, zaman serilerini analiz etmek üzere, 1970 li yıllardan beri ortaya konmuştur [4-6]. Bu teknikler, temel

olarak lineer modellerdir ve zaman verisinin durağan ve lineer olduğunu varsayarak modelleme yapmaktadır. ÖBHO modellerinden; Mevsimsel ÖBİHA (MÖBİHA), Peryodik Özbâğılımlı (PÖB), Peryodik ÖBHO (PÖBHO), Kesirsel ÖBİHA (KÖBİHA) gibi pek çok lineer parametrik modeller de geliştirilmiştir. Bu modellerden bazıları ve uygulamaları Granger ve Joyeux, Noakes ve arkadaşları, Montanari ve arkadaşları ve Grimaldi tarafından gerçekleştirilmiştir [7-10]. Dalgacık analizi, Wigner-Ville dağılımı ve Kısa Zamanlı Fourier analizi gibi yöntemler lineer fakat durağan olmayan veri analizi için tasarlanmışlardır [11-13]. Hidrolojik değişkenlerin tahmininde; Dalgacık analizi kullanarak Labat D. ve arkadaşları, Smith L. C. ve arkadaşları, Adamowski J. ve arkadaşları tarafından akımların karakterizasyonu ve tahmini üzerine çalışmalar yapılmıştır [14-20].

Ayrıca nonparametrik modellerde hidrolojik zaman seri tahmin ve analizi için kullanılmıştır. İlk olarak Yakowitz nehir akışı ile ilgili stokastik bir model ortaya koymuştur [21]. Yakowitz, Yakowitz ve Karlsson, Shamseldin ve O'Connor, nehir akış verileri için Markov zinciri, en yakın komşu metodları ve uygulamaları ile ilgili çalışmalar gerçekleştirmiştir [22-24].

Nonlineer zaman seri analizinin hidroloji uygulamaları arasında Kember ve arkadaşları, Lall ve arkadaşları, Porporato ve Ridolfi'nin çalışmaları bulunmaktadır [25-27].

Son yıllarda yapay zeka teknikleri (Artificial Intelligence- AI) nonlineer hidrolojik uygulamalarda ve gürültülü veri setlerinde yaygın olarak uygulanmaktadır [28-32]. Yapay zeka metotları matematiksel optimizasyon algoritmaları içerdiği gibi lojik, sınıflandırma, istatistiksel öğrenme, ve olasılık tabanlı yöntemlerde kullanılmaktadır. İnsan beynindeki nöron yapısını modelleyerek bilginin paralel işlenmesi prensibine dayalı çalışan Yapay Sinir Ağları (YSA), hidrolojik verilerin tahmini üzerine pek çok çalışmada kullanılmaktadır. ASCE Task komitesi tarafından yapılan çalışmada YSA'nın hidrolojideki yeri araştırılmıştır. YSA'nın diğer yaklaşım modellerine göre güçlü olduğu yanlarını ve sınırlamalarını ortaya konulmuştur [33]. Genelde bir YSA modeli girişin uygulandığı giriş katmanı, aktivasyon fonksiyonunun uygulandığı gizli katman ve çıkış katmanından oluşmaktadır. Hidrolojik verilerin modellenmesinde kullanılan İleri Beslemeli Geri Yayılımlı YSA (İBGYSA) algoritmasını sinir ağlarında ilk defa Hornik ve arkadaşları uygulamıştır. Bu algoritma, hedef ve tahmin edilen değerler arasındaki

hatayı en iyi bağlantı ağırlıklarını araştırarak bulmaktadır [34]. Radyal Tabanlı Fonksiyon Sinir Ağları (RTFSA) modeli YSA'nı literatüre ilk defa Broomhead ve Lowe sunmuştur [35]. Genelleştirilmiş Regresyon Sinir Ağları (GRSA) yapıları ise Specht tarafından ortaya konmuştur [36]. Cıgızoğlu, GRSA yapıları kullanarak akış tahmini üzerine çalışmıştır [37]. Hsu ve ark. çok değişkenli YSA modelini yağış-akış problemine uygulamıştır. Bu yöntem hızlı, hassas ve ucuz uygulamalar için uygun ve iyi sonuç vermektedir [38]. Chiang ve ark. YSA üzerine yeni bir yaklaşım getirerek yağış-akış problemine uygulamıştır. Bu yöntem öğrenme aşamasında dinamik sinir ağlarının tekrarlı bir şekilde yinelemesine yardımcı olmaktadır [39]. Cıgızoğlu yaptığı çalışmada kesikli günlük yağış miktarını tahmin etmek için GRSA yaklaşımını kullanmıştır. GRSA yapıları İBGYSA algoritmasında olduğu gibi yerel minima problemi yaşamamaktadır. Bu nedenle GRSA yapılarının İBGYSA'lı yapılara göre daha iyi sonuç verdiği tahmin probleminde ortaya konmuştur. Moradkhani ve arkadaşları Özörgütlemeli Radyal Taban (ÖRT) fonksiyon kullanarak bir ileri akım tahmini yapmıştır ve iyi bilinen Çok Katmanlı Algılayıcı İleri Beslemeli Sinir Ağları (ÇKAİBSA) ile karşılaştırmıştır. Yapılan çalışmaya göre; ÖRT yapılarının nonlinear modellere uygun olduğunu ortaya konmuştur [40]. Hu ve arkadaşları YSA temelli yağış-akış modellerinin genel performansını iyileştirmek üzere, Modifiye YSA ortaya koymuştur. Bu modelde üç gelişim noktası yaygın olarak kullanılan geri yayımlı YSA ile karşılaştırılmıştır. Bu çalışmadaki üç gelişim; a) hidrolojik ön bilginin YSA'nın öğrenmesinde kullanılması, b) değiştirilmiş objektif fonksiyonun birleştirilmesi c) giriş hatalarına karşı YSA duyarlılığının azaltılmasıdır [41]. Wu ve arkadaşları havza akış ve nehir akımı tahmini üzerine çok katmanlı ileri beslemeli YSA kullanarak tahmin işlemi gerçekleştirmiştir. Bu çalışmada i) artık yağmurdan oluşan yüzeysel su akış tahmini için dört ileri tahmin veya bir saat ileri tahmin (15 dakikalık zaman aralıkları) ve ii) akıntıya karşı istasyonlardaki pik akışa ulaşana kadarki eşit aralıklarda taşkın akışı tahmini olmak üzere iki model geliştirilmiştir [42].

Kişi, kısa dönem günlük akım tahmini için farklı öğrenme algoritmaları YSA yapıları kullanmıştır. Bunlar Geri Yayılımlı, Eşlenik Gradyent, Kaskad Korelasyon ve Levenberg Marquardt algoritmalarıdır. Sonuçlar, Levenberg Marquardt algoritmasının diğer algoritmalarla göre eğitim aşamasında daha kısa süreli olduğunu ve en iyi akış tahmini yaptığını ortaya koymuştur [43].

Ahmed ve Sarma sentetik akım üretimi için YSA tabanlı model kullanmıştır. Thomas Fiering model ve ÖBHO model olan iki geleneksel model YSA ile karşılaştırılmıştır. Akış bilgisini gösteren zaman serileri her bir aya ait akışın ortalaması, her bir aya ait akışın standart sapması, akış serisinin ortalaması, akış serisinin standart sapması ve akış serisinin eğriliğini içeren beş adet istatistiksel parametre ile üretilmiştir. Bu çalışmanın sonucunda sentetik akış serileri, geleneksel Thomas Fiering model ve ÖBHO modellerine göre YSA modeli ile daha iyi elde edildiği belirtilmiştir [44].

Jain ve Kumar geleneksel zaman serisi analizi teknikleri ve YSA yaklaşımının kuvvetli yanlarını içeren bir model ortaya koymuştur. Önerilen yaklaşım geleneksel ve YSA tekniklerini içermektedir. Kompleks zaman serilerinin analizinde sunduğu farklı yapılardaki YSA'nın güçlü bir model olduğunu belirtmiştir [45].

Bir diğer çalışmada Toth ve Brath YSA modelin gerçek zamanlı tahmin kabiliyetini araştırmıştır. Sonuçta YSA'nın sürekli periyotlarda (düşük, ortalama ve pik akışlar) gerçek zamanlı yağış-akış simülasyonunda çok başarılı bir araç olduğu belirtilmiştir [46].

Mutlu ve arkadaşları Çok Katmanlı Algılayıcı Sinir Ağları (ÇKASA) ve RTFSA modellerini dört ölçme istasyonundan akış bilgisini tahmin etmek üzere kullanmıştır. Veri setlerinin farklı kombinasyonları akım tahmini yapmak üzere kullanılmıştır. Her iki modelde giriş vektörü kros – oto - ve kısmi otokorelasyon gibi istatistiksel özellikleri içermektedir. Her iki modelin de akış tahmininde yeterli performansı sergilediği belirtilmiştir. Ancak özellikle ÇKASA modelinin RTFSA modeline göre daha başarılı olduğu ortaya konmuştur [47].

Kagoda ve arkadaşları RTFSA modelini kullanarak akış verilerinden 1 günlük ileri tahmin çalışması yapmıştır. İdeal model yaklaşımının gelişen ülkelerde bazı havzaların kompleks veri yoğunluğuna sahip olması sebebiyle önemli olduğu belirtilmiştir. Elde edilen sonuçlara göre YSA'nın akış tahmininde tatmin edici olduğu belirlenmiştir [48].

YSA'nda; Elliott sigmoid, Bipolar sigmoid ve Tanjant sigmoid fonksiyonların etkinliği Yonaba ve arkadaşları tarafından incelenmiştir. ÇKASA modeli ile muhtelif havzalardan 1-5 günlük ileri tahmin çalışması yapılmıştır. Test ve eğitim girdi setlerini seçmek üzere; Kohonen ağları kümeleme yöntemi kullanılmıştır. Bayes regularizasyon

ile modifiye edilmiş Levenberg Marquardt eğitim algoritması ve ÇKASA modeli oldukça başarılı sonuçlar sergilemiştir. Özellikle Tanjant Sigmoid fonksiyon ile diğer fonksiyonlara göre daha başarılı sonuçlar elde edilmiştir [49].

Yakın zamanlarda Danandeh Mehr ve arkadaşları YSA kullanarak başarılı akım tahmin modeli geliştirmiştir. Bu çalışmada akış tahminine pratik bir yaklaşım olarak aylık akım kayıtları kullanılmıştır. İlk aşamada sekiz adet farklı istasyon tahmin senaryosu ortaya konmuştur. İBGYSA modeli nehir için uygun arama aracı olarak kullanılmıştır. Ayrıca GRSA ve RTFSA modelleri seçilen senaryolar için yeni modeller olarak kullanılmaktadır. Yapılan çalışmanın sonucuna göre; istasyonlarda 1 aylık süreli aralıkların yüksek verimlilikte başarı sağladığı görülmektedir [50].

Veintimilla-Reyes ve arkadaşları, Tomebamba nehrindeki akımı tahmin etmek üzere, YSA temelli bir yaklaşım üzerine çalışmıştır. YSA girişleri istasyondan ölçülen akım miktarı olarak belirlenmiştir. Geri yayımlı ve çıkış veri bağlantılarını ağırlıklandıran modifiye bir model olmak üzere iki tip YSA kullanılmıştır. Sonuçları test etmek üzere; Ortalama Karesel Hata, Kök Ortalama Karesel Hata, Etkinliği, Determinasyon Katsayısı ve Yanlılığı (MSE, RMSE, EF, CD ve BIAS) performans parametreleri kullanılmıştır. Elde edilen sonuçlara göre geri yayımlı YSA tahminlerinin Cucenca şehrindeki taşkınları tahmin etmede başarılı olduğu ortaya konmuştur [51].

Son zamanlarda Karar Destek Makinaları (KDM) kullanılarak hidrolojik veri modelleme ve veri tahmini çalışmaları yapılmaktadır. Sivapragasam ve arkadaşları yaptığı çalışmada KDM kullanarak akımına ait hidrolojik veri tahmin çalışması gerçekleştirmiştir. Model girişleri geçmişteki akarsu akım verileri olarak belirlenmiştir. Akış sahası düşük, orta ve yüksek olmak üzere sınıflandırılmıştır ve nitelikleri akış alanındaki hidrolojik proseslere göre belirlenmiştir. Çalışmanın sonucunda üç ileri tahmin için KDM modelinin tatmin edici olduğu ortaya konmuştur [52].

Li ve arkadaşları modifiye KDM yöntemini rezervuar giriş akımını tahmin etmek üzere kullanmıştır. Bu çalışmada KDM parametrelerinin optimizasyonu için Genetik Algoritma kullanılmıştır. Önerilen modifiye KDM modelinin tahmin başarısı Çoklu Lineer Regresyon, KDM yöntemleriyle karşılaştırılmıştır. Çalışmanın sonucunda modifiye KDM yönteminin başarısının karşılaştırılan diğer yöntemlere göre daha üstün olduğu ortaya konmuştur [53].

Noori ve arkadaşları KDM'nın performansını değerlendirmek üzere giriş vektörünün belirlenmesi üzerine çalışma yapmıştır. Gelecek aydaki akım tahminini gerçekleştirmek üzere 18 özellik (yağış miktarı, güneş radyasyonu vb.) kullanılmıştır. Bu özellikler Temel Bileşenler Analizi, Gama Testi, İleri Seçim gibi veri azaltma teknikleri kullanılarak 12 adet özelliğe indirilmiştir. Bu çalışmada sonuç olarak veri azaltma teknikleri kullanılarak tahmin başarısının arttığı ortaya konulmuştur [54].

Nonlinear Regresyon ve Zaman Serileri problemlerini çözmek için Ch ve arkadaşları Parçacık Sürü Optimizasyon yönteminin modifiye hali olan Kuantum Parçacık Sürü Optimizasyon tabanlı KDM yöntemini kullanmıştır. Çalışmada kullanılan modelin akım tahmininde başarılı olduğu sonucuna varılmıştır [55].

He ve arkadaşları, yarı kurak bölgede akımını tahmini için YSA, KDM ve Adaptif Nöro Bulanık Sistem (ANBS) modelleri kullanmıştır. Zaman serileri; farklı zaman aralıklarında farklı kombinasyonlarla tahmin edilmeye çalışılmış, sonuçta Bu çalışmanın sonucunda KDM yönteminin diğer yöntemlere göre daha başarılı olduğu belirtilmiştir [56].

Kompleks sistem davranışını belirlemede sıklıkla kullanılan ANBS model El-Shafie ve arkadaşları tarafından aylık akım miktarını tahmin etmek üzere kullanılmıştır. Bu çalışmada, 130 yıllık aylık akım miktarını gösteren bir veri tabanı ANBS modelini eğitim ve testi için kullanılmıştır. Çalışmanın sonucunda ANBS modelinin aylık akım tahmini için güvenilir bir model olduğu belirtilmiştir [57].

Nayak ve arkadaşları yapay zeka tekniklerinden YSA ve ANBS modellerini birleştirerek hibrit bir modelle yağış-akış probleminde kullanmıştır. Öne sürülen hibrit modelin performansı tek başına diğer modellerle karşılaştırıldığında; daha az parametre, süre ve kural tabanı ile daha iyi sonuçlar elde edildiği ifade edilmiştir [58].

Özger yaptığı çalışmada genetik algoritma ile eğitilmiş Mamdani ve Tagai Sugeno tip bulanık sistem kullanarak, akım tahmini üzerine bir çalışma yapmıştır. Çalışmanın sonucunda Mamdani tip bulanık sistem modelinin performansının Tagai Sugeno tip modele göre daha üstün olduğu ortaya konmuştur [59].

Sanikhani ve Kişi akım bilgisini tahmin etmek üzere iki farklı ANFIS sistemi kullanmıştır. Alt sınıflandırıcılı ANBS (ANBS-SC) ve ızgara bölümlleme (ANBS-GP) bir ileri adım tahmini için kullanılmıştır. Gerçekleştirilen çalışmada verideki periyodikliğin tahmin üzerindeki etkisi analiz edilmiştir. Ayrıca iki farklı ANBS tekniğinin performansı analiz edilmiştir. Sonuç olarak ANBS-SC modelinin ANBS-GP modeline göre biraz daha başarılı olduğu ortaya konmuştur [60].

Günlük nehir akımını modellemek üzere, Greco, Bulanık-Özbağımlı (B-ÖB) model kullanmıştır[61]. ÖB model taban akışını belirlemek üzere, bulanık kurallar ise yağış-akış dönüşümündeki temel fiziksel özelliklerine göre tanımlanmıştır. Giriş akımları; günlük olarak, altı adet yağış ölçüm istasyonunun ortalaması ile ölçülmüştür. Çalışmanın sonucunda düşük nehir akımlarında ve yüksek taşkın durumlarında önerilen modelin performansının yüksek olduğu gösterilmiştir [61].

Son zamanlarda su kaynaklarının tahmini ve modellemesi üzerine evrimsel tekniklerin kullanımı araştırmacıların uygulamaları arasında yer almaktadır. Evrimsel teknikler, Evrimsel Algoritma (EA) [62,63], Genetik Algoritmalar (GA) [64], Evrimsel Strateji (ES) [65] ve Genetik Programlama (GP) [66] olmak üzere dört bölüme ayrılmaktadır. Ancak tüm katagorilerin ortak özelliği Seçim, Dönüşüm ve Yeniden üretme durumlarının uygulanmasıdır [62-66].

Whigham ve Crapper, grametik tabanlı Genetik Algoritma kullanarak yağış-akış ilişkisini tanımlamaya çalışmıştır [67]. Bağımsız veri seti üzerinde bulgular toplu parametrelili model ile karşılaştırılmıştır. Özellikle su hareketinin nonlineer olması durumunda önerilen yöntemin hidrolojik modellerin gelişmesinde başarılı olduğu sonucuna ulaşılmıştır [67].

Dorodo ve arkadaşları, kentsel alandaki çeşitli taşkınları uyarmak için bir alarm sistemi araştırmıştır. GP ve YSA modellerinin yağış-akış ilişkisini tanımlamak üzere kullanılmıştır. GP tekniğinin; parametreler ve bu parametreler arası matematiksel ifadelerin oluşumunda çok başarılı olduğu ifade edilmiştir [68].

Akımını tahmininde Makkeasorn ve arkadaşları yapay zeka tekniklerinden GP ve YSA kullanmıştır. Çalışmanın sonucunda GP tabanlı akım tahmininin tahminin hassasiyetini artırmada avantajlı olduğu belirtilmiştir [69].

Zaman serilerinin analizinde sıklıkla kullanılan Dalgacık Dönüşümü (DD) sinyallerin zaman ve frekans ekseninde analizini sağlamaktadır. Hidrolojik verilerin tahmininde DD, sinyalin farklı çözünürlük seviyelerinde ayrıştırılarak, tahminin kolaylaştırılmasını sağlaması sebebiyle kullanılmaktadır. DD, Fourier Dönüşümüne (FD) göre bir takım avantajlara sahiptir. DD ve FD yöntemlerini Sifuzzaman detaylı olarak karşılaştırarak analiz etmiştir [70].

Partal, farklı YSA yapılarını DD ile birleştirerek akım tahmini için hibrit bir model geliştirmiştir. Bu modelde akış verileri periyodik bileşenlerine ayrıştırılmıştır. Ayrıştırılmış verilerin tahmini için YSA yapısı kullanılmıştır. Sonuçta geliştirilen hibrit yapı ile başarılı tahmin işlemi gerçekleştirilmiştir [71].

Shiri ve Kişi, hibrit Dalgacık-Nöro-Bulanık (DNB) sistem kullanarak günlük, aylık ve yıllık akım tahmini gerçekleştirmiştir [72]. İlk olarak sadece Neuro-Fuzzy sistemle tahmin yapmıştır. Daha sonra DNB sistemle tahmin gerçekleştirerek modelleri karşılaştırmıştır. Çalışmanın sonucunda Dalgacık modelinin tahmin sistemine eklenmesi ile özellikle periyodik bileşenlerin tahmininde iyileşme olduğu görülmüştür [72].

Yarar aynı yöntemi ve ÖBHO modelini akım tahmininde kullanmıştır [73]. Aylık ortalama akım veri seti alt serilere ayrıştırılmıştır ve bir sonraki ay ile olan korelasyonlarına bakılmıştır. Çalışmanın sonucunda DNB yönteminin ÖBHO yöntemine göre üstün olduğu belirtilmiştir [73].

Adamowski ve Sun, Dalgacık Dönüşümü ve YSA modellerini birleştirerek akım tahmini gerçekleştirmiştir [74]. Veri seti Dalgacık Dönüşüm yöntemi kullanılarak, alt serilere ayrıştırılmış ve alt seri sinyalleri YSA ile tahmin edilmiştir. Bu çalışmanın sonucunda Dalgacık-YSA modelinin YSA modeline göre 1-3 ileri tahminde daha başarılı olduğu ortaya konmuştur [74].

Pramanik ve arkadaşları Dalgacık-YSA modeli kullanarak akım tahmini üzerine çalışma yapmıştır [75]. Bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) ile günlük akım verileri Dalgacık katsayılarına ayrıştırılmıştır. Ayrıştırılan akım verileri YSA kullanılarak, 1,2 ve 3 ileri günlerde tahmin edilmiştir. Bu çalışmanın sonucunda da Dalgacık-YSA modelinin, tahmin performansının yüksek olduğu belirtilmiştir [75].

KDM modelinin hassasiyetini geliřtirmek üzere Guo ve arkadaşları tarafından adaptif bir yapı kullanan KDM modeli ortaya konulmuřtur [76]. Ayrıca KDM parametrelerini optimize etmek üzere Parçacık Sürü Optimizasyon algoritması kullanılmıřtır. Elde edilen KDM model Dalgacık Dönüřümü ile birleřtirilerek Dalgacık-KDM modeli elde edilmiřtir. Sonuç olarak, sunulan modelin kompleks yapıdaki hidrolojik zaman serilerinin sınıflandırılmasında oldukça bařarılı olduđu ifade edilmiřtir [76].

Bir bařka çalıřma, YSA ve Destek Vektör Regresyon (DVR) modeli Dalgacık dönüřümü ile birleřtirilerek akım tahmini Kalteh tarafından yapılmıřtır. Çalıřmanın sonucunda Dalgacık-YSA ve Dalgacık-DVR modeli YSA ve DVR modellerinin tek bařına kullanımından çok daha yüksek tahmin bařarisına sahip olduđu bilgisi elde edilmiřtir[77].

Danandeh Mehr ve arkadaşları ADD-YSA modeli kullanarak akım tahmini gerçekleřtirmiřtir [78]. Bir ileri tahmin için kullanılan YSA modeli İleri Beslemeli Sinir Ağlarından oluřmaktadır. Giriř verileri Daubechies Dalgacık fonksiyonu kullanarak 4 seviyeye ayrıřtırılmıřtır. Çalıřmanın sonucunda, durağan olmayan veri serisi için ADD-YSA modelinin uygun olduđu ortaya konmuřtur [78].

Makwana ve Tiwari Dalgacık tabanlı YSA (DYSA) modeli hidrolojik veri tahmininde kullanmıřtır [79]. Çalıřmada, modelin eđitilmesinde test verisinin modele dahil edilmesi ya da edilmemesi řeklinde iki yaklařım kullanılmıřtır. Çalıřmanın sonucunda DYSA modelinin, kesikli verinin tahmininde bařarılı olduđu ortaya konmuřtur [79].

Sahay ve Srivastava, Dalgacık Dönüřümü-Genetik Algoritma-YSA (DGASA) modeli kullanarak, Muson nehir akımının 1 ileri tahmininde kullanmıřtır [80]. Bu veriler; rastgele piklerin ortaya çıktıđı geniř olaylarda ve deđiřen sürelerde sürekli akımlar olması sebebiyle tahmini zor verilerdir. Bu çalıřmada Genetik Algoritma YSA'nın bařlangıç parametrelerini optimize etmek için kullanılmıřtır. Çalıřmanın sonucunda DGASA model ÖB ve GA optimize YSA modelinden daha yüksek performansta tahmin bařarısı gösterdiđi belirtilmiřtir [80].

Görüldüđu gibi; yapılan ilgili literatür çalıřmalarına göre, son zamanlarda lineer ve durağan olmayan verilerin tahmininde nonlinear modeller olan YSA, KDM, ANBS gibi yapay zeka tekniklerine dayalı yaklařımlar kullanılmıřtır. Ancak bu yaklařımların

performansını artırmak için hibrit yaklaşımlar geliştirilmiştir. Hibrit yaklaşımlardan en yaygın olarak Dalgacık-YSA modeli çalışmalarda yer almaktadır.

Son zamanlarda lineer olmayan ve durağan olmayan verilerin analizinde ampirik yaklaşımın kullanıldığı, Ampirik Kip Ayırışım (AKA) tekniği literatürde yer almaktadır [81,82].

Karthiyekean ve arkadaşları, AKA yöntemi ve Dalgacık yöntemini kullanarak, zaman serilerini ayırtmış ve altbant verilerini ÖB yöntemi kullanarak tahmin etmeye çalışmıştır. Bu çalışmada, AKA ve Dalgacık yöntemlerinin tahmin işleminde kullanılabileceğini ortaya koymuştur [83].

Wei Nehri havzasına ait verilerin tahmininde Huang ve arkadaşları, AKA-KDM hibrit modelini kullanmışlardır [84]. Bu çalışmada AKA-KDM modelinin performansını iyileştirmek için, İçsel Mod Fonksiyon (İMF) bileşenlerinden yüksek frekans içeren İMF1 bileşeni tahmin aşamasında kullanılmamıştır. Sonuç olarak değiştirilmiş AKA-KDM yönteminin tahminde oldukça başarılı olduğu belirtilmiştir [84].

Wang ve arkadaşları, hisse senedi fiyat dalgalanmalarının bir ileri zamanlı tahmini için AKA yöntemi ve stokastik YSA (SYSA) yöntemlerini kullanmıştır [85]. AKA yöntemi kullanarak zaman verileri salınım bileşenlerine ayrıştırılmıştır. Lineer Regresyon yöntemi ile önerilen yöntemin tahmin etme performansı incelenmiştir. Önerilen yöntemin geleneksel yöntemlere göre tahmin başarısındaki etkinliği incelenmiştir. Bu çalışmada, ayrıca yeni değerlendirme kriteri olarak q derece çoklu skalalı komplekslik değişmezlik mesafesi (q -order multiscale complexity invariant distance), gerçek veri ve tahmin edilen veri arasındaki tahmin başarısını belirlemek üzere kullanılmıştır. Sonuç olarak; önerilen yöntemin borsa dalgalanmalarını tahmininde oldukça başarılı olduğu ortaya konmuştur [85].

Zhang ve arkadaşları AKA yöntemi, Radial Tabanlı Fonksiyon Sinir Ağları (RTFSA) ve harici güç (External Force, EF) değişkenleri kullanarak, CEREF olarak isimlendirilen hibrit bir model ile tahmin çalışması yapmıştır [86]. Bu modelde, AKA yöntemi ayrıştırma aşamasında, RTFSA yöntemi ise IMF bileşenlerinin tahmini için kullanılmıştır. Gelecek trend bileşeni EFli regresyon işlemi ile belirlenmiştir. Bu çalışmada Wuding akarsu havzası verileri tahmin için kullanılmıştır. Ortalama karesel

hata (RMSE) ve ortalama mutlak hatadan (MAE) oluřan iki istatistiksel parametre önerilen modelin performansını ölçmek üzere kullanılmıştır. Önerilen yöntem, ÖB, RTFSA ve AKA-RTFSA yöntemi ile karşılaştırılmıştır. Çalışmanın sonucunda CEREF yönteminin diğerk yöntemlere göre oldukça başarılı olduğı belirtilmiştir [86].

Sinyali zaman bilgisine göre ayırıştıran ikinci önemli yöntem de, çok değıřkenli analiz teknikleri arasında yer alan ve çok güçlü tekniklerden olan Tekil Spektrum Analizi (TSA) tekniğidir. Bu teknik, durağan ve durağan olmayan verilerin analizinde kullanılması, parametrik olmayan bir model olması ve AKA tekniğinde olduğı gibi veri ile ilgili ön bilgi gerektirmemesi sebebiyle son zamanlarda oldukça yaygın olarak kullanılmaya başlanmıştır [87,88].

Rocco, TSA yöntemi kullanarak arıza durumunun tespiti üzerine bir çalışma yapmıştır. Çalışmanın sonucunda TSA yönteminin zaman serilerinden arıza tahmininde kullanılıřlı bir yöntem olduğı ortaya konmuştur [89].

Wang ve arkadaşları, TSA ve DVR modeli kullanarak arıza tahmini üzerine çalışma gerçekleřtirmiştir. Bu çalışmada önerilen yöntemin arıza tahmininde oldukça başarılı olduğı ortaya konmuştur [90].

Marques ve arkadaşları, hidrolojik zaman verilerinin tahminini, TSA yöntemi kullanarak gerçekleřtirmiştir. Bu çalışmada su sıcaklığına ait zaman eksenindeki veriler, yavaş değıřen ve hızlı değıřen bileřenlere ayırıştırılmıştır. Alt bileřenlerin tahmini ile toplam veri tahmini başarılı bir şekilde gerçekleřtirilmiştir [91].

Literatür çalışmaları incelendiğinde; son dönem tahmin çalışmalarında hibrit modellerin kullanıldığı görölmektedir. Gerçekleřtirilen tez çalışmasında hidrolojik verilerin tahmini için yapılan ön iřlem ařamasında AKA ve TSA yöntemleri kullanılmıştır. Hidrolojik veriler, AKA-YSA ve TSA-YSA hibrit modelleri kullanılarak, tahmin edilmeye çalışılmıştır. Geliřtirilen modelin performansı, YSA modeli ile karşılaştırılmıştır. Tez çalışmasının bölümleri ařağıda verilen řemada görölmektedir.



Şekil 1.2. Tez Çalışmasının Bölümleri

2. BÖLÜM


MATERYAL VE YÖNTEM

2.1. Hidrolojik Verilerin Tahmini için Klasik Yaklaşımlar

Doğadaki hidrolojik sistemin soyutlanmış bir benzeri olarak düşünülen hidrolojik modeller mühendislik çalışmalarında gerekli olan hidrolojik büyüklüklerle ilgili bilgilerin elde edilmesini sağlamaktadır. Hidrolojik olayların modellenmesi ve tahmini için öncelikle doğal verilerin ölçülmesi gerekmektedir. Hidrolojik veriler, suya ait zaman içerisinde sıralanmış ölçümlerinin bir kümesidir. Bu zaman serisi verileri genel eğilim (trend), mevsimsel bileşen, çevrimsel bileşen ve gürültü bileşenlerinden oluşmaktadır. Ölçümlerle elde edilen verilere ve fiziğin temel yasalarına dayanarak hidrolojik olayların incelenmesi ve tahmini için lineer ve nonlineer yaklaşımlara dayalı modeller kurulmaktadır. Bu modellerden ÖBHO ve ÖB modelleri lineer yaklaşımlara dayalı hidrolojik verilerin modellenmesi ve tahmini için kullanılan klasik yöntemlerin başlıcalarını oluşturmaktadır [1].

2.1.1. Özbağımlılı Hareketli Ortalama Modelleme

ÖBHO modelleme, hidrolojik verilerin tahmininde kullanılan en eski ve temel yöntemlerden birisidir. Bu model; Lineer Zamana Göre Değişmeyen (LZD) bir sisteme rastgele değişkenin (beyaz gürültünün) uygulandığı varsayılarak elde edilen sistem çıktısı; sisteme uygulanan girişin şimdiki ve geçmiş değerleri ile sistem çıktısının geçmiş değerleri kullanılarak elde edilmektedir.



Şekil 2.1. ÖBHO modele ait LZD sistem Giriş-Çıkış ilişkisi [92]

ÖBHO (p,q) modeli;

$$x[n] = -\sum_{l=1}^p a_k[l]x[n-l] + \sum_{l=0}^q b_k[l]w[n-l] \quad 2.1$$

biçimindeki Sabit Katsayılı Lineer Fark Denklemi ile ifade edilmektedir. Bu denklemde görüldüğü gibi $x[n-l]$ sistem çıkışının geçmiş değerlerini, $w[n-l]$ LZD sistem girişine ait beyaz gürültü sinyalinin geçmiş değerlerini göstermektedir. Denklemde yer alan a_k ve b_k katsayıları ÖBHO modele ait model parametreleridir. Modeldeki $w[n]$ beyaz gürültünün, ortalaması sıfır ve varyansının σ_w^2 olan Normal dağılımlı bir rastgele değişken olduğu kabul edilmektedir.

Eşitlik 2.1 de verilen denklemin Z dönüşümü alınırsa, sistemin transfer fonksiyonu elde edilmektedir.

$$H(z) = \frac{B_q(z)}{A_p(z)} = \frac{\sum_{k=0}^q b_q[k]z^{-k}}{1 + \sum_{k=1}^p a_p[k]z^{-k}} \quad 2.2$$

ÖBHO modele ait model parametrelerinin belirlenebilmesi için literatürde en küçük kareler yaklaşımına ve sinyalin doğrudan kendisiyle ilişkisine dayalı yöntemler bulunmaktadır. Bu yöntemler arasında $x[n]$ çıkış sinyalinin otokorelasyonu kullanılarak model parametrelerini hesaplayan Yule Walker eşitliği oldukça yaygın kullanılmaktadır [92].

2.1.1.1. ÖBHO Model Parametrelerinin Belirlenmesi için Yule-Walker Eşitliği

Yule-Walker eşitliğinde 2.1 numaralı denklemin her iki tarafı çıkış verisinin geçmiş değerleri ($x^*[n-k]$) ile çarpılır ve eşitliğin her iki tarafının beklenen değeri alınırsa 2.1 numaralı eşitlik aşağıdaki gibi ifade edilmektedir.

$$r_x[k] + \sum_{l=1}^p a_p[l] r_x[k-l] = \sum_{l=0}^q b_q[l] E[w[n-l]x^*[n-k]] \quad 2.3$$

Eşitlik 2.3 teki ifadede $r_x[k]$ sistem çıkışı $x[n]$ sinyalinin otokorelasyonudur. Verilen eşitlikte $E[w[n-l]x^*[n-k]]$ ifadesi sistemin çıkışı ve girişi arasındaki ilişkiyi göstermektedir ve çapraz korelasyon ifadesini vermektedir. $E[w[n-l]x^*[n-k]] = r_{vx}[k-l]$ olarak 2.3 numaralı denklemde yerine yazabiliriz. Bu durumda Eşitlik 2.3 aşağıdaki gibi yazılabilir.

$$r_x[k] + \sum_{l=1}^p a_p[l] r_x[k-l] = \sum_{l=0}^q b_q[l] r_{vx}[k-l] \quad 2.4$$

LZD sistem çıkışı konvolüsyon işlemi ile ifade edileceğinden;

$$x[n] = w[n] * h[n] = \sum_{m=-\infty}^{\infty} w[m]h[n-m] \text{ ve}$$

$$x^*[n-k] = w^*[n] * h^*[n-k] = \sum_{m=-\infty}^{\infty} w^*[m]h^*[n-k-m]$$

ile gösterilmektedir. Bu nedenle;

$$E[w[n-l]x^*[n-k]] = E[\sum_{m=-\infty}^{\infty} w[n-l]w^*[m]h^*[n-k-m]] \text{ ve}$$

$$E\left[\sum_{m=-\infty}^{\infty} w[n-l]w^*[m]h^*[n-k-m]\right] = \sum_{m=-\infty}^{\infty} E[w[n-l]w^*[m]]h^*[n-k-m]$$

şeklinde yazılırsa

$E[w[n-l]x^*[n-k]] = \sigma_w^2 h^*[l-k]$ ifadesi elde edilir. Bu durumda 2.4 numaralı denklem

$$r_x[k] + \sum_{l=1}^p a_p[l] r_x[k-l] = \sigma_w^2 \sum_{l=0}^q b_q[l] h^*[l-k] \quad 2.5$$

ifadesi ile de gösterilebilir.

$c_q(k) = \sum_{l=0}^q b_q[l] h^*[l-k] = \sigma_w^2 \sum_{l=0}^{q-k} b_q[l+k] h^*[l]$ ifadesini eşitlik 2.5 te yerine yazarsak;

$$r_x[k] + \sum_{l=1}^p a_p[l] r_x[k-l] = \begin{cases} \sigma_w^2 c_q(k); & 0 \leq k \leq q \\ 0; & k > q \end{cases} \quad 2.6$$

Yule Walker eşitliği elde edilir. Bu eşitliği matris formunda yazacak olursak, aşağıdaki denklem ile gösterilmektedir [92].

$$\begin{bmatrix} r_x[0] & r_x[-1] & \cdots & r_x[-p] \\ r_x[1] & r_x[0] & \cdots & r_x[-p+1] \\ \vdots & \vdots & \ddots & \vdots \\ r_x[q] & r_x[q-1] & \cdots & r_x[q-p] \\ \hline r_x[q+1] & r_x[q] & \cdots & r_x[q-p] \\ \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots \\ r_x[q+p] & r_x[q+p-1] & \cdots & r_x[q] \end{bmatrix} \begin{bmatrix} 1 \\ a_p[1] \\ a_p[2] \\ \vdots \\ \vdots \\ \vdots \\ a_p[p] \end{bmatrix} = \sigma_w^2 \begin{bmatrix} c_q[0] \\ c_q[1] \\ \vdots \\ c_q[q] \\ \cdots \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad 2.7$$

2.1.2. Özbâğımlı Modelleme

ÖB modelleme, ÖBHO modellemenin özel bir şeklidir. Bu modelde eşitlik 2.1 ile ifade edilen Sabit Katsayılı Lineer Fark denkleminde giriş gürültü sinyalinin geçmiş değerleri kullanılmaz ve sistem çıkışı giriş sinyalinin şu anki değerine ve çıkış sinyalinin geçmiş değerlerine bağlıdır.

ÖB(p) modeli;

$$x[n] = -\sum_{l=1}^p a_k[l]x[n-l] + b[0]w[n] \quad 2.8$$

fark denklemi ile gösterilmektedir.

Bu modelde ÖBHO modelinde olduğu gibi $w[n]$ sıfır ortalama ve σ_w^2 varyansa sahip beyaz gürültü sinyalidir. a_k , ÖB modele ait model parametresidir.

Eşitlik 2.8 ile gösterilen ÖB modele ait fark denkleminin Z dönüşümü alınırsa transfer fonksiyonu aşağıdaki eşitlikle gösterilmektedir [92].

$$H(z) = \frac{w[0]}{1 + \sum_{k=1}^p a_k z^{-k}} \quad 2.9$$

ÖB model parametrelerinin çözümü de, ÖBHO modellemeye olduğu gibi Yule Walker eşitliği ile gerçekleştirilebilmektedir. Eşitlik 2.6 ile verilen Yule Walker modelinde $q=0$ için $c_0(0) = b(0)h^*(0) = |b(0)|^2$ yazılırsa aşağıdaki eşitlik elde edilmektedir.

$$r_x[k] + \sum_{l=1}^p a_p[l] r_x[k-l] = \sigma_w^2 |b(0)|^2 \delta[k]; \quad k \geq 0 \quad 2.10$$

ÖB modelleme için elde edilen Yule Walker eşitliğini matris formunda yazacak olursak aşağıda yer alan eşitlik elde edilmektedir.

$$\begin{bmatrix} r_x[0] & r_x[-1] & \cdots & r_x[-p] \\ r_x[1] & r_x[0] & \cdots & r_x[-p+1] \\ \vdots & \vdots & \ddots & \vdots \\ r_x[p] & r_x[p-1] & \cdots & r_x[0] \end{bmatrix} \begin{bmatrix} 1 \\ a_p[1] \\ a_p[2] \\ \vdots \\ a_p[p] \end{bmatrix} = \sigma_w^2 |b(0)|^2 \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad 2.11$$

Bu eşitlik kullanılarak ÖB model parametreleri kolaylıkla elde edilebilmektedir. Örneğin ÖB(1) modelleme için gürültü sinyalinin varyansı $\sigma_w^2=1$ alınırsa;

$$r_x(0) + r_x(1)a(1) = b^2(0)$$

$$r_x(1) + r_x(0)a(1) = 0$$

$$\text{İfadeleri kullanarak } a(1) = -\frac{r_x(1)}{r_x(0)}$$

$$b^2(0) = r_x(0) + r_x(1)a(1) = \frac{r_x^2(0) - r_x^2(1)}{r_x(0)} \quad \text{eşitlikleri ile model parametreleri elde edilmektedir.}$$

2.2. Hidrolojik Verilerin Tahmini için Hibrit Yaklaşımlar

Hidrolojik verilerin tahmini için, son zamanlarda klasik yaklaşımlara alternatif olarak yapay zeka teknikleri kullanılmaktadır. Yapay zeka teknikleri arasında YSA oldukça yaygın olanıdır. Verilerin doğrudan YSA kullanarak tahmininin yanı sıra, literatürde son zamanlarda verilerin ön işlemlerden geçirilerek tahmini üzerine uygulamalar kullanılmaya başlanmıştır. Hidrolojik verilerin ön işlenmesi için genellikle verilerin frekans özelliklerine göre ayrıştırma işlemi gerçekleştiren Dalgacık Dönüşümü kullanılmıştır [70-74,77-80]. Gerçekleştirilen tez çalışmasında literatürdeki çalışmalara yenilik olarak hidrolojik verilerin ön işlenmesi aşamasında Ampirik Kip Ayrışımı (AKA) ve Tekil Spektrum Analizi (TSA) yöntemleri uygulanmıştır.

2.2.1 Hidrolojik Verilerin Ön İşlenmesi

Hidrolojik veriler doğası gereği lineer olmayan ve durağan olmayan yapıdadır. Bu verilerin zaman ekseninde analizi için uygun olarak kullanılabilecek yöntemlerin başında ampirik yaklaşımların kullanıldığı AKA yöntemi gelmektedir [81, 82, 93].

Sinyali zaman eksenini özelliklerine göre analiz eden, durağan/durağan olmayan ve lineer/lineer olmayan veriler için uygun bir analiz yöntemi olan diğer bir teknik de TSA tekniğidir. Bu teknik çok değişkenli analiz teknikleri arasında yer almaktadır. Verilerin parametrik olmayan bir model olması ve veri ile ilgili ön bilgi gerektirmemesi sebebiyle, AKA yöntemi gibi yaygın olarak kullanılmaya başlanmıştır [87- 91, 94,95].

Gerçekleştirilen tez çalışmasında hidrolojik verilerin ön işlenmesi aşamasında AKA ve TSA yöntemleri kullanılmıştır.

2.2.1.1. Ampirik Kip Ayrışım (AKA) Yöntemi

Sezgisel, doğrudan, adaptif ve girdiden türetilen- girdiye dayalı bir çözüm metodu olması sebebiyle son bilgi (posteriori) tanımlı bir yapıya sahip olan, ilk olarak Huang tarafından ortaya konulan AKA yöntemi lineer olmayan ve durağan olmayan süreçlerin analizinde oldukça önemlidir [81,82]. AKA yöntemi, sinyaldeki salınımların basit, farklı, esas modlarını (İçsel Mod Fonksiyon, IMF) içeren herhangi bir veri ile gösterimine dayanmaktadır. Böylece herhangi bir sinyali IMF'lerin toplamı olarak ifade edebilmekteyiz. Bu sayede veri tahmini daha kolay hale gelmektedir.

Her bir IMF lineer ya da lineer olmayan eşit sayıda ekstremi ve sıfır geçişi bulunan basit bir salınım sinyali ile gösterilir ve bu sinyal yerel ortalamaya göre simetriktir. Herhangi bir andaki verinin birbirini takip eden pek çok değişik salınım modları bir arada bulunur ve sonuçta veri nihai halini alır. Böylece bu yöntemle temel olarak bir zaman serisi, IMF olarak isimlendirilen salınım fonksiyonlarına ayrılmaktadır. Bu sinyallerin her biri, aşağıda temel iki özelliği tanımlanan IMF lerce temsil edilir.

1. Tüm veri dizisinde ekstrem ve sıfır geçişlerin sayısı ya eşit, ya da en fazla bir farklıdır.
2. Herhangi bir noktada, yerel maksimumlarla tanımlanan zarflar ile yerel minimumlarla tanımlanan zarfların ortalaması sıfır olmalıdır [81, 82].

IMF fonksiyonlarının taşıdığı ilk durum durağan Gauss süreci (normal dağılıma sahip rastgele değişken değerlerin oluşturduğu süreç) için geleneksel dar bant (oluşma sıklığının belirli aralıkta olması) gereksinimlerine benzemekle birlikte 2. Durum, anlık frekansın hesaplanmasında asimetrik dalga formlarının sebep olduğu istenmeyen dalgalardan etkisini ortadan kaldırmaktadır.

IMF; basit bir harmonik fonksiyonun karşılığı olarak sinyaldeki basit bir salınım modunu temsil etmekle birlikte basit harmonik bileşen içinde sabit bir genlik ve frekans yerine, zamanın fonksiyonu olan değişken genlik ve frekanslara sahiptir. AKA yönteminin detaylı algoritması aşağıda verilmiştir.

Adım 1:

- Deneysel data $x(t)$ 'nin yerel ekstremeleri belirlenir
- Tüm yerel maksimum ve minimumları ($U(t)$ ve $L(t)$ olarak isimlendirilen eğriler) interpolasyon yöntemleri kullanılarak birleştirilir ve sinyale ait alt ve üst zarf eğrilerini oluşturulur.
- Bu iki çizgi arasında bir $m1(t)$ ortalama eğrisi çizdirilir ve aşağıdaki gibi hesaplanır.

$$m1(t) = [U(t) + L(t)]/2$$

- Mevcut data $x(t)$ 'den elde edilen ortalama serisi $m1(t)$ çıkarılarak $h1(t)$ verisi elde edilir.

$$h1(t) = x(t) - m1(t)$$

Eğer $h1(t)$ grafiği simetrik, tüm maksimumları pozitif, tüm minimumları negatif ise yani yukarıda bahsettiğimiz IMF olma kriterlerini sağlıyorsa bir IMF dir. Aksi takdirde söz konusu veri ($h1(t)$) üzerinde IMF i elde edebilmek için eleme süreci devam eder.

- Eleme süreci yukarıdaki prosedürün tekrarıdır.

$$m_{11}(t) = [U_{11}(t) + L_{11}(t)]/2$$

$$h_{11}(t) = h_1(t) - m_{11}(t)$$

.....

.....

$$h_{1k}(t) = h_1(k-1)(t) - m_{1k}(t)$$

Adım 2:

- $h_{1k}(t)$ bir IMF ise $c_1(t) = h_{1k}(t)$ olarak kabul edilir ve birinci bileşen olarak belirlenir.
- Bu sefer deneysel data $x(t)$ 'den $c_1(t)$ çıkarılarak $r_1(t) = x(t) - c_1(t)$ kalıntı datası elde edilir.
- Artık yeni veri $r_1(t)$ dir ve 1. adımda uygulanan eleme süreci i nci data elde edilene kadar dataya aynen uygulanır.
 $r_i(t) = r_{i1}(t) - c_i(t)$
- Sonuncu $c_i(t)$ yi elde ettikten sonra kalan $r_i(t)$; bir sabit veya $x(t)$ 'nin ortalama trendini veren, salınımına sahip olmayan monoton bir fonksiyondur.
- $c_1(t), c_2(t), \dots, c_i(t)$ lerden oluşan IMF ler en yüksekinden düşüğüne kadar değişen frekans bantlarını kapsar. Her bir IMF in frekans bileşenleri farklıdır ve $r_i(t)$; $x(t)$ 'nin genel eğilimini temsil etmektedir, bu frekans bileşenleri $x(t)$ 'nin değişmesi (varyasyonu) ile değişir [81,82].

AKA işlemi sonucunda herhangi bir zaman seri sinyali aşağıdaki gibi ifade edilebilmektedir.

$$x(t) = \sum_{i=1}^k IMF_i + r(t) \quad 2.12$$

Bu ifadede $x(t)$; zaman sinyalini, $r(t)$; artık sinyali, yani salınım bileşeni olmayan sinyali ve IMF_i ise zaman sinyaline ait salınım bileşenlerini içeren altbant bileşenlerini göstermektedir.

Gerçekleştirilen tez çalışmasında; tahmin için kullanılacak hidrolojik eğitim ve test verileri en iyi tahmin başarısını elde etmek üzere, deneysel olarak farklı sayıda altbantlara ayrıştırılmıştır. Verilerdeki son değerlerin maksimum veya minimum değer olarak atanmamasına dikkat edilmiştir. Bunun nedeni ise eğer verideki son değerleri maksimum veya minimum değer olarak belirlenirse, tahmin çalışmaları için AKA yönteminin sınır etkisi olarak isimlendirilen bir kısıtlaması ortaya çıkmaktadır ve modeli geleceğe bağımlı hale getirmektedir [92]. Bunu önlemek açısından eğitim verilerindeki IMF leri belirlerken, verilerdeki son değerler ekstremum noktaları dışında tutulmuştur [92].

2.2.1.2. Tekil Spektrum Analiz (TSA) Yöntemi

TSA yöntemi klasik zaman serileri analizi, çok değişkenli istatistiksel analiz, dinamik sistemler ve işaret işleme gibi pek çok tekniğin içinde bulunduğu yeni geliştirilen güçlü bir algoritmadır [94,95]. TSA, pek çok bilimde kullanılan matematiksel yöntemlerde, finansal matematik, fizik, sosyal bilimlerde market araştırmasında ve biyomedikal uygulamalarda olmak üzere olası pek çok uygulama alanı bulunmaktadır. Bu teknik; sinyaldeki farklı çözünürlüklerin eğilimini bulmada, düzgünleştirme işleminde, dönemsel bileşenlerin analizinde, dönemsel periyotların belirlenmesi ve analizinde, değişen genlikli periyodikliğin elde edilmesinde, kompleks eğilim ve periyodikliğin ardışık olarak elde edilmesinde, kısa süreli zaman serilerinin yapısının çıkarılmasında, değişen noktaların bulunması problemlerinin çözümünde ayrıca bir veri içerisindeki örüntüyü belirleyerek birbiri ile ilişkili olan veya olmayan bileşenlerin belirlenmesinde, boyut azaltma işlemlerinde oldukça faydalı bir araçtır.

TSA, belirli bir parametreye bağlı değildir ve analizde ön koşul gerektirmeyen bir yöntemdir.

Bu algoritma aşağıda verildiği gibi dört adımdan oluşmaktadır.

- 1- Zaman serisi sinyalinin küçük aralıklara gömülmesi işlemi,
- 2- Tek değerli ayrıştırma ile öz üçlünün eldesi,
- 3- Gruplandırma,
- 4- Diyagonal ortalama.

Bu adımlardan sinyallerin zaman aralıklarına gömülmesi ve tek değerli ayrıştırma işlemleri algoritmanın *ayrıştırma* aşamasını oluşturmaktadır. Gruplandırma ve diyagonal ortalama işlemleri ise algoritmanın *yeniden yapılandırma* aşamasını oluşturmaktadır.

Ayrıştırma ve yeniden yapılandırma aşamaları aşağıda ayrıntılı olarak anlatılmaktadır.

i. Ayırıştırma Aşaması

i.1. Gömme İşlemi

Bu işlemde, zaman serisi sinyali bir yörünge matrisi olarak ifade edilen bir matris haline dönüştürülmektedir. Bunun için zaman eksenindeki sinyale gömme işlemi uygulanmaktadır. $X = \{x_1, \dots, x_N\}$ olarak ifade edilen sinyali görebilmek için, öncelikle L pencere uzunluğu belirlenir. Pencere uzunluğu genellikle sinyalin uzunluğunun yarısından daha az seçilmelidir ($2 < L < N/2$), ancak periyodik sinyallerde bir periyod değerinde veya bunun tamsayı katlarında pencere uzunluğu olarak belirlenebilmektedir [94,95].

Gömme işlemi neticesinde zaman eksenindeki sinyali K adet L boyutlu geciktirilmiş vektöre dönüştür.

$$X_i = \{x_i, \dots, x_{i+L-1}\} \quad i=1, \dots, K \text{ ve } K=N-L+1$$

K adet L uzunluklu geciktirilmiş vektörler kullanılarak elde edilen Yörünge matrisi (T_X), $L \times K$ boyutundadır ve çapraz köşegen elemanları $T_{i,j+1} = T_{i+1,j}$ şeklindedir. Böylece T_X matrisi Eşitlik 2.13. teki gibi yazılabilmektedir.

$$T_X = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_K \end{pmatrix} = \begin{pmatrix} x_1 & x_2 & \dots & x_L \\ x_2 & x_3 & \dots & x_{L+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_K & x_{K+1} & \dots & x_N \end{pmatrix} \quad 2.13$$

i.2. Tek Değerli Ayırıştırma İşlemi

Tek değerli ayırıştırma işlemi bir matris ayırıştırma tekniği olup, bu işlem T_X yörünge matrisine uygulanmaktadır.

$K \times L$ boyutundaki T_X matrisi tek değerli ayrıştırma işlemi ile; $T_X = USV^T$ yani özdeğer üçlüsü matrislere ayrıştırılmaktadır ve her biri; gömme işlemi sonunda elde ettiğimiz T_X matrislerinin transpozesi ile çarpımı sonuçlarından ($T_X T_X^T$ ve $T_X^T T_X$) elde edilmektedir. Burada; U , $K \times K$ boyutunda ortonormal karesel birim matris olup, $T_X T_X^T$ matrisinin özvektörlerinden elde edilmektedir. S , $K \times L$ boyutunda diyagonal bir matris olup, diyagonal elemanlar $T_X T_X^T$ matrisinden elde edilen özdeğerlerin genlik

karekökünden oluşmaktadır. V ise $L \times L$ boyutunda bir ortonormal karesel birim matris olup, $T_x^T T_x$ matrisinin özvektörlerinden oluşmaktadır.

Bu adımda T_x matrisi $S_1 > S_2 > \dots > S_L$ şeklinde pek çok L adedince tekli değere sahiptir. Böylece i inci öz üçlüsü $U_i x S_i x V_i^T$ olarak yazılabilmektedir. Sonuç olarak T_x yörünge matrisi

$$T_x = T_1 + T_2 + T_3 + \dots + T_d \quad i=1, \dots, d \quad (d=K)$$

$$T_x = U_1 x S_1 x V_1^T + \dots + U_d x S_d x V_d^T$$

$$T_x = \sum_{i=1}^d U_i x S_i x V_i^T$$

Burada d değeri T_x matrisinin rank değeridir. Zaman serileri için d değeri K ya eşittir. Her bir T_i matrisinin T_x matrisine katkısı $S_i / \sum_{i=1}^d S_i$ olarak hesaplanabilmektedir.

ii. Yeniden Yapılandırma Adımı

ii.1. Gruplama İşlemi

Algoritmanın üçüncü adımı olan gruplandırma işleminde $\{i = 1, \dots, d\}$ indise sahip bölümler $I = \{I_1, \dots, I_m\}$ şeklinde gruplandırılır ve T_x matrisi aşağıdaki gibi elde edilir.

$$T_x = \frac{\overbrace{T_1 + \dots + T_d}^{\text{Tek değerli ayrıştırma}}}{\overbrace{T_{I1} + \dots + T_{Im}}^{\text{Gruplandırma}}}$$

Bu adımda T_x matrisinden elde edilen yeni T_i matrisi, sinyaldeki eğilimi bulmayı, mevsimsel bileşenleri, aylık bileşenleri bulmayı ve beyaz gürültülerine göre sınıflandırma işlemlerini sağlamaktadır. TSA aracılığı ile sinyalden T_i matrisini elde etmek için T_x matrisi içinde elementer işlemler gerçekleştirilmektedir.

Tüm ayrıştırma işlemleri kesinleşmiş bir pencere uzunluğu (L) ile tamamlandıktan sonra, yörünge matrisinden Tek Değerli Ayrışım (TDA) kullanılarak elde edilen matris (TDA uygulandıktan sonra elde edilen matrisler); başlangıçtaki zaman serisinin düzenli bölünmüş alt serilerini elde etmek için gruplandırılır.

Bunun için; TDA sonucu özdeğer üçlülere ve T_i verileri elde edilmektedir ($i = 1, \dots, d$). TDA uygulandıktan sonra elde edilen tekli değerler (S_i) çizdirildiğinde; eğilimi, mevsimsel bileşenleri, aylık bileşenleri ve beyaz gürültüleri yani sinyal içerisindeki deseni açığa çıkararak, gruplar kendini göstermektedir. Özdeğerlerin temsil oranına göre belirlenen özdeğer sayısı kadar yeniden gruplandırma işlemi gerçekleştirilir.

ii.2. Diyagonal Ortalama

Diyagonal ortalama işleminde, gruplandırılmış matrisleri (T_{Im}) orijinal veri uzunluğu olan N uzunluğundaki yeni bir zaman serisine dönüştürülmektedir. T_{Im} matrisinin karşılık gelen köşegenlerinin ortalanması (hankelizasyon) ile yeni zaman serisi $\tilde{T}(i)$ elde edilmektedir. Bu aşamada gerçekleştirilen Hankelizasyon işlemi diyagonal ortalama dönüşümünü gerçekleştirmektedir. Zaman serisine dönüştürmek istediğimiz herhangi bir matrisin örneğin A matrisinin A_{ij} elemanlarından $i+j=\text{sabit}$ olan elemanların ortalaması, bize zaman serisine dönüştürdüğümüz serinin k ıncı elemanını, $i+j=k+2$ şartıyla, vermektedir. Bu sürece A matrisinin Hankelizasyonu denmektedir. Bu işlem sonunda yenilenmiş altbant zaman seri bileşenleri (RC-Rekonstrüktif Bileşenler) elde edilir [94, 95].

Tez çalışmasında kullanılan hidrolojik veriler doğası gereği periyodik yapıya benzerlik gösterdiği için gömme işleminde pencere uzunluğu 12 olarak belirlenmiştir.

2.2.2. Hidrolojik Verilerin Tahmini için Yapay Sinir Ağları

Son zamanlarda YSA, nonlineer yapılara uygun olması, paralel ve seri işlem yapabilme kabiliyeti, adaptif yapıda olması gibi avantajları sayesinde hidrolojik verilerin tahmininde yaygın olarak kullanılmaktadır.

En genel anlamda bir YSA, insan beynindeki birçok nöronun (sinir hücresinin), ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistemdir. YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Bu nedenle, YSA'nın

programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilim dalı olduğu söylenebilir.

YSA insanlar tarafından gerçekleştirilmiş örnekleri (gerçek beyin fonksiyonlarının ürünü olan örnekleri) kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde; öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme, optimizasyon, tahmin gibi konularda başarılı bir şekilde uygulanmaktadır. YSA, örneklerden elde edilen bilgileri kullanarak kendi deneyimlerini oluşturur ve benzer konularda benzer kararlar veren sonuçlar üretir. YSA günümüzde pek çok probleme çözüm üretebilecek yeteneğe sahiptir. YSA birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır. Proses elemanları olarak isim verilen bu hücrelerin birbirlerine bağlandıkları ve her bir bağlantının bir ağırlık değerinin olduğu kabul edilmektedir. Proses elemanlarının birbirine bağlanmaları sonucu oluşan ağa YSA denmektedir. Bu ağın oluşturulması insan vücudundaki biyolojik sinir sistemi göz önünde bulundurularak gerçekleştirilmektedir.

YSA temel olarak kendisine uygulanan bir girdi bilgisine karşılık gelecek bir çıktı bilgisi oluşturan bir sistemdir. Böyle bir sistemin gerçekleştirilmesi için ilgili olayın örnekleri ile eğitilerek (öğrenme) genelleme yapabilecek kabiliyete kavuşturulması gerekmektedir. Bu genelleme sayesinde YSA benzer olaylara karşılık gelen çıktı bilgisini üretmektedir.

Ağı oluşturan proses elemanları, bunların bilgileri işleme yetenekleri, birbirleri ile bağlantıları değişik YSA yapılarını oluşturmaktadır [96-98].

2.2.2.1 Yapay Sinir Ağlarının Genel Özellikleri

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Ancak ortak olarak aşağıda verilen özellikleri taşımaktadır.

- i. ***YSA makine öğrenmesi gerçekleştirmektedir.*** YSA'nın temel işlevi bilgisayarın öğrenmesini sağlamaktadır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışır.

- ii. ***YSA programları geleneksel programlama yöntemlerine benzememektedir.*** Geleneksel programlama ve yapay zeka yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi kullanılmaktadır.
- iii. ***Bilginin saklanması geleneksel programlardan farklıdır.*** YSA’nda bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi, veriler bir veri tabanında veya programın içinde gömülü olmayıp bilgiler ağın üzerinde saklıdır. Bu nedenle bilgilerin ortaya çıkarılması ve yorumlanması zordur.
- iv. ***YSA örnekleri kullanarak öğrenmektedir.*** YSA’nın adaptif öğrenme yeteneği sayesinde olay ile ilgili belirlenen örnekler kullanılarak olay hakkında genelleme yapabilmektedir. Eğer olaylar ile ilgili örnekler (eğitim verisi) bulunmuyorsa YSA’nın eğitilmesi mümkün değildir.
- v. ***YSA’nın güvenle çalışabilmesi için öncelikle eğitilmesi ve daha sonra performanslarının test edilmesi gerekmektedir.*** YSA’nın eğitilmesi; mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir.
- vi. ***Gömülmemiş örnekler hakkında bilgi üretebilir.*** Ağ kendine gösterilen örneklerden genellemeler yaparak eğitim aşamasında kendisine gösterilmeyen örnekler hakkında genelleme yapabilmektedir.
- vii. ***Algılamaya yönelik olaylarda kullanılabilir.*** Ağlar daha çok algılamaya yönelik bilgilerde kullanılmaktadır.
- viii. ***Şekil (Örüntü) ilişkilendirme, sınıflandırma, modelleme ve tamamlama (tahmin) yapabilir.***
- ix. ***Kendi kendini organize etme ve öğrenebilme yetenekleri bulunmaktadır.***
- x. ***Eksik bilgi ile çalışabilirler.*** YSA kendileri eğitildikten sonra eksik bilgi ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilme yeteneğine sahiptir.

- xi. ***Hata toleransına sahiptir.*** YSA'nın eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam edebilir.
- xii. ***Belirsiz tam olmayan bilgileri işleyebilmektedir.*** YSA'nın belirsiz bilgileri işleyebilme yetenekleri bulunmaktadır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar hakkında ilişki kurarak çıkarım yapabilmektedir
- xiii. ***Dereceli Bozulma gösterirler.*** YSA'nın hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına neden olmaktadır. Bir ağ zaman içerisinde yavaş yavaş bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar herhangi bir problem ortaya çıktığında anında bozulmaz.
- xiv. ***Dağıtık belleğe sahiptir.*** YSA'nda bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini göstermektedir. Tek bir bağlantının anlamı bulunmamaktadır.
- xv. ***Sadece nümerik bilgiler ile çalışmaktadır.*** YSA sadece nümerik bilgiler ile çalışmaktadır. Sembolik ifadeler ile gösterilen bilgilerin nümerik ifadelere çevrilmesi gerekmektedir [96].

YSA, bilgi sınıflandırma ve yorumlamanın da içerisinde bulunduğu çok değişik problemlerin çözümünde kullanılmaktadır. Başlıca uygulama alanlarını sınıflandırma, tahmin ve modelleme olarak ele alacak olursak, yukarıda anlatılan özellikler YSA'nın üstünlüklerini ortaya koymaktadır. YSA'nın başlıca dezavantajı çalışmasının analiz edilememesi ve öğrenme işleminde başarılı olunamama riski olmasıdır [96,97].

YSA'nın başlıca üstünlükleri;

aşağıdaki gibi sıralanabilir.

Matematiksel modele ihtiyaç duymazlar.

Kural tabanı kullanımı gerektirmezler.

Öğrenme kabiliyeti vardır ve farklı öğrenme algoritmaları ile öğrenebilir.

YSA'nın sakıncaları;

aşağıdaki gibi sıralanabilir.

Sistem içerisinde ne olduğu bilinemez.

Bazı ağlar hariç kararlılık analizi yapılamaz.

Farklı sistemlere uyarlanması zor olabilir.

Fazla eğitim ezberleme ile sonuçlanır ve yanlış çıktı verebilir.

Ağ yapısı uygun seçilemeyebilir.

2.2.2.2 Yapay Sinir Ağlarının Tarihçesi

İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanmaktadır. Modern elektroniğin gelişmesi ile birlikte bu düşünce işlemini kullanmaya çalışmak doğal bir hale gelmiştir. İlk YSA modeli 1943 yılında bir sinir hekimi olan Warren McCulloch ile matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts insan beyninin hesaplama yeteneğinden esinlenerek elektrik devreleriyle basit bir sinir ağı modellemiştir. 1948 yılında Wiener “Cybernetics” isimli kitabında sinirlerin çalışması ve davranış özelliklerine değindi. 1949 yılında ise Hebb “Organization of Behavior” isimli kitabında öğrenme ile ilgili temel teoriyi ele almıştır [97]. Hebb kitabında öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel oluşturacak Hebb Kuralı’nı ortaya koymuştur. Hebb Kuralı sinir ağının bağlantı sayısı değiştirilebilirse öğrenebileceğini öngörmektedir. 1950 li yıllarda sonra pek çok araştırmacı Hebb Kuralından esinlenerek YSA’nın hesaplama gücünü artırıcı yönde çalışmalar yapmıştır. 1957 yılında Frank Rosenblatt’ın Perceptron’u gerçekleştirmesinden sonra, YSA alanındaki gelişmeler hızlanmıştır. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip olan yapay sinir ağıdır. 1959 yılında, Stanford Üniversitesinde Bernard Widrow ve Marcian Hoff ADALINE ve MADALINE diye adlandırılan ağ modellerini geliştirmişlerdir. MADALINE, telefon hatlarında oluşan yankıları yok eden bir uyarlanabilir süzgeç olarak kullanılmış ve gerçek dünya sorunlarına uygulanmış olan ilk

sinir ağıdır. 1969 yılında Minsky ve Papert Perceptron'un yetersizliğini görmüşler ve XOR problemini çözemediğini ispat etmişlerdir. Bunun için ileri beslemeli iki katmanlı ağların kullanılabileceğini öne sürmüşlerdir. 1982 yılında Hopfield ağların önemli sınıflarının temelini atmıştır. Hopfield'ın modeli beyne benzeyen basit bir model değil, kullanışlı bir alet olarak ortaya çıkmıştır. 1984 yılında, Kohonen, sinirlerin düzenli sıralanışına eşleme özelliği için danışmansız öğrenme ağlarını geliştirmiştir. 1987 yılında Elektrik Elektronik Mühendisliği Enstitüsü tarafından sinir ağlarını konu alan ilk uluslararası konferansı 1800'ü aşkın katılımcıyla gerçekleştirmiştir [96,97].

YSA biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Biyolojik sinir sistemi birbiri ile iletişim halinde olan sinir hücrelerinden oluşmaktadır. Bir biyolojik sinir ağı insan beyninin çalışmasını sağlayan en temel taşlardan birisidir ve milyarlarca sinir hücresinin biraraya gelmesi ile oluşmaktadır. Sinir hücreleri birbiri ile bağlanarak fonksiyonunu yerine getirir. Duyu organlarımızdan gelen bilgiler beyin sinir sistemimiz sayesinde beyne taşınır ve beynin oluşturduğu kararlar da yine sinir sistemi sayesinde vücudun ilgili organlarına eylem olarak iletilir. Bir sinir hücresi aşağıdaki şekilde yer almaktadır. Şekilde 2.2.1 de görüldüğü gibi bir sinir hücresi sinaps, hücre gövdesi, dendrite ve aksondan oluşmaktadır.



Şekil 2.2.1. Bir biyolojik sinir hücresinin yapısı [99]


Sinapsler sinir hücreleri arasındaki bağlantılar olarak görülebilir. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine geçmeyi sağlayan elektriksel boşluklardır. Hücre gövdesine gelen sinyaller işleme tabi tutularak elektriksel sinyale çevrilir ve aksonlar aracılığı ile dendrite gönderilir. Dendriteler ise bu sinyalleri sinapslara göndererek başka hücrelere gönderir. Verilen özellikte milyarlarca sinir hücresi bir araya gelerek sinir sistemini oluşturmaktadır. YSA biyolojik hücrelerin bu özelliklerinden faydalanılarak geliştirilmiştir [96]

YSA temel olarak, basit yapıda ve yönlü bir graf biçimindedir. Her bir düğüm, hücre denilen n . dereceden lineer olmayan bir devredir. Düğümler işlem elemanı olarak tanımlanır. Düğümler arasında bağlantılar vardır. Her bağlantı tek yönlü işaret iletim yolu (gecikmesiz) olarak görev yapar. Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir.

YSA paralel dağılmış bir bilgi işleme sistemidir. Yani, YSA'nın temelinde, zeka gerektiren işlemlerden oluşan bilgi işleme işlevi vardır. Bu sistem tek yönlü işaret kanalları ile birbirine bağlanan işlem elemanlarından oluşur ve katmanlar şeklinde düzenlenir.

2.2.2.3. Yapay Sinir Hücresi

Biyolojik sinir ağlarında sinir hücreleri olduğu gibi YSA'nda yapay sinir hücreleri bulunmaktadır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak adlandırılmaktadır. Şekil 2.2.2 de yapay bir sinir (proses elemanı) bulunmaktadır [96-98].



Şekil 2.2.2. Yapay Sinir Hücresinin Yapısı


Girişler: Girişler ($x_1, x_2, \dots, x_n$) çevreden aldığı bilgiyi sinire iletir. Girişler kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir.

Ağırlıklar: Ağırlıklar ($w_1, w_2, \dots, w_i$) YSA tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bir ağırlığın değerinin büyük olması, o girişin yapay sinirine güçlü bağlanması ya da

önemli olması, küçük olması ise, zayıf bağlanması ya da önemli olmaması anlamına gelmektedir.

Toplama Fonksiyonu: Toplama işlevi (v_i) sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamalarını bir θ_j eşik değeri ile toplayarak aktivasyon fonksiyonuna göndermektedir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Bu çalışmalarda bazı formüllerde basit bir toplama işlemi yerine minimum, maksimum veya birkaç normalleştirme algoritmaları kullanılarak daha karmaşık hale getirilmiştir.

Aktivasyon Fonksiyonu: Toplama fonksiyonunun sonucu, aktivasyon fonksiyonundan $F(NET)$ geçirilerek sonuca iletilmektedir. Bu fonksiyon hücreye gelen net girdiyi belirleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplam fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Bazı modeller bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağırlık proses elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Günümüzde en çok kullanılan ve tez çalışmasında da kullanılan Çok Katmanlı Algılayıcı modelinde genellikle, aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyon; $F(NET) = \frac{1}{1+e^{-NET}}$ formülü ile gösterilmektedir. Aşağıdaki Şekilde Sigmoid fonksiyonunun grafiği yer almaktadır.



Şekil 2.2.3. Sigmoid fonksiyonun grafiği

Çıkış: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye (proses) gönderilir.

2.2.2.4. Yapay Sinir Ağının Yapısı


Yapay sinir hücreleri bir araya gelerek YSA'nı oluşturmaktadır. Sinir hücreleri rastgele bir şekilde bir araya gelmez. Genel olarak hücreler üç katman halinde ve her katmanda paralel olarak bir araya gelerek ağı oluştururlar. Bu katmanlar Girdi katmanı, Ara katman ve Çıktı katmanı olmak üzere üç katmandır.

Girdi Katmanı: Bu katmanda proses elemanı dış dünyadan gelen bilgileri alarak ara katmana transfer etmekle sorumludur. Bazı ağlarda girdi katmanında herhangi bilgi işleme olmaz.

Ara (Gizli) Katmanlar: Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderirler. Bu bilgilerin işlenmesi ara katmanda meydana gelir. Bir ağ içerisinde birden fazla ara katman olabilmektedir.

Çıktı Katmanı: Bu katmandaki proses elemanı ara katmandan gelen bilgileri işleyerek ağın girdi katmanından gelen bilgiler için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.

Bu üç katmanın her birinde bulunan proses elemanları ve katmanlar arası ilişkiler şematik olarak Şekil 2.2.4 te gösterilmektedir [96-98].



Şekil 2.2.4. Bir YSA Örneği (Çok Katmanlı YSA)

2.2.2.5. Yapay Sinir Ağlarında Öğrenme

YSA'nda proses elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Başlangıçta bu ağırlık değerleri rastgele atanır. YSA kendisine

örnekler uygulandıkça, bu ağırlık değerini değiştirmektedir. Burada amaç, ağa uygulanan örnekler için doğru çıktıları üretecek ağırlık değerlerinin bulunmasıdır. Ağın doğru ağırlık değerine ulaşması, örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine “**ağın öğrenmesi**” denmektedir. Ağırlıkların değişmesi belirli kurallara göre olmaktadır. Buna “**öğrenme kuralı**” denmektedir. Literatürde kullanılan öğrenme stratejisine göre farklı öğrenme kuralları bulunmaktadır. YSA’nda öğrenme olayının iki aşaması bulunmaktadır. Birinci aşamada ağa uygulanan örnek için ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir. Ağın çıktısının belirlenmesi ve ağırlıklarının değiştirilmesi öğrenme kuralına bağlı olarak farklı şekillerde olmaktadır. Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise ağın test edilmesi denmektedir. Test etmek için ağın öğrenme sırasında görmediği örnekler kullanılmaktadır. Test sırasında ağın ağırlık değerleri değiştirilmez. Test örnekleri ağa uygulanır ve ağ eğitim sırasında kullanılan bağlantı ağırlıklarını kullanarak çıkışlar üretir. Elde edilen çıkışların doğruluk değerleri ağın öğrenmesi hakkında bilgi vermektedir. Eğitimde kullanılan örnek verilere “**eğitim seti**”, testte kullanılan örnek verilere “**test seti**” adı verilmektedir. YSA’nın bu şekilde bilinen örneklerden belirli bilgileri çıkartarak bilinmeyen örnekler hakkında yorumlar yapabilme (genelleme yapabilme) yeteneğine “**Adaptif Öğrenme**” denmektedir.

Bir YSA’nda proses elemanlarının bağlanması sonucu oluşan topoloji, proses elemanlarının sahip oldukları toplama ve aktivasyon fonksiyonları, öğrenme stratejisi ve kullanılan öğrenme kuralı ağın modelini belirlemektedir. Günümüzde YSA için pek çok model geliştirilmiştir. Bunlardan en yaygın olarak kullanılanları ve pratik olarak uygulananları aşağıda yer almaktadır.

- Algılayıcılar (Tek Katmanlı Algılayıcılar)
- Çok Katmanlı Algılayıcılar (Hatayı geriye yayma modelleri)
- Vektör Kuantizasyon Modelleri (VKM)
- Kendi kendini organize eden model (KOM)
- Adaptif Rezonans Teorisi modelleri (ART)
- Hopfield Ağları
- Counterpropagation ağı

- Neocognitron ağı
- Boltzman makinesi
- Probabilistik Ağlar (PSA)
- Elman Ağı
- Radyal Temelli Ağlar (RBSA)

Tez çalışmasında tahmin çalışmalarında yaygın olarak kullanılan Çok Katmanlı Algılayıcılar kullanılmıştır.

2.2.2.6. Çok Katmanlı Yapay Sinir Ağları

YSA'nın en fazla kullanılan modeli Çok Katmanlı Algılayıcı YSA (ÇKAYSA, Multilayer Perceptron- MLP) modelidir. Bir ÇKAYSA modeli her bir katmanda en az bir nöron bulunacak şekilde giriş; bir veya daha fazla gizli katman ve çıkış katmanından oluşur.

Ara katmanı olmayan sadece giriş ve çıkış katmanı olan ağlar karmaşık işlemleri hesaplama yeteneğine sahip değildir. Bu nedenle karmaşık hesaplamalar için oluşturulan ağlarda en az bir ara katman olmalıdır. Şekil 2.2.3'te giriş, ara katman ve çıkış katmanı olmak üzere ÇKAYSA görülmektedir. Bu yapılarda bir katmandaki her sinir bir sonraki katmanın bütün sinirlerine bağlıdır. Aynı katmandaki sinirler arasında veya geri besleme şeklinde bağlantıları bulunmamakta olup, “İleri beslemeli” YSA'dır. Giriş katmanından alınan giriş verileri giriş katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılarak gizli katmana iletilmektedir. Gizli katmandaki sinirlere gelen girişler toplanarak aynı şekilde gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıkış katmanına iletilmektedir. Çıkış katmanındaki sinirlerde kendisine gelen bu girişleri toplayarak buna uygun çıkış üretilmektedir. Burada giriş katmanından çıkış katmanına doğru gizli katmanlar üzerinden tek yönlü bir işlem mevcuttur.

2.2.2.6.1. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Kuralı

YSA'nda farklı öğrenme algoritmaları kullanılarak ağı eğitilmesi sağlanır. Kullanılan eğitim algoritmasına göre ağı çıkışı ile istenen çıkış arasındaki hata minimuma düşünceye kadar ağı ağırlıkları değiştirilir.

Çok katmanlı YSA danışmanlı öğrenme stratejisine göre çalışmaktadır. Yani bu ağlara eğitim sırasında hem girdiler, hem de girdilere karşılık üretilmesi gereken (beklenen) çıktılar uygulanmaktadır. Ağın görevi, her girdi için o girdiye karşılık çıktı üretmektir. ÇKAYSA'nın öğrenmesi iki aşamada gerçekleşmektedir. Birinci safha; **ileri doğru hesaplama** safhasıdır. Bu safhada ağın çıktısı hesaplanır. İkinci safha ise; **geriye doğru hesaplama** safhasıdır. Bu safhada istenilen çıktı ve ağın çıktısı arasındaki farka yani hataya göre ağırlıklar yeniden hesaplanır. Çok katmanlı YSA'nın öğrenme kuralı bu şekilde geriye yayılarak gerçekleştirildiği için **“geri yayılımlı”** öğrenme kuralına sahiptir. Geri Yayılımlı YSA, eğimi en dik inişli eğitim algoritması kullanmaktadır. Eğimi inişli algoritmalar için, adım büyüklüğü (öğrenme oranı) öncelikle belirlenmelidir. Adımı büyük olanlar ağ salınımına ve yakınsamadaki tutarsızlığa sebep olurken, daha küçük olanlar yakınsamadan önce öğrenme sürecini yavaşlatmaya başlar. Bu da öğrenme oranı küçük olanların önemini artırmaktadır.

ÇKAYSA için yaygın olarak kullanılan öğrenme algoritmaları aşağıda yer almaktadır [96, 97].

1. Gradient descent algoritması
2. Gauss Newton's method algoritması
3. Conjugate gradient algoritması
4. Quasi-Newton method algoritması
5. Levenberg-Marquardt algoritması

Tez çalışmasında, hidrolojik verilerin tahmini için kullanılan YSA'nda hız avantajına sahip olan Levenberg Marquardt (LM) öğrenme algoritması kullanılmıştır. .

2.2.2.6.2. Levenberg Marquardt Algoritması

LM algoritması Hessian matrisi kullanımına gerek kalmadan ikinci dereceden eğitim hızına yaklaşan maksimum komşuluk üzerine kurulu en küçük kareler hesabına dayalı Quasi Newton yöntemine benzer bir yöntemdir. LM algoritması, Gauss-Newton ve Gradient-descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını ortadan kaldırmaktadır. Hessian matrisi; $H = J^T J$ ile gösterilmektedir ve gradyent; $g = J^T e$ ile ifade edilmektedir. Burada J YSA'nın ağırlıklarına karşı

hatalarını içeren Jacobian matrisidir ve e ise hata vektörüdür. Jacobian matrisi standart geri yayılım teknikleri ile hesaplanmaktadır ve Hessian matrisi hesabına göre daha kolaydır. LM algoritması Hessian matrise yaklaşımı aşağıdaki formülle gerçekleştirir.


$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad 2.14$$

Burada μ skalar bir değere sahiptir ve 0 olduğu zaman yukarıdaki eşitlik Newton yöntemi ile aynı olur. μ değeri büyük olduğunda yukarıdaki eşitlik küçük adımlı Gradient-descent algoritması haline döner. Newton's method hatanın minimum olduğu durumlarda daha hızlı ve daha hassastır. μ değeri iterasyonlarla artırılıp azaltılarak ağırlık bulunmaya çalışılır. LM algoritması 100 numaralı referansta ve YSA'na uygulaması ise 98 numaralı referansta açıklanmıştır.

Genel olarak bu metot yavaş yakınsama probleminden etkilenmez. Gauss-Newton algoritmasının kombinasyonu olan Levenberg-Marquart algoritması optimizasyon problemlerinde eğimli düşüş algoritmasına göre (gradient descent) daha etkin ve daha hızlıdır [98,100].

2.3. Tahmin Çalışmasında Kullanılan Hidrolojik Veriler

2.3.1. Kızılırmak Nehri Yamula İstasyonuna ait Hidrolojik Veriler



Şekil 2.3.1. Kızılırmak Nehri Yamula İstasyonu [101]

Devlet Su İşleri (DSİ) Genel Müdürlüğü tarafından işletilen Kızılırmak nehri Yamula istasyonundan kaydedilen 1940-1972 yılları arası 32 yıllık (380 ay) aylık ortalama akım verileridir. 15,581.6 km² lik drenaj alanı Şekil 2.3.1 de görülmektedir.


Tahmin çalışması için kullanılan bu verilerin 260 adetlik kısmı eğitim verisi olarak 120 adetlik kısmı test verisi olarak kullanılmıştır. Hidrolojik verilere ait istatistiksel değerler Tablo 2.3.1 de verilmektedir.

Tablo 2.3.1. 32 yıllık gözlenmiş aylık akım verilerine ait hidrolojik değişkenlerin istatistiksel parametreleri

Veri seti	X_{mean}	S_x	C_{sx}	X_{min}	X_{max}	C_{KX}
Tamamı	68.53	81.5021	2.1623	4.73	441	7.711
Eğitim	64.7367	78.7365	2.2249	4.73	441	7.907
Test	76.7798	86.9647	2.0320	7.7800	440	7.2229

Tablo 2.3.1 de verilen X_{mean} , S_x , C_{sx} , X_{min} , X_{max} , C_{KX} parametreleri sırasıyla ortalama, Standart sapma, Çarpıklık Katsayısı, Minimum Değer, Maksimum Değer, Basıklık katsayısı değerlerini göstermektedir.

2.3.2. Meriç Havzası Şeytan Deresine ait Hidrolojik Veriler



Şekil 2.3.2. Meriç Havzası Şeytan Deresi [101]

Tez çalışmasında drenaj alanı Şekil 2.3.2 de görülen Meriç havzasında bulunan Şeytan Deresinden 1-101 nolu istasyondan alınan 1957 – 1992 yılları arası gözlenen bir günlük kesikli akım verilerinin tahmini üzerine çalışılmıştır. Günlük akım debi miktarı verileri 12774 adettir.

Tahmin çalışması için kullanılan bu verilerin 8000 adetlik kısmı eğitim verisi olarak 4774 adetlik kısmı test verisi olarak kullanılmıştır. Bu hidrolojik verilere ait istatistiksel değerler Tablo 2.3.2 de verilmektedir.

Tablo 2.3.2. 35 yıllık gözlenmiş günlük akım verilerine ait hidrolojik değişkenlerin istatistiksel parametreleri

Veri seti	X_{mean}	S_x	C_{sx}	X_{min}	X_{max}	C_{KX}
Tamamı	2.4344	5.3745	9.4665	0	175	171.53
Eğitim	2.6730	5.7215	8.8864	0	175	159.96
Test	2.0345	4.7097	10.8252	0	119	192.77

Bu hidrolojik verilere ait istatistiksel değerler Tablo 2.3.3 de verilmektedir.

Tablo 2.3.3. 44 yıllık gözlemlenmiş aylık su seviyesi değerlerinin istatistiksel parametreleri

Veri seti	$\bar{X}_{\text{mean}}$	S_x	C_{sx}	X_{min}	X_{max}	C_{KX}
Tamamı	917.5868	1.0069	-0.3455	915.33	919.66	2.2050
Eğitim	917.8346	1.0522	-0.7747	915.70	919.66	2.7762
Test	917.2345	0.8207	-0.0192	915.33	918.79	1.8124

2.4. Tahmin Çalışmasında Kullanılan Performans Değerlendirme Kriterleri

Çeşitli modelleme teknikleriyle hidrolojik verilerin tahmini sonucu oluşan tahmin değerlerinin karşılaştırılmasında yaygın olarak kullanılan istatistikî kriterler; Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE), Belirginlik katsayısı (R^2) ve Korelasyon katsayısıdır (R). Tez çalışmasında modellerin gerçekleştirilmesi aşamasında performansını değerlendirmek içinde bu parametreler kullanılmıştır.

Ortalama Karesel Hata: Seride gözlenen ve tahmin edilen veri değerlerinin farkının karelerinin toplanıp, toplam veri sayısına bölünmesiyle elde edilen değerdir. Gözlenen değer ($X_{\text{gözlenen}}$) ile tahmin için kullanılan modelinin üretmiş olduğu çıktı (X_{tahmin}) arasındaki hatayı karesel olarak gösteren parametredir. Bu değerın sifıra yakın olması, tahmin edilen değerin kuvvetli biçimde doğruya yakınsadığını göstermektedir. MSE hesaplamak için kullanılan formül Eşitlik 2.14 te yer almaktadır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_{\text{gözlenen},i} - X_{\text{model},i})^2 \quad 2.15$$

Ortalama Mutlak Hata: Seride gözlenen ve tahmin edilen veri değerlerinin farkının, gözlenen değere bölündükten sonra her bir sonuç için yüzde olarak toplanmasıyla elde edilen değerdir. Gözlenen değer ($X_{\text{gözlenen}}$) ile tahmin için modelinin sonucu arasındaki hatayı mutlak olarak göstermekte olup, bu değerin sifıra yakın olması tahmin modelinin üretmiş olduğu sonucun istenen değere kuvvetli biçimde yaklaştığını göstermektedir. MAE değeri Eşitlik 2.15. teki formülle hesaplanmaktadır.

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_{\text{gözlenen},i} - X_{\text{model},i}| \quad 2.16$$

Belirginlik katsayısı: Seride gözlenen ve tahmin edilen veri değerleri arasındaki ilişkinin bir ölçüsüdür. R^2 , 0 ile 1 arasında değer almaktadır. Model çıktısı sonucu tahmin edilen değer ile gözlenen değer arasında bir ilişki var ise bu değer bire ilişki yok ise sıfıra yaklaşır. R^2 değeri Eşitlik 2.16. daki formülle hesaplanmaktadır.

$$R^2 = 1 - \frac{\sum_{i=1}^N [X_{gözlenen,i} - X_{model,i}]^2}{\sum_{i=1}^N [X_{gözlenen,i} - X_{ortalama gözlenen,i}]^2} \quad 2.17$$

Korelasyon Katsayısı: İki seri arasında doğrusal bir ilişki bulunup bulunmadığının yönünün ve derecesinin bir göstergesidir. Yani iki veri seti arasındaki X_i ve Y_i karşılıklı değerleri arasında doğrusal ilişkinin derecesini göstermektedir. R , -1 ile 1 arasında değerler almaktadır. R 'nin sıfıra yakın olması iki veri seti arasında ilişkinin olmadığı, bire yakın olması ise güçlü bir ilişkinin olduğunun göstergesidir. Eksi bire yakın olması ise iki veri seti arasında negatif yönde bir ilişki bulunduğunun göstermektedir. R değeri Pearson Korelasyon Katsayısı olarakta isimlendirilmektedir ve Eşitlik 2.17 deki formülle hesaplanmaktadır.

$$R = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{X_i - \mu_X}{\sigma_X} \right) \left(\frac{Y_i - \mu_Y}{\sigma_Y} \right) \quad 2.18$$

Yukarıda verilen eşitlikte μ_X ve σ_X X veri setinin ortalama ve standart sapmasını μ_Y ve σ_Y Y veri setinin ortalama ve standart sapmasını göstermektedir.

3. BÖLÜM

BULGULAR

Gerçekleştirilen tez çalışmasında Kızılırmak Nehri üzerinde Yamula istasyonundan alınan aylık akış verileri, Şeytan deresine ait günlük akış verileri ve Eğirdir havzasına ait aylık ortalama su seviyesini gösteren hidrolojik verilerin tahmini üzerinde çalışılmıştır. Hidrolojik verilerin tahmini için klasik lineer varsayımlara dayalı yaklaşımlardan ÖBHO ve ÖB modelleri kullanılmıştır. Hidrolojik verilerin tahmin performansını artırmak üzere nonlinear yaklaşım olan YSA kullanılmıştır. YSA performansını da daha iyileştirmek üzere hibrit yaklaşımlar olan AKA-YSA ve TSA-YSA yaklaşımı kullanılmıştır. Temel olarak tez çalışmasında hibrit yaklaşımların hidrolojik veri tahmin performansı üzerine etkisi incelenmiştir.


3.1. Kızılırmak Nehri Yamula İstasyonuna ait Hidrolojik Verilerin Tahmin Çalışması

Gerçekleştirilen tez çalışmasının ilk aşamasında Kızılırmak Nehri Yamula istasyonundan elde edilen akış verilerinin tahmin çalışması gerçekleştirilmiştir. İlk aşamadaki tahmin çalışmasında lineer yaklaşım olan ÖBHO ve ÖB modelleri kullanılmıştır. Ayrıca bu verilerin YSA ile tahmini gerçekleştirilmiştir. Son zamanlarda kullanılmaya başlayan hibrit modeller üzerinde çalışılmış ve YSA'nın performansını artırmak üzere AKA-YSA ve TSA-YSA modelleri kullanılmıştır.

3.1.1. ÖBHO ve ÖB Modeli Kullanarak Veri Tahmini

Devlet Su İşleri (DSİ) Genel Müdürlüğü tarafından işletilen Kızılırmak Nehri üzerinde kurulu Yamula İstasyonundan alınan hidrolojik veriler, Şekil 3.1.1'de görüldüğü gibi 380 adet ve her bir aya ait akım debilerini göstermektedir. Bu veriler normalize

edilerek (veriden, verinin minimum değeri çıkarılarak verinin en büyük ve en küçük değeri arasındaki farka bölünmesi) bir ileri tahmin işleminde kullanılmıştır.




Şekil 3.1.1. Yamula İstasyonu'na ait normalize aylık akış verileri

ÖB Modelleme ile veri tahmini; Tez çalışmasında; Yamula istasyonundaki aylık akımların, ÖB modelleme kullanarak tahmini aşamasında 380 adet verinin 260 adeti model parametrelerinin belirlenmesinde 120 adetlik veri seti ise belirlenen modelin uygulanması safhasında kullanılmıştır. ÖB modellemede model derecesini belirlemek önemli olmaktadır. Tez çalışmasında ÖB model derecesini ‘Yule Walker metodu’ kullanarak en iyi tahmini elde etmek üzere; 260 adet veri seti üzerinde ÖB modeli kurularak, model derecesi 1 den 35’e kadar iterasyonla artırılmıştır ve Akaike Bilgi Kriteri (ABK) değeri en iyi modeli belirlemek üzere hesaplanmıştır. Akaike tarafından ilk defa ortaya konulan ve ABK olarak bilinen kriter aşağıdaki formülle hesaplanmaktadır.

$$AIC(k) = N \ln(Mse) + 2k$$

Burada N veri sayısını, k parametre sayısını ve MSE ortalama karesel hatayı göstermektedir [102].

Şekil 3.1.2’de ÖB model derecesinin 1 den 35 e kadar artırılması durumunda ABK değerleri görülmektedir.






Şekil 3.1.2. ÖB Model derecesine ABK değerleri

Şekil 3.1.2 deki grafikte de anlaşılaçağı üzere ÖB model derecesi 12 için ABK değerinin en küçük olduğı görülmüştür. Bu nedenle hidrolojik veri tahmininde ÖB model derecesi 12 olarak belirlenmiştir. ÖB model derecesinin belirlenmesi ve modelin kurulması aşamasında kullanılan 260 veriden oluşan veri setine eğitim verisi ve kurulan modelin testi için belirlenen 120 adet veriden oluşan veri setine test verisi olarak isimlendirecek olursak, eğitim ve test için gözlemlenen veri ve tahmin verisi arasındaki MSE, MAE, R ve R^2 değerleri Tablo 3.1.1 de yer almaktadır. Şekil 3.1.3 te gözlem ve ÖB(12) modeli kullanılarak elde edilen tahmin verileri yer almaktadır.


Tablo 3.1.1. Yamula istasyonunda aylık akımların tahmini için ÖB(12) Modelinin tahmin performans sonuçları

EĞİTİM			
MSE	MAE	R	R^2
0.0109	0.0550	0.8153	0.6648
TEST			
MSE	MAE	R	R^2
0.0113	0.0586	0.8445	0.7131

ÖB modelleme ile eğitim ve test verisi için elde edilen tahmin sonuçlarına ait grafikler Şekil 3.1.3.'te görülmektedir.



a



b

Şekil 3.1.3. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve
a ÖB(12) modelinin elde edildiği veri seti ve tahmin verisi
b. ÖB(12) modelinin uygulandığı veri seti ve tahmin verisi




ÖBHO Modelleme ile veri tahmini; Tez çalışmasında ÖBHO modelleme kullanarak tahmini aşamasında da 380 adet veriden, eğitim verisi olarak isimlendirilen 260 adet model parametrelerinin belirlenmesinde test verisi olarak isimlendirilen 120 adetlik veri seti ise belirlenen modelin uygulanması aşamasında kullanılmıştır. ÖBHO modellemeye de model derecesini belirlemek önemlidir. Tez çalışmasında ÖBHO model kullanarak en iyi tahmini elde etmek üzere; 260 adet veri seti üzerinde ÖBHO (p,q) modeli kurularak model derecesi sistemin sıfır ve kutupları için 1 den 35'e kadar iterasyonla artırılmıştır. Her bir model derecesi için tahmin performansını değerlendirmek üzere ABK kriteri kullanılmıştır ve ABK kriterinin en düşük olduğu değerdeki model derecesi p=26, q=27 olarak hesaplanmıştır.

Eğitim ve test verisinin ÖBHO (26, 27) modeli kullanarak tahmini sonucu elde edilen veri ile gözlemlenen veri arasındaki MSE, MAE, R ve R^2 değerleri hesaplanmıştır ve Tablo 3.1.2 de yer almaktadır. Şekil 3.1.4 te gözlem ve ÖBHO (26,27) modeli kullanılarak elde edilen tahmin verileri yer almaktadır.


Tablo 3.1.2. Yamula istasyonunda aylık akımların tahmini için ÖBHO (26,27) modelinin tahmin performans sonuçları

EĞİTİM			
MSE	MAE	R	R^2
0.0059	0.0455	0.9045	0.8181
TEST			
MSE	MAE	R	R^2
0.0097	0.0602	0.8687	0.7546

ÖBHO (26,27) modelleme ile eğitim ve test verisi için elde edilen tahmin sonuçlarına ait grafikler Şekil 3.1.4.'te görülmektedir.



a



b




Şekil 3.1.4. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve
a ÖBHO(26,27) modelinin elde edildiği eğitim veri seti ve tahmin verisi
b ÖBHO (26,27) modelinin uygulandığı test veri seti ve tahmin verisi

3.1.2. Yapay Sinir Ağları Modeli Kullanarak Veri Tahmini




Tez çalışmasında, lineer olmayan ve durağan olmayan sinyallerin analizi ve tahmini için yaygın olarak kullanılmaya başlanan YSA ile hidrolojik verilerin tahmini gerçekleştirilmiştir. Böylece tahmin çalışmasında kullanılan farklı yaklaşımların performansını karşılaştırma imkanı sağlanmış olmaktadır. Normalize edilmiş su verileri ön işleme tabi tutulmadan doğrudan YSA'na tahmin amaçlı uygulanmıştır. YSA modelinde ÇKAYSA kullanılmıştır ve ağ yapısı bir giriş bir çıkış ve bir ara katmandan oluşmaktadır. Tahmin performansı en yüksek ağ yapısını oluşturabilmek için ara katman nöron sayısı 1 den 9 a kadar artırılarak oluşturulan ÇKAYSA ile tahmin işlemi gerçekleştirilmiştir. Tahmin sonucunda performansı en yüksek olan, en düşük hatanın elde edildiği nöron sayısı ile YSA modeli gerçekleştirilmiştir. Bu yapıda da iterasyon sayısı 100 olarak belirlenmiştir ve aktivasyon fonksiyonu olarak sigmoidal fonksiyon kullanılmıştır. ÇKAYSA yapısında öğrenme algoritması olarak Levenberg Marquardt geriyayılım algoritması kullanılmıştır. YSA'na bir, iki, üç, dört, beş, altı ve on girişler uygulanmış ve giriş sayısının tahmin performansı üzerine etkileri incelenmiştir. ÖB ve ÖBHO modellerde kullanıldığı gibi veri setinin ilk 260 verilik kısmı eğitim verisi olarak kalan 120 verilik kısmı ise test verisi olarak seçilmiştir. YSA ile bir ileri tahmin sonucu MSE, MAE, R performans parametreleri eğitim ve test aşamasında hesaplanmıştır ve Tablo 3.1.3' de yer almaktadır. Ayrıca Şekil 3.1.5 te gözlem ve YSA modeli kullanılarak elde edilen tahmin verileri yeralmaktadır.

Tablo 3.1.3. Yamula istasyonunda aylık akımların tahmini için kullanılan YSA modelinden elde edilen tahmin performans parametreleri




	1 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
	TEST	EĞİTİM
MSE	0.0218	0.0191
MAE	0.0901	0.0808
R	0.6745	0.6406
R²	0.4549	0.4104
	2 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0187	0.0104
MAE	0.0764	0.0579
R	0.7333	0.8237
R²	0.5378	0.6784
	3 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0189	0.0121
MAE	0.0819	0.0661
R	0.7293	0.7920
R²	0.5319	0.6272
	4 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0189	0.0121
MAE	0.0821	0.0662
R	0.7308	0.7931
R²	0.5341	0.6290
	5 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0188	0.0118
MAE	0.0816	0.0648
R	0.7359	0.7989
R²	0.5416	0.6383
	6 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0188	0.0111
MAE	0.0825	0.0629
R	0.7425	0.8117
R²	0.5513	0.6588
	10 giriş- 1 çıkışlı bir ara katmanlı YSA Modeli	
MSE	0.0172	0.0080
MAE	0.0750	0.0499
R	0.7724	0.8641
R²	0.5967	0.7467






a



b



C



d




Şekil 3.1.5. a,b,c,d. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve bir, üç, beş, ve on giriş bir ara katmanlı YSA modeli ile elde edilen tahmin verisi

Tablo 3.1.3 ve Şekil 3.1.5 den de görüleceği gibi, bir gizli katmana sahip ÇKAYSA modelinde giriş sayısı arttıkça, tahmin performansının yükseldiği görülmektedir. Ancak giriş sayısının on olması durumunda, tahmin performansında azalma olduğu da görülmektedir.




Tablo 3.1.1., Tablo 3.1.2. ve Tablo 3.1.3. incelendiğinde, ÖB ve ÖBHO modellerine göre bir girişli YSA modeli ile tahmin işleminde, tahmin performansında iyileşme görülmemektedir. Tez çalışmasında; ÇKAYSA modeli için gizli katman sayısının etkisini incelemek amacıyla, iki gizli katmana sahip ÇKAYSA modeli kurularak, bu modelin tahmin performansı incelenmiştir. İki ara katmana sahip ÇKAYSA modeli kurulurken en iyi arakatman nöron sayısını belirlemek için her iki ara katman sayısı 1 den 9'a kadar iterasyonlarla artırılmış ve en iyi tahmin performansının elde edildiği nöron sayısı belirlenerek ÇKAYSA modeli ortaya konmuştur. Bu model içinde bir, iki, üç, dört, beş ve on giriş için ÇKAYSA modeli ile tahmin işlemi gerçekleştirilmiştir. İki ara katmana sahip YSA modeli için performans değerleri Tablo 3.1.4 te görülmektedir. İki ara katmanlı YSA modeli için gözlem ve tahmin verileri Şekil 3.1.6 da görülmektedir.

Tablo 3.1.4. Yamula istasyonunda aylık akımların tahmini kullanılan iki ara katmanlı YSA modelinden elde edilen tahmin performans parametreleri




	1 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
	TEST	EĞİTİM
MSE	0.0218	0.0192
MAE	0.0897	0.0811
R	0.6777	0.6397
R²	0.4592	0.4092
	2 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.0227	0.0095
MAE	0.0852	0.0499
R	0.6689	0.8418
R²	0.4474	0.7086
	3 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.0322	0.0069
MAE	0.0894	0.0465
R	0.6357	0.8881
R²	0.4041	0.7887
	4 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.0265	0.0045
MAE	0.1033	0.0360
R	0.6125	0.9279
R²	0.4021	0.8610
	5 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.0204	0.0090
MAE	0.0833	0.0545
R	0.7149	0.8509
R²	0.5110	0.7241
	6 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.0350	0.0078
MAE	0.0983	0.0530
R	0.5222	0.8725
R²	0.2727	0.7613
	10 giriş- 1 çıkışlı iki ara katmanlı YSA Modeli	
MSE	0.6820	0.0030
MAE	0.2502	0.0284
R	0.3438	0.9511
R²	0.1182	0.9047




a



b



C



d


Şekil 3.1.6. a,b,c,d. Kızılırmak Nehri aylık akım için gözlemlenmiş akımlar ve bir, üç, beş ve on giriş iki ara katmanlı YSA modeli ile elde edilen tahmin verisi

Tablo 3.1.4 incelendiğinde, giriş sayının artması ile tahmin performansının artırdığı görülmektedir. Ancak giriş sayısının fazla artırılması durumunda tahmin performansının bir ara katmanlı ÇKAYSA modelinde olduğu gibi azaldığı görülmektedir. Bu nedenle, YSA ile tahmin çalışması için elde edilen sonuçlara göre, 5 girişli modelin tahmin çalışması için yeterli olduğu söylenebilmektedir. Aynı zamanda, Tablo 3.1.3 ve Tablo 3.1.4'deki performans parametreleri karşılaştırıldığında, 1 ara katmanlı ÇKAYSA modeli ile iki ara katmanlı ÇKAYSA modelleri arasında tahmin performansında önemli iyileşme olmadığı görülmüştür. Bu nedenle, çalışmada kullanılan verilerin ÇKAYSA modeli ile tahmini için 5 giriş bir ara katmanlı yapının uygun olduğu görülmektedir.

3.1.3. Ampirik Kip Ayrışım-Yapay Sinir Ağları Modeli Kullanarak Veri Tahmini


Gerçekleştirilen tez çalışmasında Kızılırmak Nehri Yamula istasyonuna ait aylık akımlar olan hidrolojik verilerin tahmini, Şekil 3.1.7.de de görüldüğü gibi, aşağıdaki adımlar ile gerçekleştirilmiştir.

- 1- Hidrolojik verilerin eğitim ve test verisi olmak üzere iki gruba ayrılması.
- 2- Eğitim verileri ve test verilerinin kendi içlerinde AKA yöntemi kullanarak IMF bileşenlerine ayrıştırılması.
- 3- Eğitim aşamasında eğitim alt bileşenlerinin tahmini ve tahmin sonucu elde edilen bileşenlerin toplanması ile eğitim tahmin sonucunun elde edilmesi
- 4- Eğitim tahmin sonuçlarına göre en iyi tahmini elde etmek üzere YSA yapısının belirlenmesi
- 5- Elde edilen YSA yapısı ile test verisi alt bileşenlerinin tahmini ve tahmin verilerinin toplanması ile test tahmin sonucu




Şekil 3.1.7. Hidrolojik verilerin tahmini için AKA-YSA Modelinin şematik gösterimi

Tez çalışmasında önerilen AKA-YSA modelinin performansını test edebilmek için, hidrolojik veriler normalize edilerek, eğitim ve test datası olmak üzere iki gruba ayrılmıştır. Diğer modellerde olduğu gibi, veri setinin ilk 260 adet veriden oluşan parçası, Şekil 3.1.8.a'da görüldüğü gibi, eğitim için sonraki 120 adet veriden oluşan daha kısa süreli parçası da Şekil 3.1.8.b'de görüldüğü gibi test aşamasında test verisi olarak kullanılmıştır.




a




b

Şekil 3.1.8. Yamula İstasyonunda **a.** Eğitim için kullanılan **b.** Test için kullanılan aylık akış verileri m^3/sn

Hidrolojik veri tahmini için kullanılacak eğitim ve test verileri, AKA metodu kullanılarak 4 altbantta IMF bileşenine ayrılmıştır. Elde edilen IMF bileşenleri Şekil 3.1.9 da görülmektedir.



a



Şekil 3.1.9. a. Eğitim için Kullanılan b. Test için Kullanılan IMF bileşenleri

Tahmin çalışmasında kullanılan ağ yapısı; Tahmin çalışması için ÇKAYSA ağ yapısı kullanılmıştır. Her bir IMF bileşeni için oluşturulan ÇKAYSA yapısı bir giriş, bir ara katman ve bir çıkış katmanından oluşmaktadır. Ara katmandaki en iyi nöron sayısını belirleyebilmek için MATLAB ortamında nöron sayıları 1 den 9 a kadar iterasyonla artırılmıştır ve ara katmanlardaki nöron sayısı en düşük ortalama karesel hatayı veren nöron sayısı ile belirlenmiştir.

Her bir altbant için olmak üzere toplam 4 adet ÇKAYSA Levenberg Marquardt geri yayılım algoritması kullanılarak eğitilmiştir. Tahmin için en iyi YSA'nı belirlemek üzere performans kriteri olarak MSE ve MAE değerleri kullanılmıştır.


Verilerin eğitimi için iterasyon sayısı 100 olarak seçilmiştir. Eğitim aşamasında YSA çıkışından elde edilen alt bileşen tahmin verileri toplanarak hidrolojik verilerin eğitim tahmin verileri elde edilmiştir. Eğitim aşamasında en iyi tahmin sonucunu veren ağ yapısı, test aşamasında test verilerinin tahmini için kullanılmıştır. Tez çalışmasında veri tahmini için bir, iki, üç, dört ve beş giriş olmak üzere beş farklı yapı en iyi tahmin çalışması için denenmiştir.

Veri tahmini için AKA-YSA Modeli 1 giriş-1 çıkışlı yapı; Burada YSA giriş verileri her bir altbant için $x(t)$ değeri iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ değeri olarak belirlenmiştir. Dolayısı ile eğitim ve test için kullanılan giriş öznitelik sayısı bir olmuştur. Tablo 3.1.5.a da eğitim ve test süresince her bir IMF bileşeninin tahmini sırasında elde edilen MSE, MAE, R ve R^2 değerleri de verilmektedir.

Tablo 3.1.5. a.Yamula istasyonunda aylık akımların tahmini için 1 giriş-1 çıkışlı AKA-YSA modelin ile tahmin edilen IMF lerin eğitim ve test performans değerleri

	IMF1	IMF2	IMF3	IMF4
	Eğitim	Eğitim	Eğitim	Eğitim
MSE	0.0164	0.0084	0.0002	0.00001
MAE	0.0974	0.0775	0.0101	0.0028
R	0.5544	0.8734	0.9684	0.9980
R²	0.3073	0.7628	0.9379	0.9960
	Test	Test	Test	Test
MSE	0.0145	0.0104	0.00001	0.00001
MAE	0.0935	0.0848	0.0053	0.0002
R	0.3220	0.8658	0.9922	0.9989
R²	0.1037	0.7497	0.9845	0.9978

Tablo 3.1.5.a dan da görüldüğü gibi, IMF1 in eğitimi dışında tüm IMF lerin tahmini oldukça başarılı olmuştur. IMF1 in tahmininde hatanın yüksek olma sebebi, verideki IMF1 bileşeninin yüksek frekanslı gürültü bileşeninin içeriyor olmasındandır. Şekil 3.1.10 da tüm IMF’lerin tahminine ait grafikler verilmektedir.




Şekil 3.1.10. IMF bileşenlerine ayrılmış veriler ve 1 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF veriler

Tablo 3.1.5..a'da IMF alt bileşenlerden IMF1'in tahmin performansının diğer IMF bileşenlerin tahmin performansına göre düşük olduğu görülmektedir. YSA ile tahmin edilen IMF bileşenlerinin tamamı ve IMF1 dışındaki diğer IMF bileşenleri toplanarak iki adet tahmin sonucu elde edilmiştir. Elde edilen tahmin verisinin gözlemlenen veriye göre MSE, MAE ve R değerleri Tablo 3.1.5.b. de görülmektedir. Elde edilen tahmin verisi Şekil 3.1.11'de görülmektedir.

Tablo 3.1.5.b. Yamula istasyonunda aylık akımların tahmini için 1 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri


	Tum IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0221	0.0210
MAE	0.1048	0.1006
R	0.6868	0.6369
R²	0.4716	0.4057
	IMF1 dışındaki bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0246	0.0290
MAE	0.1189	0.1324
R	0.6685	0.5664
R²	0.4469	0.3208



Şekil 3.1.11. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 1 giriş- 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri

Tablo 3.1.5.b’de 1 giriş – 1 çıkışlı AKA-YSA veri tahmin modeli kullanılarak IMF’lerin toplanması sonucu tahmin verisinin yeniden elde edilmesi aşamasında, IMF1 in toplama katılmadığı yapıda MSE, MAE ve R performans değerlerinin IMF1 in toplama katıldığı duruma yakın olduğu görülmektedir. AKA-YSA modelinde 1 giriş 1 çıkışlı yapıda yüksek frekanslı pikleri içeren bileşen IMF1’in tahmin performansının düşük olduğu ancak diğer IMF’lerin tahmin performansının iyi olduğu görülmektedir.

Veri tahmini için 2 giriş-1 çıkışlı yapı; Bu aşamada YSA giriş verileri her bir IMF alt bileşeni için $x(t-1)$, $x(t)$ değerleri iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ değeri olarak belirlenmiştir. Dolayısı ile eğitim ve test verileri için kullanılan giriş öznitelik sayısı iki olmuştur. Eğitim veri seti her bir IMF için 2×260 boyutlu bir matris iken test veri seti girişte 2×120 boyutlu bir matristir. Tablo 3.1.6.a. dan da görüleceği üzere YSA ile IMF lerin tahmininde oldukça başarılı sonuçlar elde edilmiştir. Şekil 3.1.12 de tüm IMF bileşenlerinin 2 girişli YSA için tahmin sonuçları görülmektedir.



Şekil 3.1.12. Yamula istasyonunda aylık akımlar hidrolojik gözlem verisi ve 2 giriş-1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri


Tablo 3.1.6.a'da 2 giriş 1 çıkışlı modelde IMF alt bileşenlerden IMF1'in tahmin performansının diğer IMF bileşenlerin tahmin performansına göre 1 giriş 1 çıkışlı modelde olduğu gibi düşük olduğu görülmektedir. Ancak 2 giriş 1 çıkışlı modelin tahmin performansının daha yüksek olduğu görülmektedir. YSA ile tahmin edilen IMF bileşenlerinin tamamı ve IMF1 dışındaki diğer IMF bileşenleri toplanarak iki adet tahmin sonucu elde edilmiştir. Elde edilen tahmin verisinin gözlemlenen veriye göre MSE, MAE ve R değerleri Tablo 3.1.6.b. de görülmektedir. Tahmin verileri ve gözlenen verileri Şekil 3.1.13 de yer almaktadır.

Tablo 3.1.6. a. Yamula istasyonunda aylık akımların tahmini için 2 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri

	IMF1	IMF2	IMF3	IMF4
	Eğitim	Eğitim	Eğitim	Eğitim
MSE	0.0071	0.0002	0.0000	0.0000
MAE	0.0574	0.0105	0.0017	0.0006
R	0.8316	0.9973	0.9990	0.9999
R ²	0.6916	0.9945	0.9980	0.9998
	Test	Test	Test	Test
MSE	0.0115	0.0002	0.0000	0.0000
MAE	0.0683	0.0123	0.0017	0.0001
R	0.6189	0.9972	0.9998	1.0000
R ²	0.3830	0.9945	0.9996	1.0000

Tablo 3.1.6.b. Yamula istasyonunda aylık akımların tahmini için 2 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri

	Tum IMF bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0117	0.0073
MAE	0.0668	0.0572
R	0.8553	0.8812
R ²	0.7315	0.7765
	IMF1 dışındaki bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0158	0.0228
MAE	0.0976	0.1231
R	0.8134	0.7019
	0.6617	0.4927




Şekil 3.1.13. Kızılırmak Nehri aylık akım için gözlemlenmiş akımlar ve 2 giriş - 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri

Veri tahmini için 3 giriş-1 çıkışlı yapı Her bir IMF alt bileşene ait; YSA giriş verileri $x(t-2)$, $x(t-1)$, $x(t)$ değerleri iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ değeri olmuştur. Dolayısı ile eğitim ve test için kullanılan giriş öznitelik sayısı üçtür ve her bir IMF için eğitim giriş datası 3×280 iken test giriş datası 3×120 dir. Eğitim ve test sırasında 3 girişli 1 çıkışlı AKA-YSA modelinde elde edilen hatalar Tablo 3.1.7.a da verilmiştir.

Tablo 3.1.7.a da görüldüğü gibi 3 girişli 1 çıkışlı AKA-YSA modelinde IMF lerin tahmini oldukça başarılı sonuçlar alınmıştır. Şekil 3.1.14 de 3 girişli – 1 çıkışlı AKA-YSA modeli için IMF lerin tahmin grafikleri görülmektedir.

Tablo 3.1.7. a. Yamula istasyonunda aylık akımların tahmini için 3 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri

	IMF1	IMF2	IMF3	IMF4
	Eğitim	Eğitim	Eğitim	Eğitim
MSE	0.0049	0.0001	0.000001	0.000001
MAE	0.0452	0.0066	0.0019	0.0015
R	0.8844	0.9989	0.9992	0.9993
R²	0.7822	0.9978	0.9983	0.9986
	Test	Test	Test	Test
MSE	0.0093	0.0002	0.00001	0.000001
MAE	0.0648	0.0098	0.0020	0.0002
R	0.6927	0.9978	0.9998	1.0000
R²	0.4799	0.9955	0.9996	1.0000




Şekil 3.1.14. Yamula istasyonunda aylık akımların tahmini için IMF bileşenlerine ayrılmış test verileri ve 3 giriş - 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler

Tablo 3.1.7.a'da 3 giriş 1 çıkışlı modelde 2 giriş - 1 çıkışlı ve 1 giriş - 1 çıkışlı modele göre tahmin performansının daha yüksek olduğu görülmektedir. YSA ile tahmin edilen IMF bileşenlerinin tamamı ve IMF1 dışındaki diğer IMF bileşenleri toplanarak elde edilen iki adet tahmin verisinin gözlemlenen veriye göre MSE, MAE ve R değerleri Tablo 3.1.7.b. de görülmektedir. Tez çalışmasında kullanılan model ve gözlenen veriler Şekil 3.1.15. de yer almaktadır.

Tablo 3.1.7. b. Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri

	Tum IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0092	0.0050
MAE	0.0645	0.0453
R	0.8786	0.9216
R ²	0.7719	0.8493
	IMF1 Dışındaki Bileşenlerinin toplanması sonucu elde edilen tahmin	
	TEST	EĞİTİM
MSE	0.0162	0.0228
MAE	0.0983	0.1232
R	0.8117	0.7016
R ²	0.6589	0.4922




Şekil 3.1.15. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 3 giriş - 1 çıkışlı AKA-YSA modeli ile elde edilen tahmin verileri

Veri tahmini için 4 giriş-1 çıkışlı yapı; Her bir IMF alt bileşene ait, YSA giriş verileri $x(t-3)$, $x(t-2)$, $x(t-1)$, $x(t)$ değerleri iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ değeri olmuştur. Dolayısı ile eğitim ve test için kullanılan giriş öznitelik sayısı dördüttür ve her bir IMF için eğitim giriş datası 4×280 iken test giriş datası 4×120 dir. Eğitim ve test sırasında 4 girişli 1 çıkışlı AKA-YSA modelinde elde edilen hatalar Tablo 3.1.8.a da verilmiştir.

Tablo 3.1.8. a. Yamula istasyonunda aylık akımlar serisi için 4 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF lerin eğitim ve test performans değerleri

	IMF1	IMF2	IMF3	IMF4
	Eğitim	Eğitim	Eğitim	Eğitim
MSE	0.0049	0.0001	0.000001	0.000001
MAE	0.0483	0.0056	0.0017	0.0007
R	0.8829	0.9992	1.0000	0.9998
R²	0.7795	0.9983	0.9999	0.9996
	Test	Test	Test	Test
MSE	0.0096	0.0001	0.000001	0.000001
MAE	0.0677	0.0079	0.0018	0.0001
R	0.7139	0.9986	1.0000	1.0000
R²	0.5097	0.9973	1.0000	1.0000

Tablo 3.1.8.a da görüldüğü gibi 4 girişli 1 çıkışlı AKA-YSA modelinde IMF lerin tahmininde, 3 girişli 1 çıkışlı AKA-YSA modelinde olduğu gibi başarılı sonuçlar alınmıştır. Şekil 3.1.16 da 4 girişli 1 çıkışlı AKA-YSA modeli için IMF lerin tahmin grafikleri görülmektedir.




Şekil 3.1.16. IMF bileşenlerine ayrılmış test verileri ve 4 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler

YSA ile tahmin edilen IMF bileşenlerinin tamamı ve IMF1 dışındaki diğer IMF bileşenleri toplanarak elde edilen iki adet tahmin verisinin gözlemlenen veriye göre MSE ve MAE hataları ve R değerleri Tablo 3.1.8.b. de görülmektedir. Tez çalışmasında kullanılan model ve gözlenen veriler Şekil 3.1.17 de yer almaktadır.

Tablo 3.1.8. b. Yamula istasyonunda aylık akımlar serisi için 4 giriş -1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri

	Tum IMF Bileşenlerinin toplanması sonucu elde edilen tahmin	
	TEST	EĞİTİM
MSE	0.0098	0.0048
MAE	0.0682	0.0471
R	0.8711	0.9245
R²	0.7589	0.8548
	IMF1 Dışındaki Bileşenlerinin toplanması sonucu elde edilen	
	TEST	EĞİTİM
MSE	0.0162	0.0219
MAE	0.0987	0.1215
R	0.8089	0.7105
R²	0.6543	0.5048




Şekil 3.1.17. Kızılırmak Nehri aylık akım için gözlemlenmiş akımlar ve 4 giriş - 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler

Veri tahmini için 5 giriş-1 çıkışlı yapı; Her bir IMF alt bileşene ait YSA giriş verileri $x(t-4)$, $x(t-3)$, $x(t-2)$, $x(t-1)$, $x(t)$ değerleri iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ değeridir. Dolayısı ile eğitim ve test için kullanılan giriş öznitelik sayısı beştir ve her bir IMF için eğitim giriş datası 5x280 iken test giriş datası 5x120 dir. Eğitim ve test sırasında 5 girişli 1 çıkışlı AKA-YSA modelinde elde edilen hatalar Tablo 3.1.9.a da verilmiştir.

Tablo 3.1.9 .a. Yamula istasyonunda aylık akımlar serisi için 5 giriş-1 çıkışlı AKA-YSA modeli ile tahmin IMF lerin eğitim ve test performans değerleri

	IMF1	IMF2	IMF3	IMF4
	Eğitim	Eğitim	Eğitim	Eğitim
MSE	0.0048	0.00001	0.00001	0.000001
MAE	0.0489	0.0045	0.0021	0.0010
R	0.8831	0.9995	0.9997	0.9998
R²	0.7798	0.9990	0.9994	0.9996
	Test	Test	Test	Test
MSE	0.0114	0.0003	0.00001	0.000001
MAE	0.0770	0.0093	0.0030	0.00001
R	0.6515	0.9965	0.9996	1.0000
R²	0.4244	0.9930	0.9993	1.0000

Tablo 3.1.9.a da görüldüğü gibi 5 girişli 1 çıkışlı AKA-YSA modelinde IMF lerin tahmininde, 4 girişli 1 çıkışlı AKA-YSA modelinde olduğu gibi benzer performans sergilemiştir. Şekil 3.1.8 de 5 girişli 1 çıkışlı AKA-YSA modeli için IMF lerin tahmin grafikleri görülmektedir.




Şekil 3.1.18. IMF bileşenlerine ayrılmış test verileri ve 5 giriş- 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler

Tablo 3.1.9.b. Yamula istasyonunda aylık akımlar serisi için 5 giriş-1 çıkışlı AKA-YSA modeli ile tahmin edilen IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait performans değerleri

	Tüm IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	0.0131	0.0048
MAE	0.0793	0.0486
R	0.8232	0.9244
R²	0.6776	0.8545
	IMF1 Dışındaki Bileşenlerinin toplanması sonucu elde edilen tahmin	
	TEST	EĞİTİM
MSE	0.0174	0.0219
MAE	0.1007	0.1211
R	0.7879	0.7110
R²	0.6209	0.5056

5 giriş 1 çıkışlı YSA ile tahmin edilen IMF bileşenlerinin tamamı ve IMF1 dışındaki diğer IMF bileşenleri toplanarak elde edilen iki adet tahmin verisinin gözlemlenen veriye göre MSE, MAE ve R değerleri Tablo 3.1.9.b. de görülmektedir. 5 giriş 1 çıkışlı model ve gözlenen veriler Şekil 3.1.19. da yer almaktadır.



Şekil 3.1.19. Kızılırmak Nehri aylık akım için gözlenmiş akımlar ve 5 giriş 1 çıkışlı AKA-YSA modeli ile tahmin edilen veriler


Tablo 3.1.5 – 9 da görüldüğü gibi, AKA-YSA modelinde test durumunda 3 giriş 1 çıkışlı modelde MSE değeri **0.0092**, MAE değeri **0.0645**, R değeri **0.8786** ve R^2 değeri

0.7719 olarak elde edilmiştir. Sadece YSA ile yapılan tahmin işleminde tahmin edilen veri ve gözlemlenen veri arasındaki MSE, MAE, R ve R^2 değerleri Tablo 3.1.3 ve Tablo 3.1.4 de görülmektedir. Veri tahmini için kullanılan ÇKAYSA modelinde 1 ara katman ve 5 giriş ve 1 çıkışlı modelin diğer YSA modellerine göre performansının daha yüksek olduğu görülmektedir. 5 girişli 1 çıkışlı 1 ara katmanlı YSA modelinde MSE değeri **0.0188**, MAE değeri **0.0816**, R değeri **0.7359** ve R^2 değeri **0.5416** olarak elde edilmiştir. Ayrıca ÖB(12) modeli ile elde edilen tahmin sonuçlarına göre MSE değeri **0.0113**, MAE değeri **0.0586**, R değeri **0.8445** ve R^2 değeri **0.7131** olarak elde edilmiştir. ÖBHO(26,27) modeli ile gerçekleştirilen tahmin işleminde MSE değeri **0.0097**, MAE değeri **0.0602**, R değeri **0.8687** ve R^2 değeri **0.7546** olarak elde edilmiştir. Bu sonuçlara göre AKA-YSA modelinin performansının en iyi olduğu görülmektedir [103].

AKA-YSA Modelinde Tablo 3.1.5-9 tan da görüleceği üzere IMF2-IMF4 bileşenleri YSA kullanılarak oldukça başarılı bir şekilde tahmin edilmektedir. Ancak veride IMF1 bileşeninin YSA ile tahmin başarısı düşüktür. Bunun sebebi ise IMF1 bileşeninde yüksek frekanslı bileşenlerini ve gürültü bileşenlerini içermesidir.

3.1.4. Hidrolojik Verilerin Tahmini için Tekil Spektrum Analizi, Ampirik Kip Ayırışım Yöntemi ve Yapay Sinir Ağları

Tez çalışmasında hidrolojik verinin yüksek frekanslı IMF1 bileşeninin tahminin iyileştirilmesi için TSA tekniği kullanılmıştır. Hidrolojik verinin IMF1 bileşeni, TSA tekniği ile en yüksek özdeğerine göre eğitim ve test verisi Şekil 3.1.20 de görüldüğü gibi yeniden yapılandırılmıştır ve bu yeniden yapılandırılan IMF1 bileşeni kullanılarak, test verisi tahmin edilmeye çalışılmıştır.



Şekil 3.1.20. IMF1 verisi ve TSA yöntemi ile yeniden yapılandırılan IMF1 verisi

Hidrolojik verilerin tahmini için, IMF2-IMF4 bileşenleri tezin 3.1.3 bölümünde belirtildiği gibi, tek ara katmanlı YSA ile tahmin edilmiştir. IMF1 bileşeninin tahmini öncesi, bu bileşene TSA yöntemi uygulanarak, TSA+IMF1 bileşeni YSA ile tahmin edilmiştir. Böylece toplam tahmin verisi, tahmin edilen TSA-IMF1 bileşeni ve IMF2, IMF3 ve IMF4 bileşenlerinin toplamı ile elde edilmiştir.

Tahmin performansı yüksek olan 3 giriş 1 çıkış YSA modeli kullanarak TSA+IMF1 bileşeninin tahmini ve toplam tahmin performans değerleri Tablo 3.1.10 da görülmektedir.

Bu sonuca göre; IMF1 verisine TSA uygulanması sonucu elde edilen tahmin sonucunda MSE değeri 0.0007, MAE değeri 0.0195, R değeri 0.9667 ve R^2 değeri 0.9346 olarak elde edilmiştir. Böylece IMF1 verisinin tahmin başarısı artırılarak tüm verinin tahmini neticesinde MSE değeri 0.0054, MAE değeri 0.0563, R değeri 0.9327 ve R^2 değeri 0.8703 olarak elde edilmiştir. Böylece veri tahmin performansı, IMF1 bileşeninin TSA kullanılarak yeniden yapılandırılması ile iyileştirilmiştir.


Tablo 3.1.10. Yamula istasyonunda aylık akımlar serisi için IMFlerin toplamı sonucu elde edilen tahmin sonuçlarının performans değerleri

	IMF1+TSA	IMF2	IMF3	IMF4
MSE	0.0007	0.0001	0.000001	0.000001
MAE	0.0195	0.0066	0.0019	0.0015
R	0.9667	0.9989	0.9992	0.9993
R²	0.9346	0.9978	0.9983	0.9986
TÜM IMF LERİN BİRLEŞTİRİLMESİ SONUCU TAHMİN				
MSE	0.0054			
MAE	0.0563			
R	0.9329			
R²	0.8703			

3.1.5. Tekil Spektrum Analizi-Yapay Sinir Ağları Modeli Kullanarak Veri tahmini


Gerçekleştirilen tez çalışmasında Kızılırmak Nehri Yamula istasyonuna ait aylık akım halindeki hidrolojik verilerin TSA-YSA modeli kullanarak tahmini için gerçekleştirilen işlem adımları Şekil 3.1.21.de de görüldüğü gibi aşağıdaki adımlar ile gerçekleştirilmiştir.

- 1- Hidrolojik veriler eğitim ve test verisi olmak üzere iki gruba ayrılmıştır.
- 2- Eğitim verileri ve test verilerinin kendi içlerinde TSA yöntemi kullanarak alt bileşenlerine (RC_i) ayrıştırılması.
- 3- Eğitim aşamasında eğitim alt bileşenlerinin tahmini ve tahmin sonucu elde edilen bileşenlerin toplanması ile eğitim tahmin sonucunun eldesi
- 4- Eğitim tahmin sonuçlarına göre en iyi tahmini elde etmek üzere YSA yapısının belirlenmesi
- 5- Elde edilen YSA yapısı ile test verisi alt bileşenlerinin tahmini ve tahmin verilerinin toplanması ile test tahmin sonucu




Şekil 3.1.21. Hidrolojik verilerin tahmini için TSA-YSA Modelinin şematik gösterimi

Tez çalışmasının bu aşamasında TSA-YSA modelinde 1 ileri hidrolojik veri tahmini için kullanılacak eğitim ve test verileri diğer model uygulamalarında olduğu gibi ayrıştırılmıştır. Tahmini gerçekleştirilen veriler aylık olduğu için, TSA yöntemi kullanarak 12 altbanta ayrıştırılmıştır. Şekil 3.1.22 de TSA yöntemi ile altbantlara ayrıştırılan veri tahmini için kullanılan altbant verileri görülmektedir.



a



b


Şekil 3.1.22. TSA yöntemi ile alt bantlara ayrıştırılmış **a.** Eğitim Verisi **b.** Test Verisi

TSA-YSA Tahmin çalışmasında kullanılan ağ yapısı; TSA-YSA tahmin çalışmasında hidrolojik verilerin tahmini için daha önceki bölümlerde bahsedilen modellerin performansını karşılaştırabilmek amacıyla öncekilerle aynı ÇKAYSA ağ yapısı kullanılmıştır. Her bir RC_i bileşeni için oluşturulan ÇKAYSA yapısı bir giriş, bir ara katman ve bir çıkış katmanından oluşmaktadır. Ara katmandaki en iyi nöron sayısını belirleyebilmek için MATLAB ortamında nöron sayıları 1 den 9 a kadar iterasyonla artırılmıştır ve ara katmanlardaki nöron sayısı en düşük ortalama karesel hatayı veren nöron sayısı ile belirlenmiştir. Her bir altbant sinyali için ÇKAYSA Levenberg Marquardt geri yayılım algoritması kullanılarak eğitilmiştir ve en iyi YSA'nı belirlemek üzere performans kriteri olarak MSE ve MAE değerleri kullanılmıştır.

Önceki ÇKAYSA modelinde olduğu gibi tahmin verilerin eğitimi için iterasyon sayısı 100 olarak seçilmiştir. Eğitim aşamasında YSA çıkışından elde edilen RC_i alt bileşen tahmin verileri toplanarak hidrolojik verilerin eğitim tahmin verileri elde edilmiştir. Eğitim aşamasında en iyi tahmin sonucunu veren ağ yapısı test aşamasında test verilerinin tahmini için kullanılmıştır. Tez çalışmasında veri tahmini için bir, iki, üç, dört ve beş giriş olmak üzere beş farklı yapı en iyi tahmin çalışması için denenmiştir. Elde edilen tahmin performansları Tablo 3.1.11'de verilmektedir. 3 giriş 1 çıkış YSA modeli ile RC alt bileşenlerin tahmin grafikleri Şekil 3.1.23'te görülmektedir.

Tablo 3.1.11. Yamula istasyonunda aylık akımlar serisi için 1, 2, 3, 4 ve 5 giriş-1 çıkışlı TSA-YSA modelinde alt bileşenlerin test performans değerleri

	RC1	RC2	RC3	RC4	RC5	RC6
1 giriş						
MSE	0.000028	0.001143	0.001347	0.001010	0.001161	0.000599
MAE	0.004088	0.028630	0.031577	0.024807	0.026315	0.018315
R	0.9938	0.8989	0.8720	0.6648	0.5957	0.327
R²	0.987	0.808	0.7605	0.4419	0.3549	0.1074
2 giriş						
MSE	0.000002	0.000009	0.000014	0.000016	0.000010	0.000021
MAE	0.001234	0.002424	0.002957	0.003106	0.002547	0.003430
R	0.999	0.999	0.998	0.995	0.997	0.983
R²	0.999	0.998	0.997	0.991	0.994	0.968
3 giriş						
MSE	0.000005	0.000004	0.000009	0.000009	0.000011	0.000023
MAE	0.001723	0.001692	0.002284	0.002503	0.002694	0.003712
R	0.998	0.999	0.999	0.997	0.996	0.982
R²	0.931	0.999	0.998	0.994	0.993	0.964
4 giriş						
MSE	0.000004	0.000006	0.000009	0.000004	0.000008	0.000009
MAE	0.001636	0.002022	0.002221	0.001574	0.002324	0.002494
R	0.999	0.999	0.999	0.998	0.997	0.992
R²	0.998	0.998	0.998	0.997	0.995	0.985
5 giriş						
MSE	0.000002	0.000004	0.000009	0.000005	0.000007	0.000007
MAE	0.001259	0.001698	0.002267	0.001852	0.002205	0.002065
R	0.999	0.999	0.999	0.998	0.997	0.994
R²	0.999	0.999	0.998	0.997	0.995	0.989
	RC7	RC8	RC9	RC10	RC11	RC12
1 giriş						
MSE	0.000619	0.000201	0.000167	0.000036	0.000028	0.000003
MAE	0.018397	0.011249	0.010547	0.004619	0.004219	0.001530
R	0.3385	0.5491	0.6592	0.8541	0.9019	0.9880
R²	0.1145	0.3016	0.4346	0.7296	0.8135	0.9762
2 giriş						
MSE	0.000009	0.000013	0.000008	0.000005	0.000002	0.000002
MAE	0.002514	0.002668	0.002235	0.001818	0.001108	0.001197
R	0.992	0.976	0.987	0.980	0.992	0.993
R²	0.986	0.953	0.975	0.961	0.985	0.986
3 giriş						
MSE	0.000009	0.000009	0.000004	0.000004	0.000001	0.000001
MAE	0.002628	0.002257	0.001658	0.001574	0.001017	0.000866
R	0.992	0.982	0.992	0.984	0.994	0.996
R²	0.985	0.964	0.985	0.969	0.989	0.992
4 giriş						
MSE	0.000005	0.000010	0.000002	0.000006	0.000002	0.0000009
MAE	0.001784	0.002353	0.001322	0.001827	0.001212	0.000694
R	0.995	0.981	0.995	0.976	0.990	0.997
R²	0.991	0.962	0.990	0.954	0.981	: 0.995
5 giriş						
MSE	0.000006	0.000009	0.000003	0.000005	0.000003	0.000004
MAE	0.001910	0.002388	0.001463	0.001686	0.001421	0.004974
R	0.996	0.982	0.994	0.977	0.991	0.828
R²	0.992	0.964	0.989	0.955	0.982	0.686



Şekil 3.1.23. Altbant bileşenlerine ayrıştırılmış test verileri ve 3 giriş- 1çıkışlı TSA-YSA modeli ile tahmin edilen altbant verileri


Altbant bileşenlerin toplanması ile tahmin verisi elde edilmiştir. 1, 2, 3, 4 ve 5 giriş TSA-YSA modeline ait tahmin performans sonuçları Tablo 3.1.12 de görülmektedir.

Tablo 3.1.12. TSA-YSA modeli ile test sırasında elde edilen tahmin test performans değerleri

	1 giriş	2 giriş	3 giriş	4 giriş	5 giriş
MSE	0.012077	0.000014	0.000008	0.000014	0.000018
MAE	0.075571	0.0090	0.006893	0.008200	0.0105038
R	0.8354	0.998	0.998	0.998	0.997
R²	0.6979	0.996	0.997	0.997	0.995

Tablo 3.1.12 den de görüleceği gibi 3 giriş 1 çıkış TSA-YSA metodu ile oldukça yüksek tahmin performansı ile tahmin işlemi gerçekleştirilmektedir. Şekil 3.1.24 te 3 giriş 1 çıkış TSA-YSA modeli ile elde edilen tahmin verisi görülmektedir.





Şekil 3.1.24 TSA-YSA modeli kullanılarak elde edilen tahmin verisi

3.1.5.1 Tekil Spektrum Analizi-Yapay Sinir Ağları Yöntemi ile 1-6 ileri Tahmin

Tez çalışmasının bu aşamasında 3 giriş-1 çıkış TSA-YSA yöntemi ile 1-6 ileri tahmin çalışması gerçekleştirilmiştir. Ayrıca 3 giriş 1 çıkış YSA modeli ile de 1-6 ileri tahmin işlemi gerçekleştirilerek önerilen modelin performansı karşılaştırılmıştır. 1-6 ileri tahmin için TSA-YSA modeli ile elde edilen sonuçlar Tablo 3.1.13 te verilmiştir.

Tablo 3.1.13. Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkış TSA-YSA modeli ile 1-6 ileri tahmin test performans değerleri

	1 ileri	2 ileri	3 ileri
MSE	0.000008	0.00027	0.0006
MAE	0.006893	0.013055	0.019825
R	0.998	0.996	0.992
R²	0.997	0.993	0.985
	4 ileri	5 ileri	6 ileri
MSE	0.001149	0.0018815	0.001383
MAE	0.02469	0.031455	0.028238
R	0.976	0.941	0.983
R²	0.962	0.886	0.968

1-6 ileri tahmin için 3 giriş 1 çıkış YSA modeli ile elde edilen sonuçlar Tablo 3.1.14 te verilmiştir.

Tablo 3.1.14. Yamula istasyonunda aylık akımlar serisi için 3 giriş-1 çıkış YSA modeli ile 1-6 ileri tahmin test performans değerleri

	1 ileri	2 ileri	3 ileri
MSE	0.0322	0.036878	0.027888
MAE	0.0894	0.126123	0.109796
R	0.6357	0.423	0.567
R²	0.4041	0.179	0.3221
	4 ileri	5 ileri	6 ileri
MSE	0.035224	0.031736	0.103693
MAE	0.110369	0.103580	0.153468
R	0.465	0.547	0.136364
R²	0.216	0.299	0.018


Tablo 3.1.13 ve Tablo 3.1.14. incelendiğinde TSA-YSA modelinin performansı 1-6 ileri tahmin işleminde YSA modeline göre oldukça iyi olduğu görülmektedir [104].

Tez çalışmasının bu aşamasında; Kızılırmak nehri Yamula istasyonundan elde edilen aylık akım verilerinin tahmini için ÖB, ÖBHA, YSA, AKA-YS, TSA-AKA-YS ve TSA-YS modelleri uygulanmıştır. Bu verileri için uygulanan modellerin performansı Tablo 3.1.15'te ve Şekil 3.1.25 te görülmektedir.

Tablo 3.1.15. Yamula istasyonunda aylık akımlar serisi için verilerin tahmininde ÖB, ÖBHA, YSA, AKA-YS, TSA-AKA-YS, TSA-AKA modellerinin 1 ileri tahmin performans değerleri

	MSE	MAE	R	R²
ÖB(12)	0.0113	0.0586	0.8445	0.7131
ÖBHO(26,27)	0.0097	0.0602	0.8687	0.7546
YS	0.0188	0.0816	0.7359	0.5416
AKA-YS (3 giriş 1 çıkış 1 arakatman)	0.0092	0.0645	0.8786	0.7719
TSA-AKA-YS (3 giriş 1 çıkış 1 arakatman)	0.0054	0.0563	0.9329	0.8703
TSA-YS (3 giriş 1 çıkış, 1 arakatman)	0.000008	0.006893	0.998	0.997


Tablo 3.1.15 ve Şekil 3.1.25 incelendiğinde tahmin çalışmasında kullanılan modellerden TSA-YS modelinin performansının diğer modellere göre daha iyi olduğu görülmektedir.



Şekil 3.1.25. Hidrolojik veri tahmininde ÖB, ÖBHA, YSA, AKA-YSA, TSA-AKA-YSA, TSA-AKA modellerinin performans değerleri

3.2. Meriç Havzası Şeytan Deresine ait Hidrolojik Verilerin Tahmin Çalışması

Tez çalışmasında Meriç havzasında bulunan Şeytan deresinden 1-101 nolu istasyondan alınan günlük kesikli verilerin tahmini üzerine çalışılmıştır. Şeytan deresine ait normalize 12774 adet veriden oluşan günlük akımlar hidrolojik zaman serisi verileri Şekil 3.2.1 de görülmektedir.



Şekil 3.2.1. Şeytan deresine ait hidrolojik zaman verileri


Bu verilerin tahmini için YSA, AKA-YSA, TSA-AKA-YSA ve TSA-YSA modelleri kullanılmıştır. Verilerin tahmininde YSA ile tahmin aşamasında farklı giriş değerleri için modellerin tahmin performansı denenmiş ve dört giriş 1 çıkışlı modelde tahmin performansının yüksek olduğu görülmüştür. Bu nedenle verilerin tahmin aşamasında YSA'na dört giriş uygulanmıştır.

YSA modeli ile tahmin çalışması;


Kesikli hidrolojik verilerin tahmininde önerilen modellerin performansını karşılaştırmak amacıyla hidrolojik zaman verileri YSA kullanılarak tahmin edilmeye çalışılmıştır.

Şeytan deresinden elde edilen günlük debi (m^3/sn) verilerin normalize edilmesinden sonra dört giriş kullanılarak bir ileri, iki ileri ve üç ileri zamanlı tahminine çalışılmıştır. Tahmin işlemi için öncelikle, hidrolojik veriler eğitim ve test verileri olarak Şekil 3.2.2

de görüldüğü gibi iki gruba ayrılmıştır. Eğitim verisi, veri setinin ilk 8000 veri içeren kısmı olarak seçilmiştir. Test verisi ise kalan 4774 veri içeren kısmı olarak seçilmiştir.



a



b

Şekil 3.2.2 a. Eğitim, b. Test için kullanılan hidrolojik gözlem verileri

Tahmin aşamasında, çalışması için tez çalışmasının önceki bölümlerinde de kullanılan çok katmanlı ağ yapısı kullanılmıştır. ÇKAYSA yapısı en iyi tahmin performansını

vermek üzere dört giriş, iki ara katman ve bir çıkış katmanından oluşacak şekilde belirlenmiştir. Ara katmanlardaki en iyi nöron sayısını belirleyebilmek için ara katmanların nöron sayıları 1 den 9 a kadar artırılmıştır ve ara katmanlardaki nöron sayısı en düşük ortalama karesel hatayı veren nöron sayısı ile belirlenmiştir. YSA, Levenberg Marquardt geri yayılım algoritması kullanılarak eğitilmiştir. YSA da performans kriteri olarak ortalama karesel hata ve ortalama mutlak hata kullanılmıştır.

Bir ileri zamanlı veri tahmini için YSA'na giriş verileri $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, çıkış verileri de $x(t+1)$ olmuştur. Dolayısı ile eğitim ve test için kullanılan giriş özniteik sayısı dört olarak belirlenmiştir ve bir ileri zamanlı tahmin işlemi gerçekleştirilmiştir.


İki ileri zamanlı veri tahmini için YSA'na giriş verileri $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, çıkış verileri de $x(t+2)$ olmuştur.

Üç ileri zamanlı veri tahmini için YSA'na giriş verileri $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, çıkış verileri de $x(t+3)$ olmuştur.


Tablo 3.2.1 de YSA kullanılarak tahmin işlemi performans sonuçları görülmektedir. Ayrıca bir, iki ve üç ileri zamanlı tahmin işlemi neticesinde elde edilen tahmin verilerine ait grafikler Şekil 3.2.3,4 ve 5 de görülmektedir.

Tablo 3.2.1. Şeytan Deresi günlük akım hidrolojik zaman verilerinin YSA modeli ile tahmin sonuçları


	MSE		MAE	
	EĞİTİM	TEST	EĞİTİM	TEST
Bir ileri zamanlı tahmin	5.12×10^{-4}	3.91×10^{-4}	0.0066	0.0053
İki ileri zamanlı tahmin	7.10×10^{-4}	4.78×10^{-4}	0.0077	0.0063
Üç ileri zamanlı tahmin	7.43×10^{-4}	5.20×10^{-4}	0.0109	0.0093
	R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST
Bir ileri zamanlı tahmin	0.7395	0.6985	0.6085	0.5810
İki ileri zamanlı tahmin	0.6029	0.6068	0.3959	0.3772
Üç ileri zamanlı tahmin	0.5610	0.5522	0.1435	0.1471



Şekil 3.2.3. Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli YSA modeli ile *bir* ileri zamanlı tahmin verileri




Şekil 3.2.4. Şeytan Deresi günlük akım için gözlemlenmiş akımlar ve dört girişli YSA modeli ile *iki* ileri zamanlı tahmin verileri




Şekil 3.2.5. Şeytan Deresi günlük akım için gözlemlenmiş akımlar ve dört girişli YSA modeli ile üç ileri zamanlı tahmin verileri

AKA-YSA Modeli ile Tahmin Çalışması

Şeytan deresine ait kesikli verilerin tahmini için AKA-YSA modeli kullanılmıştır. Eğitim ve test verileri AKA metodu ile şekil 3.2.6 da görüldüğü gibi 13 adet IMF bileşenlerine ayrılmıştır.





b

Şekil 3.2.6. a.Eğitim için kullanılan 13 adet IMF bileşeni, b.Test için kullanılan 13 adet IMF bileşeni

Elde edilen IMF bileşenlerinin tahmini için yukarıda bahsedilen yaklaşımı sergileyerek YSA tasarlanmıştır. Her bir IMF için olmak üzere toplam 13 adet YSA Levenberg Marquardt geri yayılım algoritması kullanılarak eğitilmiştir.

Bir ileri zamanlı veri tahmini:

Burada YSA giriş verileri her bir IMF için $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, veri tahmini için kullanılan çıkış verileri de $x(t+1)$ olmuştur. Dolayısı ile eğitim ve test için kullanılan giriş öznitelik sayısı dört olarak belirlenmiştir ve bir ileri zamanlı tahmin işlemi gerçekleştirilmiştir. Tablo 3.2.2.a da eğitim ve test süresince, her bir IMF bileşeninin tahmini sırasında elde edilen MSE, MAE, R ve R^2 değerleri görülmektedir.

Tablo 3.2.2. a.Şeytan Deresi günlük akım hidrolojik verilerinin *bir ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları*


	MSE		MAE		R		R^2	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF1	2.49×10^{-4}	2.32×10^{-4}	0.0074	0.0063	0.884	0.8457	0.614	0.672
IMF2	9.17×10^{-4}	9.86×10^{-4}	0.0049	0.0052	0.6138	0.4002	0.585	0.395
IMF3	3.94×10^{-5}	7.90×10^{-5}	0.0032	0.0038	0.8310	0.7140	0.725	0.627
IMF4	1.67×10^{-5}	3.97×10^{-5}	0.0033	0.0030	0.9744	0.7791	0.957	0.764
IMF5	1.06×10^{-5}	1.48×10^{-4}	0.0024	0.0051	0.9813	0.7881	0.815	0.762
IMF6	1.78×10^{-5}	9.14×10^{-4}	0.0019	0.0020	0.9107	0.9313	0.808	0.874
IMF7	4.76×10^{-6}	2.29×10^{-4}	0.0014	0.0026	0.9672	0.9031	0.972	0.747
IMF8	2.36×10^{-5}	1.79×10^{-5}	0.0021	0.0023	0.9590	0.9131	0.960	0.808
IMF9	8.76×10^{-6}	4.87×10^{-5}	0.0019	0.0035	0.9455	0.8966	0.7656	0.734
IMF10	6.60×10^{-6}	6.70×10^{-6}	9.32×10^{-4}	0.0018	0.9659	0.9634	0.9783	0.965
IMF11	2.00×10^{-5}	3.31×10^{-6}	0.0013	0.0032	0.9375	0.9313	0.960	0.951
IMF12	2.66×10^{-5}	7.94×10^{-6}	0.0021	0.0021	0.9540	0.9732	0.983	0.978
IMF13	8.22×10^{-7}	4.63×10^{-7}	6.18×10^{-4}	4.90	0.9963	0.9971	0.908	0.929

Tablo 3.2.2.a dan da görüldüğü gibi, IMF2 dışında tüm IMF lerin tahmini başarılı olmuştur. Tahmin edilen veriler, YSA çıkışında alınan 13 adet IMF lerin toplanması ile elde edilmiştir. YSA ile tahmin edilen IMF verilerinin tamamı toplanarak, bir adet tahmin verisi elde edilmiştir. Tablo 3.2.2.b de YSA eğitim ve test sırasında IMF verilerinin toplanması sonucu elde edilen tahmin verisine ait MSE, MAE, R ve R^2 değerleri görülmektedir. Ayrıca önerilen model ile elde edilen tahmin ve gözlem verileri Şekil 3.2.7 de görülmektedir. Tahmin edilen IMF bileşenlerinin toplanması sonucu elde

edilen tahmin verilerine ait performans değerleri, Tablo 3.2.2.b. de yer almaktadır. Bu sonuçlara bakıldığında; tahmin edilen veri ile orijinal veri arasındaki MSE değeri 4.15×10^{-4} , MAE değeri 0.0104, R değeri 0.7384 ve R^2 değeri 0.6168 olarak elde edilmiştir.


Tablo 3.2.2.b.Şeytan Deresi günlük akım hidrolojik verilerin *bir* ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları

	Tüm IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	3.80×10^{-4}	4.15×10^{-4}
MAE	0.0089	0.0104
R	0.7384	0.7892
R^2	0.6168	0.7761



Şekil 3.2.7. Şeytan Deresi günlük akım için gözlenmiş akımlar ve dört girişli AKA-YSA modeli ile **bir** ileri zamanlı tahmin verileri


Tablo 3.2.2.a dan görüleceği üzere, IMF2 bileşeninin tahmini başarısı diğer bileşenlere göre daha düşük olduğu görülmektedir. Bu nedenle tahmin performansının iyileştirilmesi için IMF2 bileşenine ön işlem olarak ayrıca TSA tekniği uygulanmıştır. Verinin IMF2 bileşeni, TSA tekniği ile Şekil 3.2.8 de görüldüğü gibi yeniden yapılandırılmıştır ve bu yeniden yapılandırılan IMF2 bileşeni kullanılarak test verisi tahmin edilmeye çalışılmıştır. Elde edilen sonuçlar Tablo 3.2.3 de görülmektedir. Yeniden yapılandırılmış IMF verisi ile elde edilen tahmin grafiği Şekil 3.2.9 da görülmektedir.



Şekil 3.2.8. Şeytan Deresi günlük akım serisi için IMF2 verisi ve TSA yöntemi ile yeniden yapılandırılmış IMF2 verisi

Tablo 3.2.3. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin *bir* ileri zamanlı tahminine ait performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile tahmin performans değerleri

	MSE		MAE		R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF2+ TSA	3.40×10^{-6}	8.73×10^{-6}	0.0015	0.0015	0.9397	0.9721	0.7627	0.7745
Tüm IMF Bileşenlerinin toplanması sonucu elde edilen bir ileri zamanlı tahmin								
	TEST					EĞİTİM		
MSE	2.90×10^{-4}					3.73×10^{-4}		
MAE	0.0077					0.0097		
R	0.8214					0.8079		
R ²	0.7021					0.7103		



Şekil 3.2.9. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve TSA-AKA-YSA modeli ile elde edilen bir ileri zamanlı tahmin grafiği

Bu sonuçlara, göre bir ileri zamanlı tahmin işleminde, AKA-YSA modeli ile yapılan tahmin işlemi neticesinde 0.7384 olarak elde edilen R değeri, tahmin performansı düşük olan IMF bileşenine TSA tekniğinin de birleştirilmesi ile 0.8214'e artırılmıştır. R^2 değeri ise 0.6168 den 0.7021 e artırılmıştır. MSE değeri 3.80×10^{-4} iken 2.90×10^{-4} değerine düşmüştür. MAE değeri ise 0.089 iken 0.0077 değerine düşmüştür. Buradan IMF2 bileşeninin tahminin iyileştirilmesi ile toplam tahminde iyileşme olduğu görülmektedir.

İki ileri zamanlı veri tahmini:

Burada YSA giriş verileri her bir IMF için $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, veri tahmini için kullanılan çıkış verileri de $x(t+2)$ olmuştur. Eğitim ve test için kullanılan giriş öznitelik sayısı dört olarak belirlenmiştir. Tablo 3.2.4.a da Eğitim ve test süresince her bir IMF bileşeninin tahmini sırasında elde edilen MSE, MAE ,R ve R^2 değerleri görülmektedir. Ayrıca önerilen metod ile elde iki ileri zamanlı tahmin ve gözlemlenen veriler Şekil 3.2.10 da görülmektedir. Tahmin edilen IMF verilerinin toplanması sonucu oluşan tahmin verisine ait performans değerleri Tablo 3.2.4.b de görülmektedir.


Tablo 3.2.4. a. Şeytan Deresi günlük akım serisi verilerinin *iki ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları*

	MSE		MAE		R		R^2	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF1	6.15×10^{-4}	3.51×10^{-4}	0.0098	0.0073	0.6791	0.7532	0.5637	0.62055
IMF2	0.14×10^{-5}	2.11×10^{-4}	0.0073	0.0070	0.4672	0.4822	0.2481	0.2948
IMF3	5.49×10^{-5}	4.86×10^{-5}	0.0051	0.0049	0.7783	0.8433	0.4838	0.5040
IMF4	3.13×10^{-5}	2.09×10^{-5}	0.0028	0.0022	0.8977	0.8794	0.640	0.5679
IMF5	3.91×10^{-5}	0.43×10^{-4}	0.0059	0.0060	0.9829	0.9841	0.7836	0.7798
IMF6	2.20×10^{-5}	6.19×10^{-6}	0.0028	0.0017	0.8869	0.9230	0.7599	0.7762
IMF7	0.13×10^{-6}	7.52×10^{-6}	0.0022	0.0017	0.9075	0.9551	0.9287	0.7474
IMF8	4.25×10^{-5}	0.44×10^{-5}	0.0031	0.0014	0.9245	0.9698	0.7187	0.7377
IMF9	2.17×10^{-6}	0.74×10^{-5}	0.0010	0.0016	0.9743	0.9814	0.9589	0.9691
IMF10	8.11×10^{-6}	0.57×10^{-6}	0.12×10^{-4}	5.89×10^{-4}	0.9577	0.9914	0.9576	0.9890
IMF11	2.20×10^{-5}	1.30×10^{-6}	0.15×10^{-4}	8.33×10^{-4}	0.9315	0.9957	0.9415	0.959
IMF12	1.52×10^{-6}	2.04×10^{-7}	9.92×10^{-4}	3.41×10^{-4}	0.9982	0.9986	0.9876	0.9882
IMF13	8.74×10^{-7}	4.70×10^{-7}	6.35×10^{-4}	4.98×10^{-4}	0.9961	0.9970	0.9290	0.9081

Tablo 3.2.4.b Şeytan Deresi günlük akım serisi verilerinin *iki* ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları

	Tüm IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	5.078×10^{-4}	8.02×10^{-4}
MAE	0.0119	0.0144
R	0.7116	0.6608
R²	0.5642	0.5427

Tablo 3.2.4.b. den de görüleceği üzere *iki* ileri zamanlı tahmin işleminde test verisi için R ve R² değerleri bir ileri zamanlı tahmin sonucuna göre daha düşük, MSE ve MAE değerleri daha yüksek çıkmıştır.




Şekil 3.2.10. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve dört girişli AKA-YSA modeli ile *iki* ileri model ile tahmin edilmiş verileri

Gürültü bileşenini de içeren IMF2 bileşeninde gürültü eliminasyonu yapmak üzere bir ileri zamanlı tahminde olduğu gibi TSA analizi uygulanarak, Şekil 3.2.11 de görüldüğü gibi yeniden yapılandırılmıştır ve elde edilen tahmin performans sonuçları Tablo 3.2.5 de yer almaktadır.

Tablo 3.2.5. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin *iki* ileri zamanlı tahmin performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile *iki* ileri zamanlı tahmin performans sonuçları

	MSE		MAE		R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF2+ TSA	1.61×10^{-5}	1.59×10^{-5}	0.0015	0.0019	0.8697	0.9721	0.8442	0.9036
	Tüm IMF Bileşenlerinin toplanması sonucu elde edilen bir ileri zamanlı tahmin							
	TEST					EĞİTİM		
MSE	3.95×10^{-4}					6.40×10^{-4}		
MAE	0.0090					0.0113		
R	0.7424					0.6825		
R²	0.5990					0.5670		

Tablo 3.2.5 den de görüleceği üzere tüm IMF lerin toplanması sırasında IMF2 nin YSA ile tahmini yerine yerine TSA uygulanmış IMF verisinin tahmin sonuçları ile elde edilen performans artmaktadır.



Şekil 3.2.11. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve TSA-AKA-YSA modeli ile elde edilen *iki ileri zamanlı tahmin* grafiği

Üç ileri zamanlı veri tahmini:

Burada da IMF bileşenlerinin tahmini için YSA'na uygulanan giriş verileri $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$ iken, veri tahmini için kullanılan çıkış verileri de $x(t+3)$ olmuştur.

Tablo 3.2.6.a da Eğitim ve Test süresince her bir IMF bileşeninin tahmini sırasında elde edilen MSE, MAE, R ve R^2 değerleri görülmektedir. Ayrıca önerilen model ile elde edilen üç ileri zamanlı tahmin ve gerçek veriler Şekil 3.2.12. de görülmektedir.

Üç ileri zamanlı tahmin verisi üç ileri zamanlı IMF tahmin verilerinin toplanması sonucu elde edilmiştir. Modelin tahmin performans sonuçları Tablo 3.2.6.b de yer almaktadır.


Tablo 3.2.6. a. Şeytan Deresi günlük akım serisi için üç ileri zamanlı tahmin için 4 girişli AKA-YSA modeli ile tahmin edilen IMF'lerin eğitim ve test performans sonuçları

	MSE		MAE		R		R^2	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF1	7.77×10^{-4}	4.51×10^{-4}	0.0116	0.0091	0.5558	0.6635	0.4594	0.4634
IMF2	1.62×10^{-4}	2.90×10^{-4}	0.0072	0.0074	0.5022	0.3506	0.3038	0.2187
IMF3	6.78×10^{-5}	7.42×10^{-5}	0.0059	0.0060	0.7577	0.7718	0.5747	0.5854
IMF4	4.19×10^{-5}	3.82×10^{-5}	0.0052	0.0051	0.9281	0.8997	0.7230	0.6844
IMF5	2.37×10^{-5}	4.64×10^{-5}	0.0031	0.0037	0.9525	0.9400	0.7966	0.7531
IMF6	5.46×10^{-5}	1.12×10^{-5}	0.0039	0.0022	0.6865	0.8552	0.6177	0.7278
IMF7	1.22×10^{-5}	1.18×10^{-5}	0.0020	0.0019	0.9334	0.9525	0.7816	0.8291
IMF8	1.02×10^{-5}	1.31×10^{-6}	0.0016	0.0008	0.9823	0.9952	0.8961	0.9549
IMF9	4.10×10^{-6}	1.17×10^{-5}	0.0013	0.0021	0.9504	0.9700	0.9285	0.9712
IMF10	1.02×10^{-5}	8.89×10^{-7}	0.0015	0.0007	0.9460	0.9863	0.9014	0.9490
IMF11	2.41×10^{-5}	1.65×10^{-6}	0.0017	0.0009	0.9247	0.9943	0.9185	0.9866
IMF12	3.85×10^{-5}	3.00×10^{-7}	0.0027	0.0004	0.9318	0.9971	0.8814	0.9262
IMF13	9.52×10^{-7}	4.95×10^{-7}	0.0006	0.0005	0.9958	0.9968	0.9179	0.9203

Tablo 3.2.6. b. Şeytan Deresi günlük akım serisi için üç ileri zamanlı tahmin için 4 girişli AKA-YSA modeline ait performans sonuçları

	Tüm IMF Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	5.22×10^{-4}	8.03×10^{-4}
MAE	0.0107	0.0136
R	0.6578	0.6304
R²	0.4830	4576

Tablo 3.2.6.b den de görüleceği üzere üç ileri zamanlı tahmin işleminde test verisi için performans değerleri bir ve iki ileri zamanlı tahmin sonucuna göre daha düşük çıkmıştır. Ayrıca veride salınımın yüksek olduğu IMF bileşenlerinin tahmininde elde edilen sonuçlar bir ve iki ileri zamanlı veri tahmininde olduğu gibi diğer bileşenlere göre daha düşük çıkmıştır.



Şekil 3.2.12. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve dört girişli AKA-YSA modeli ile üç ileri zamanlı tahmin verileri

Tahmin sonucu diğer IMF lere göre performansı daha düşük çıkan IMF2 bileşeninin tahmin performansını iyileştirmek üzere uygulanan TSA analizi elde edilen tahmin performans sonuçları Tablo 3.2.7 de yer almaktadır.

Tablo 3.2.7. Şeytan Deresi günlük akım serisi için TSA analizi ile yeniden yapılandırılan IMF2 bileşeninin üç ileri zamanlı tahmin performans sonuçları ve hidrolojik verinin TSA-AKA-YSA modeli ile tahmin performans sonuçları

	MSE		MAE		R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
IMF2+ TSA	1.91×10^{-5}	2.57×10^{-5}	0.0033	0.0034	0.9107	0.9579	0.8210	0.8548
Tüm IMF Bileşenlerinin toplanması sonucu elde edilen bir ileri zamanlı tahmin								
	TEST					EĞİTİM		
MSE	5.0430×10^{-4}					7.6802×10^{-4}		
MAE	0.0133					0.0155		
R	0.6862					0.6404		
R²	0.5248					0.5098		


Tablo 3.2.7 den de görüleceği üzere üç ileri zamanlı tahminde test verisi için R değeri 0.6862, R² değeri 0.5248, MSE değeri 5.04×10^{-4} ve MAE değeri 0.0133 olarak elde edilmiştir [105].


TSA-YSA Modeli ile tahmin çalışması;

Tez çalışmasında önerilen diğer bir yöntem olan TSA-YSA modelinin tahmin performansını analiz etmek amacıyla kesikli hidrolojik verilerin tahmin işlemi gerçekleştirilmiştir. Eğitim ve test için kullanılan hidrolojik veriler TSA yöntemi ile 12 altbant sinyaline Şekil 3.2.13 de görüldüğü gibi ayrıştırılmıştır ve her bir alt bant sinyaline RC1-RC12 isimleri verilmiştir. RCi altbant sinyalleri YSA kullanılarak tahmin edildikten sonra altbant tahmin verileri toplanarak toplam tahmin verisi TSA-YSA modeli ile elde edilmiştir. Altbant YSA giriş verileri her bir AKA-YSA modelinde olduğu gibi belirlenmiştir. Tablo 3.2.8.a da eğitim ve test süresince her bir RC bileşeninin bir ileri zamanlı tahmini sırasında elde edilen ortalama karesel hata, mutlak hata ve korelasyon katsayısı değerleri görülmektedir. Ayrıca tahmin edilen altbileşenlerinin toplanması sonucu elde edilen bir ileri tahmin verisine ait performans

değerleri de Tablo 3.2.8.b de verilmektedir. Bir ileri zamanlı tahmin aşamasında elde edilen tahmin ve gözlem grafiği Şekil 3.2.14. de görülmektedir. TSA-YSA modeli ile elde edilen *iki* ve *üç* ileri tahmin aşamasında altbant verilerinin tahmin performans değerleri sırasıyla Tablo 3.2.9.a ve Tablo 3.2.10.a. da görülmektedir. İki ve üç ileri tahmin çalışmasında tahmin edilen altbantların toplanması ile elde edilen tahmin verisine ait performans değerleri Tablo 3.2.9.b. ve Tablo 3.2.10.b. de, gözlem ve tahmin verisi ise Şekil 3.2.15. ve Şekil 3.2.16. da görülmektedir.



**a**



b


Şekil 3.2.13. TSA yöntemi ile alt bantlara ayrıştırılmış **a.** Eğitim Verisi **b.** Test Verisi

Tablo 3.2.8. a. Şeytan Deresi günlük akım serisi için *bir* ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları

	MSE		MAE		R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
RC1	6.85×10^{-6}	5.86×10^{-6}	0.0016	0.00014	0.9956	0.9939	0.991	0.987
RC2	6.86×10^{-5}	3.80×10^{-5}	0.0039	0.00031	0.9698	0.9922	0.911	0.935
RC3	1.18×10^{-5}	6.98×10^{-6}	0.0013	9.23×10^{-4}	0.8521	0.8668	0.726	0.751
RC4	2.29×10^{-5}	7.48×10^{-6}	0.0018	0.00015	0.8636	0.7908	0.917	0.925
RC5	7.57×10^{-6}	4.78×10^{-6}	0.0010	8.42×10^{-4}	0.7895	0.7962	0.623	0.634
RC6	3.16×10^{-6}	1.78×10^{-6}	5.73×10^{-4}	3.82×10^{-4}	0.8884	0.8440	0.789	0.712
RC7	2.06×10^{-5}	3.50×10^{-6}	0.0012	4.87×10^{-4}	0.7418	0.7867	0.5321	0.544
RC8	2.28×10^{-5}	2.87×10^{-6}	9.69×10^{-4}	5.76×10^{-4}	0.3208	0.5594	0.102	0.312
RC9	6.70×10^{-5}	4.05×10^{-6}	0.0014	9.69×10^{-4}	0.7199	0.7283	0.448	0.483
RC10	4.9×10^{-6}	2.85×10^{-6}	0.0011	9.50×10^{-4}	0.4253	0.4776	0.180	0.228
RC11	4.53×10^{-6}	5.07×10^{-6}	7.71×10^{-4}	6.73×10^{-4}	0.6630	0.6150	0.726	0.713
RC12	4.23×10^{-6}	5.24×10^{-6}	0.0013	0.00013	0.7736	0.7876	0.598	0.620

Tablo 3.2.8. b. Şeytan Deresi günlük akım serisi *bir* ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları

	Tüm RC Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	1.28×10^{-4}	2.10×10^{-4}
MAE	0.0053	0.0071
R	0.9672	0.9623
R ²	0.9375	0.9616




Şekil 3.2.14. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve dört girişli TSA-YSA modeli ile *bir* ileri zamanlı tahmin verileri

Tablo 3.2.9. a. Şeytan Deresi günlük akım serisi için *iki* ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları

	MSE		MAE		R		R ²	
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
RC1	1.40×10^{-5}	2.06×10^{-4}	0.00033	0.0054	0.9961	0.7145	0.989	0.992
RC2	6.12×10^{-5}	1.72×10^{-4}	0.00032	0.0093	0.560	0.419	0.488	0.403
RC3	8.37×10^{-5}	5.81×10^{-5}	0.00025	0.0034	0.6620	0.6626	0.349	0.068
RC4	3.94×10^{-6}	6.54×10^{-5}	8.94×10^{-4}	0.0035	0.9235	0.8566	0.862	0.852
RC5	6.47×10^{-5}	5.12×10^{-5}	0.00016	0.0031	0.8457	0.6975	0.694	0.715
RC6	6.57×10^{-6}	3.27×10^{-5}	0.0011	0.0026	0.7817	0.8950	0.612	0.611
RC7	1.25×10^{-5}	1.27×10^{-5}	0.0015	0.0019	0.5964	0.577	0.546	0.446
RC8	2.53×10^{-6}	1.05×10^{-5}	0.0010	0.0018	0.8681	0.8783	0.793	0.753
RC9	6.54×10^{-6}	2.16×10^{-5}	8.91×10^{-4}	0.0023	0.877	0.7577	0.773	0.627
RC10	5.50×10^{-6}	8.10×10^{-6}	7.41×10^{-4}	0.0017	0.6251	0.765	0.682	0.715
RC11	4.52×10^{-6}	5.29×10^{-6}	7.68×10^{-4}	0.0016	0.7265	0.6553	0.683	0.615
RC12	2.94×10^{-6}	3.19×10^{-6}	0.0014	0.0014	0.9153	0.9055	0.839	0.837

Tablo 3.2.9.b. Şeytan Deresi günlük akım serisi için *iki* ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları

	Tüm RC Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	1.93×10^{-4}	2.65×10^{-4}
MAE	0.0060	0.0068
R	0.8717	0.8759
R²	0.8616	0.8685




Şekil 3.2.15. Şeytan Deresi günlük akım serisi için gözlemlenmiş akımlar ve dört girişli TSA-YSA modeli ile *iki* ileri zamanlı tahmin verileri

Tablo 3.2.10. a. Şeytan Deresi günlük akım serisi için üç ileri zamanlı tahmin için 4 girişli TSA-YSA modeli ile tahmin edilen RC'lerin eğitim ve test performans sonuçları

	MSE		MAE		R			
	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST	EĞİTİM	TEST
RC1	1.48×10^{-5}	4.67×10^{-4}	0.0032	0.0116	0.9934	0.9825	0.9886	0.9877
RC2	6.24×10^{-5}	4.92×10^{-5}	0.0033	0.0022	0.476	0.445	0.439	0.436
RC3	1.97×10^{-5}	0.0012	0.0020	0.0035	0.7346	0.6213	0.6960	0.6884
RC4	6.92×10^{-6}	4.71×10^{-4}	9.20×10^{-4}	0.0021	0.8529	0.676	0.8034	0.7074
RC5	8.18×10^{-6}	1.34×10^{-4}	0.0014	0.0012	0.7417	0.6564	0.7394	0.5920
RC6	6.33×10^{-6}	5.49×10^{-6}	0.0015	7.78×10^{-4}	0.8202	0.6290	0.5911	0.4944
RC7	9.79×10^{-6}	4.85×10^{-6}	0.0017	6.77×10^{-4}	0.4644	0.4839	0.4706	0.4836
RC8	2.10×10^{-6}	3.65×10^{-6}	0.0011	5.37×10^{-4}	0.6986	0.6720	0.6311	0.6283
RC9	6.52×10^{-6}	5.70×10^{-6}	8.38×10^{-4}	7.31×10^{-4}	0.6372	0.5861	0.6311	0.6283
RC10	5.21×10^{-6}	3.10×10^{-6}	8.01×10^{-4}	5.76×10^{-4}	0.5738	0.3718	0.4060	0.2992
RC11	4.41×10^{-6}	4.96×10^{-6}	7.61×10^{-4}	6.64×10^{-4}	0.6520	0.6045	0.6448	0.461
RC12	5.61×10^{-6}	6.97×10^{-6}	8.35×10^{-4}	7.60×10^{-4}	0.6464	0.5912	0.6492	0.6053

Tablo 3.2.10. b. Şeytan Deresi günlük akım serisi için üç ileri zamanlı tahmin için 4 girişli TSA-YSA modeline ait performans sonuçları

	Tüm RC Bileşenlerinin toplanması sonucu elde edilen tahmin verisi	
	TEST	EĞİTİM
MSE	2.25×10^{-4}	2.85×10^{-4}
MAE	0.0072	0.0078
R	0.8605	0.8771
R ²	0.8404	0.8494







Şekil 3.2.16. Şeytan Deresi günlük akım serisi için gözlenmiş ve dört girişli TSA-YSA modeli ile *üç* ileri zamanlı tahmin verileri

Tez çalışmasının bu aşamasında kesikli verilerin bir, iki ve üç ileri tahmini için YSA, AKA-YSA, TSA-AKA-YSA ve TSA-YSA modelleri kullanılmıştır. Bu modellerin test tahmin performansları Tablo 3.2.12 de verilmektedir. Ayrıca Şekil 3.2.17.a.,b.,c. de modellerin MSE, MAE, R ve R² performans değerleri görülmektedir.

Tablo 3.2.11. Şeytan deresine ait hidrolojik veri tahmininde YSA, AKA-YSA, TSA-AKA-YSA, TSA-AKA modellerinin *bir, iki ve üç* ileri tahmin performans değerleri

	MSE	MAE	R	R ²
1 ileri tahmin				
YSA	3.91×10^{-4}	0.0066	0.6985	0.5810
AKA-YSA	3.80×10^{-4}	0.0089	0.7384	0.6168
TSA-AKA-YSA	2.90×10^{-4}	0.0077	0.8214	0.7021
TSA-YSA	1.28×10^{-4}	0.0053	0.9672	0.9375
2 ileri tahmin				
YSA	4.78×10^{-4}	0.0063	0.6068	0.3772
AKA-YSA	5.08×10^{-4}	0.0119	0.7116	0.5642
TSA-AKA-YSA	3.95×10^{-4}	0.0090	0.7424	0.5990
TSA-YSA	1.93×10^{-4}	0.0060	0.8717	0.8616
3 ileri tahmin				
YSA	5.20×10^{-4}	0.0093	0.5522	0.1471
AKA-YSA	5.22×10^{-4}	0.0107	0.6575	0.4830
TSA-AKA-YSA	5.04×10^{-4}	0.0133	0.6862	0.5245
TSA-YSA	2.245×10^{-4}	0.0072	0.8605	0.8404

**a****b****c**




Şekil 3.2.17. Şeytan deresine ait hidrolojik verilerin tahmininde YSA, AKA-YSA, TSA-AKA-YSA ve TSA-YSA modellerinin bir, iki, üç ileri zamanlı tahmin performans parametrelerini gösteren; **a.** MSE değerleri **b.** MAE değerleri **c.** R değerleri **d.** R^2 değerleri

Yukarıda verilen tablolardan görüleceği üzere önerilen TSA-YSA modelinde bir, iki ve üç ileri veri tahmini için elde edilen korelasyon katsayıları diğer modellere göre en yüksek değerde, sırası ile 0.9672, 0.8717 ve 0.8605 olarak elde edilmiştir. R^2 değeri ise sırası ile 0.9375, 0.8616 ve 0.8404 olarak elde edilmiştir. MSE değerleri ise diğer modellere göre en düşük değerde, 1.28×10^{-4} , 1.93×10^{-4} , 2.2452×10^{-4} olarak elde edilmiştir. MAE değerleri de MSE değerleri gibi diğer modellere göre en düşük değerde 0.0053, 0.0060 ve 0.0072 olarak elde edilmiştir. Bu sonuçlara göre TSA-YSA modelinin tahmin performansı diğer modellere göre oldukça iyi olduğu görülmektedir.


3.3. Eğirdir Gölüne ait Su Seviyesini Gösteren Hidrolojik Verilerin Tahmin Çalışması

Tez çalışmasının üçüncü aşamasında, Eğirdir Gölüne ait aylık göl su seviyelerinden oluşan hidrolojik verilerin tahmini üzerinde çalışılmıştır. Bu veriler için de AKA ve TSA teknikleri ile ön ayırışım uygulandıktan sonra tahmin hesapları yapılmıştır. Böylece tahmin işleminde veride yapılacak ön işlem adımının katkısı su seviyesini gösteren hidrolojik veriler üzerinde araştırılmıştır. Eğirdir Gölü su seviyesi aylık verileri Şekil 3.3.1 deki grafikte görülmektedir.



Şekil 3.3.1. Eğirdir Gölüne ait su seviyesini gösteren veriler

Bu veriler tahminde kullanılmak üzere normalize edilerek eğitim ve test verileri olmak üzere iki gruba ayrılmıştır. Şekil 3.3.2.de görüldüğü gibi eğitim verileri için ilk 310 aylık hidrolojik veri, test için ise sonraki 213 adet aylık hidrolojik veri kullanılmıştır.




Şekil 3.3.2. Eğirdir Gölüne ait tahmin için kullanılan **a.** Eğitim ve **b.** Test verileri

AKA-YSA Modeli ile Tahmin


Eğitim ve test verileri öncelikle AKA yöntemi ile iki adet IMF bileşenlerine ayrıştırılmıştır. Bu sayede hidrolojik eğitim ve test verileri; $x(t) = IMF_1 + IMF_2 + R$ şeklinde üç bileşenle ifade edilebilmektedir. AKA yöntemi ile IMF bileşenlerine ayrıştırılmış veriler aşağıdaki Şekil 3.3.3. te görülmektedir.

İki IMF ve bir artık veri olmak üzere üç bileşene ayrılan Eğirdir Gölüne ait verilerin tahmini için YSA modeli kullanılmıştır. Tahmin çalışması için tez çalışmasının diğer bölümlerindeki gibi ÇKAYSA modeli kullanılmıştır. Her bir IMF bileşeni için oluşturulan ÇKAYSA yapısı bir giriş, bir ara katman ve bir çıkış katmanından oluşmaktadır. Ara katman nöron sayıları daha önceki bölümlerde bahsedildiği gibi 1 den 9 a kadar iterasyonla artırılmıştır ve ara katmanlardaki nöron sayısı en düşük ortalama karesel hatayı veren nöron sayısına göre belirlenmiştir.

Her bir IMF için olmak üzere toplam 3 adet YSA Levenberg Marquardt geri yayılım algoritması kullanılarak eğitilmiştir. En iyi YSA modelini belirleyebilmek için ağ performans kriteri olarak MSE ve MAE değerleri kullanılmıştır.



a



b

Şekil 3.3.3. AKA yöntemi ile IMF bileşenlerine ayrıştırılmış **a.** Eğitim **b.** Test verisi


Verilerin eğitimi için iterasyon sayısı ve YSA parametreleri tez çalışmasının daha önceki bölümlerinde olduğu gibi belirlenmiştir. YSA çıkışından elde edilen IMF tahmin verileri toplanarak hidrolojik veri tahmini işlemi gerçekleştirilmiştir.

Bu verilerin bir giriş bir ileri, iki ileri, üç ileri, dört, beş, altı ileri zamanlı tahmini gerçekleştirilmiştir. Tablo 3.3.1.de; bir, iki, üç, dört, beş ve altı ileri tahmin için IMF bileşenlerinin eğitim ve test performans parametreleri görülmektedir.

Tablo 3.3.1. Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli kullanarak IMF bileşenlerine ayrıştırılmış verilerin tahmin sonuçları

	Bir ileri tahmin							
	Test				Eğitim			
	MSE	MAE	R	R ²	MSE	MAE	R	R ²
IMF1	0.0006	0.0198	0.8599	0.7378	0.0008	0.0246	0.8698	0.7442
IMF2	0.00001	0.0065	0.9816	0.9831	0.000001	0.0036	0.9913	0.9292
R	0.00001	0.0073	0.9995	0.999	0.000001	0.0043	0.9997	0.9992
	İki ileri tahmin							
	Test				Eğitim			
IMF1	0.0017	0.0339	0.5063	0.2596	0.0023	0.0417	0.4919	0.2398
IMF2	0.0002	0.0122	0.8644	0.8073	0.0001	0.0064	0.9697	0.9442
R	0.0002	0.0116	0.9984	0.9967	0.0001	0.0068	0.9989	0.9976
	Üç ileri tahmin							
	Test				Eğitim			
IMF1	0.0022	0.0395	0.0505	0.0193	0.0030	0.0481	0.0172	0.0118
IMF2	0.0004	0.0169	0.8837	0.8761	0.0001	0.0092	0.9360	0.8142
R	0.0004	0.0170	0.9963	0.9945	0.0003	0.0152	0.9973	0.9927
	Dört ileri tahmin							
	Test				Eğitim			
IMF1	0.0018	0.0357	0.4144	0.2433	0.0024	0.0427	0.4380	0.1639
IMF2	0.0007	0.0208	0.6428	0.7841	0.0002	0.0126	0.8855	0.4132
R	0.0007	0.0226	0.9936	0.9899	0.0006	0.0208	0.9950	0.9872
	Beş ileri tahmin							
	Test				Eğitim			
IMF1	0.0010	0.0264	0.7332	0.6246	0.0011	0.0273	0.7954	0.5480
IMF2	0.0009	0.0233	0.7027	0.6658	0.0003	0.0153	0.7940	0.2411
R	0.0011	0.0281	0.9901	0.9837	0.0010	0.0266	0.9918	0.9802
	Altı ileri tahmin							
	Test				Eğitim			
IMF1	0.0005	0.0192	0.9042	0.8220	0.0005	0.0184	0.8722	0.7586
IMF2	0.0005	0.0183	0.6907	0.4309	0.0010	0.0237	0.4103	0.2796
R	0.0015	0.0327	0.9878	0.9757	0.0015	0.0334	0.9859	0.9720

AKA yöntemi ile iki IMF bileşeni ve verinin eğilimini gösteren artık verinin tahminlerinin toplanması sonucunda tahmin verileri elde edilmiştir. Bir, üç, dört ve altı ileri tahmin neticesinde elde edilen tahmin grafikleri Şekil 3.3.4 te görülmektedir.



Şekil 3.3.4. Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli ile bir-altı ileri zamanlı tahmin verileri, **a.** Bir ileri zamanlı, **b.** İki ileri zamanlı, **c.** Üç ileri zamanlı **d.** Altı ileri zamanlı


Tahmin edilen IMF'lerin toplamı sonucu elde edilen tahmin verisine ait AKA-YSA modeli performans parametreleri Tablo 3.3.2 de yer almaktadır.

Tablo 3.3.2. Eğirdir Gölü aylık su seviyeleri için AKA-YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri


MSE	MAE	R	R ²	MSE	MAE	R	R ²
Bir ileri tahmin							
Test				Eğitim			
0.0009	0.0252	0.9879	0.9758	0.0007	0.0226	0.9939	0.9876
İki ileri tahmin							
Test				Eğitim			
0.0025	0.0430	0.9649	0.9306	0.0021	0.0392	0.9817	0.9640
Üç ileri tahmin							
Test				Eğitim			
0.0035	0.0503	0.9515	0.9076	0.0032	0.0474	0.9729	0.9468
Dört ileri tahmin							
Test				Eğitim			
0.0034	0.0471	0.9563	0.9175	0.0033	0.0468	0.9716	0.9433
Beş ileri tahmin							
Test				Eğitim			
0.0027	0.0405	0.9698	0.9405	0.0030	0.0445	0.9743	0.9483
Altı ileri tahmin							
Test				Eğitim			
0.0027	0.0498	0.9717	0.9429	0.0020	0.0443	0.9742	0.9493

TSA-YSA Modeli ile Tahmin Çalışması

Eğirdir Gölü aylık su seviyeleri verileri; TSA yöntemi kullanılarak, birbiri ile ilişkili olan ve olmayan bileşenlerine ayrıştırılmıştır. Şekil 3.3.5.te TSA yöntemi kullanılarak üç bileşene ayrıştırılmış eğitim ve test verileri görülmektedir. TSA yöntemi ile ayrıştırılan sinyaller RC olarak isimlendirilmektedir. Dolayısıyla zaman sinyalleri RC1+RC2+RC3 olarak yeniden elde edilebilmektedir. TSA işleminde sinyal 12 uzunluklu pencere boyutu ile hankelizasyon işlemine tabi tutularak, yörünge matrisi haline getirilmiştir. En yüksek özdeğerine ait bileşen RC1 ile, 2. yüksek özdeğerine ait bileşen RC2 ile ve diğer özdeğerlerine ait bileşen de RC3 ile gösterilmektedir.



a



b





Şekil 3.3.5. TSA yöntemi kullanılarak altbant (RC) bileşenlerine ayrıştırılmış **a.** Eğitim Verisi **b.** Test Verisi

TSA ile ayrıştırılmış RC bileşenlerinin tahmini sırasında elde edilen performans parametreleri, Tablo 3.3.3 te verilmektedir.

Tablo 3.3.3. Eğirdir Gölü aylık su seviyeleri için TSA-YSA modeli kullanarak ayrıştırılmış altbant verilerinin tahmin performans değerleri

	Bir ileri tahmin							
	Test				Eğitim			
	MSE	MAE	R	R ²	MSE	MAE	R	R ²
RC1	0.000001	0.0031	0.9999	0.9954	0.000001	0.0024	0.9999	0.9987
RC2	0.0003	0.0070	0.9889	0.8185	0.000001	0.0042	0.9983	0.8243
RC3	0.0008	0.0247	0.8709	0.7416	0.0007	0.0216	0.9232	0.7574
	İki ileri tahmin							
	Test				Eğitim			
RC1	0.000001	0.0031	0.9998	0.9963	0.000001	0.0029	0.9998	0.9968
RC2	0.0003	0.0079	0.9801	0.7515	0.0001	0.0072	0.9948	0.7857
RC3	0.0025	0.0428	0.5477	0.3369	0.0022	0.0394	0.7457	0.3577
	Üç ileri tahmin							
	Test				Eğitim			
RC1	0.0001	0.0055	0.9994	0.9914	0.0001	0.0074	0.9996	0.9929
RC2	0.0001	0.0068	0.9912	0.8942	0.0001	0.0077	0.9929	0.9655
RC3	0.0037	0.0526	0.1315	0.098	0.0036	0.0499	0.5053	0.0897
	Dört ileri tahmin							
	Test				Eğitim			
RC1	0.0001	0.0060	0.9991	0.9846	0.000001	0.0057	0.9993	0.9877
RC2	0.0001	0.0079	0.9917	0.8142	0.0001	0.0097	0.9880	0.9537
RC3	0.0034	0.0499	0.1001	0.0606	0.0049	0.0863	0.1806	0.0842
	Beş ileri tahmin							
	Test				Eğitim			
RC1	0.0001	0.0075	0.9986	0.9757	0.0001	0.0053	0.9991	0.9814
RC2	0.0002	0.0094	0.9862	0.9478	0.0002	0.0119	0.9815	0.9431
RC3	0.0034	0.0500	0.0829	0.0823	0.0048	0.0553	0.1652	0.1563
	Altı ileri tahmin							
	Test				Eğitim			
RC1	0.0002	0.0090	0.9979	0.9642	0.0001	0.0084	0.9984	0.9741
RC2	0.0003	0.0110	0.9785	0.9696	0.0003	0.0141	0.9737	0.8081
RC3	0.0029	0.0446	0.4435	0.4081	0.0046	0.0543	0.2383	0.2315

Tahmin edilen RC verilerinin toplanması sonucu tahmin datası elde edilmiştir. Şekil 3.3.6 da bir, iki, üç ve altı ileri tahmin sonucu elde edilen tahmin verilerinin grafikleri ve tahmin işleminin performans sonuçları Tablo 3.3.4 te görülmektedir.

**a****b****c****d**

Şekil 3.3.6. Eğirdir Gölü aylık su seviyeleri için gözlenmiş ve TSA-YSA modeli ile bir-altı ileri zamanlı tahmin verileri; **a.** Bir ileri zamanlı, **b.** İki ileri zamanlı, **c.** Üç ileri zamanlı **d.** Altı ileri zamanlı

Tablo 3.3.4. Eğirdir Gölü aylık su seviyeleri için TSA-YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri


Bir ileri tahmin							
Test				Eğitim			
MSE	MAE	R	R²	MSE	MAE	R	R²
0.0010	0.0257	0.9869	0.9758	0.0008	0.02180	0.9939	0.9776
İki ileri tahmin							
Test				Eğitim			
0.0028	0.0451	0.9611	0.9540	0.0024	0.0357	0.9623	0.9589
Üç ileri tahmin							
Test				Eğitim			
0.0037	0.0545	0.9430	0.9214	0.0030	0.0526	0.9659	0.9533
Dört ileri tahmin							
Test				Eğitim			
0.0038	0.0552	0.9456	0.9325	0.0024	0.0511	0.9528	0.9489
Beş ileri tahmin							
Test				Eğitim			
0.0039	0.0568	0.9446	0.9502	0.0036	0.0517	0.9514	0.9605
Altı ileri tahmin							
Test				Eğitim			
0.0053	0.0583	0.9529	0.9520	0.0045	0.0467	0.9532	0.9529

Tablolardan ve şekillerden de görüleceği üzere zaman sinyaline uygulanan ön işlem ile veri tahmini oldukça başarılı olmaktadır.

YSA ile tahmin çalışması; Eğirdir Gölüne ait su seviyesi verilerini kullanarak TSA ve AKA gibi ön işlemlerin tahmin üzerinde etkisini karşılaştırmak amacıyla, YSA modeli kullanılarak hidrolojik veriler üzerine hiçbir ön işlem yapmadan veri tahmini işlemi gerçekleştirilmiştir. Şekil 3.3.7 de YSA kullanılarak elde edilen tahmin sonuçlarının grafikleri ve Tablo 3.3.5. te tahmin performansına ait parametrelerin değerleri verilmiştir.


Tablo 3.3.5. Eğirdir Gölü aylık su seviyeleri için YSA modeli kullanarak bir-altı ileri tahmin sonucu elde edilen tahmin verisine ait performans değerleri

Bir ileri tahmin							
Test				Eğitim			
MSE	MAE	R	R²	MSE	MAE	R	R²
0.0009	0.0264	0.9870	0.9742	0.0008	0.0227	0.9860	0.9855
İki ileri tahmin							
Test				Eğitim			
0.0033	0.0501	0.9541	0.9103	0.0027	0.0436	0.9542	0.9522
Üç ileri tahmin							
Test				Eğitim			
0.0064	0.0696	0.9120	0.8318	0.0051	0.0610	0.9120	0.9098
Dört ileri tahmin							
Test				Eğitim			
0.0093	0.0846	0.8726	0.7614	0.0073	0.0731	0.8726	0.8617
Beş ileri tahmin							
Test				Eğitim			
0.0117	0.0935	0.8443	0.7128	0.0090	0.0806	0.8443	0.8472
Altı ileri tahmin							
Test				Eğitim			
0.0136	0.0982	0.8317	0.6897	0.0096	0.0821	0.8317	0.8293




Şekil 3.3.7. Eğirdir Gölü aylık su seviyeleri için gözlenmiş ve YSA modeli ile bir-altı ileri zamanlı tahmin verileri, **a.** Bir ileri zamanlı, **b.** İki ileri zamanlı, **c.** Üç ileri zamanlı **d.** Altı ileri zamanlı


Elde edilen sonuçlara göre, Tablo 3.3.2, Tablo 3.3.4 ve Tablo 3.3.5 incelendiğinde, hidrolojik verilerin ayrıştırma işlemi yapmadan YSA modeli kullanılarak tahmini için oluşturulan model performansının, hidrolojik sinyallerde ön işlem yaparak altbantlara ayrıştırılmış sinyallerin tahmin toplamı yaparak oluşturulan modellere göre performansının düşük olduğu görülmektedir. Üç yöntem arasındaki performans parametrelerindeki değişimini Şekil 3.3.8 deki grafiklerde görmekteyiz.




a



b



c



Şekil 3.3.8. Eğirdir Gölü aylık su seviyelerinin tahmini için AKA-YSA, TSA-YSA ve YSA modellerinin performans parametrelerini gösteren **a.** MSE değerleri **b.** MAE değerleri **c.** R değerleri, **d.** R^2 değerleri

AKA-YSA ve TSA-YSA modeli ile gerçekleştirilen tahmin çalışmasının performansının YSA modeli ile gerçekleştirilen tahmin performansına göre yüksek olduğu, özellikle iki ve daha sonrası ileri tahmin çalışmalarında AKA-YSA ve TSA-YSA modellerinin performansının oldukça iyi olduğu görülmektedir.

4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

Gelecekte vuku bulacak hidrolojik olayların tahmini, hidrolojik verilerin modellemesi ve tahmini, taşkın, kuraklık gibi doğal afetlerin engellenmesi, su altyapısının etkin kullanımı, entegre su kullanımının desteklenmesi gibi pek çok konuda önemli olmaktadır.

Gerçekleştirilen tez çalışmasında hidrolojik verilerin tahmini için literatürde yer alan lineer yaklaşımlar üzerine kurulu modellerden ÖB, ÖBHO modelleri ve nonlineer yaklaşımlar sergilleyen YSA modelleri ile hidrolojik verilerin tahmininde yenilikçi yaklaşım olarak hibrit modeller kullanılarak, performansları analiz edilmiştir. Hibrit modellerden hidrolojik verilerin tahmini için yeni yaklaşımlar olan TSA ve AKA yöntemleri ile hidrolojik veriler altbantlara ayrıştırılmış ve altbant sinyallerinin tahmini gerçekleştirilmiştir.

Hidrolojik verilerin tahmininde; son 30-40 yılda yapay zeka tekniklerinin kullanımının hızla arttığı görülmektedir. Gerçekleştirilen tez çalışmada ön işlem uygulanan hidrolojik veriler yapay zeka tekniklerinden YSA ile tahmin edilmiştir. Tahmin çalışması için üç grup hidrolojik veri kullanılmıştır. 1. grup veriler Orta Kızılırmak Havzası Kızılırmak Nehri üzerine kurulu Yamula İstasyonundan kaydedilen aylık ortalama debi (m^3/sn) miktarını gösteren verilerdir. 2. Grup veriler ise Meriç Havzası Şeytan Deresinden alınan günlük debi (m^3/sn) miktarını gösteren verilerdir. Bu veriler kesikli yapıya sahip olup debinin ölçülmediği günlerde sıfır değerini almıştır. 3. grup hidrolojik veriler ise Eğirdir havzasına ait olup, Eğirdir Gölü aylık ortalama su seviyesini (m.) gösteren verilerdir.

1. grup veriler üzerinde gerçekleştirilen tahmin çalışmasında 1 ileri tahmin için en iyi ÖB ve ÖBHO model derecesi ABK kriteri kullanılarak belirlenmeye çalışılmıştır. ÖB

model için 12. derece, ÖBHO model için 26, 27 model dereceleri en uygun olarak belirlenmiştir. ÖB, ÖBHO modelleri tahmin performansını gösteren MSE, MAE, R ve R^2 değerleri tablolar halinde gösterilmiştir ve gözlemlenen, tahmin edilen veriler grafikler halinde saçılım grafikleri ile gösterilmiştir.

Hidrolojik verilerin bir ileri tahmini için kullanılan YSA modeli ile tahmin çalışmasında, nöron sayısı iterasyonlarda değiştirilerek, en iyi tahmini veren nöron sayısı modelde kullanılmıştır. Ayrıca tahmin performansı, YSA modeli giriş sayısı 1-9 arasında uygulanarak, en iyi performansın beş giriş bir ara katman ile elde edildiği 5 giriş-1 çıkış YSA modeli kullanılmıştır.

Veride ön işlem gerçekleştirerek, tahmin yaklaşımının kullanıldığı AKA-YSA modeli için hidrolojik veriler öncelikle eğitim ve test verisi olarak iki gruba ayrıştırılmıştır. Her iki grup sinyal AKA yöntemi kullanılarak ayrı ayrı tahmin performansı yüksek, işlem yükünün de fazla olmayacağı uygun seviye sayısı olarak 4 adet altbanta ayrıştırılmıştır. Her bir altbant sinyali; IMF1, IMF2, IMF3 ve IMF4 isimleri verilmiştir. AKA yöntemi ile altbantlara ayrıştırılmış eğitim ve test verilerinden eğitim verileri kullanılarak, en iyi YSA yapısı belirlenmeye çalışılmıştır. AKA-YSA modeli ile gerçekleştirilen tahmin çalışmasında, IMF altbantlarının YSA ile tahmini aşamasında, 3 giriş - 1 çıkışlı, 1 ara katmana sahip YSA ile en iyi tahmin performansı elde edilmiştir. Ayrı ayrı 4 altbanttan tahmin edilen IMF'ler toplanarak, tahmin verisi elde edilmiştir.

TSA-AKA-YSA modelinde, IMF1 altbant tahmin performansını iyileştirmek üzere, IMF1 altbant sinyali en yüksek özdeğerine bağlı özvektörüne göre yeniden yapılandırılarak tahmin edilmiştir. Böylece tahmin performansı artırılmıştır.

Aylık debi verilerinin bir ileri zamanlı tahmini çalışmasında, veriler üzerinde TSA yöntemi kullanılarak ön işlem gerçekleştirilmiş ve altbant sinyalleri elde edilmiştir. TSA yöntemi ile gerçekleştirilen ayrıştırma işleminde elde edilen altbant verilerine; RC1, RC2, RC3, RC4, RC5, RC6, RC7, RC8, RC9, RC10, RC11 ve RC12 isimleri verilmiştir. RC_i altbant verilerinin tahmini aşamasında, en iyi YSA yapısı için 1-5 giriş uygulanmıştır. En iyi ağ yapısı 3 giriş - 1 çıkış bir ara katman olarak belirlenmiştir.

Kızılırmak üzerindeki Yamula akım rasat istasyonunda aylık debi tahmini için kullanılan modellerin performansları; **ÖB(12)** modeli ile elde edilen tahmin sonuçlarına

göre MSE değeri **0.0228**, MAE değeri **0.1057**, R değeri **0.6149** ve R^2 değeri **0.7131** olarak elde edilmiştir. **ARMA(26,27)** modeli ile gerçekleştirilen tahmin işleminde MSE değeri **0.0131**, MAE değeri **0.0897** ve R değeri **0.7994** olarak elde edilmiştir. Sadece **YSA** ile yapılan tahmin işleminde tahmin edilen veri ve gözlemlenen veri arasındaki MSE, MAE, R ve R^2 değerleri sırasıyla **0.0188**, **0.0816**, **0.7359** , **0.5416** olarak elde edilmiştir. **AKA-YSA** modeli performans değerleri MSE değeri için **0.0092**, MAE değeri için **0.0645**, R değeri için **0.8786** ve R^2 değeri **0.7719** olarak elde edilmiştir. **TSA-AKA-YSA** modeli ile elde edilen tahmin performansları, MSE değeri **0.0054**, MAE değeri **0.0563**, R değeri **0.9329** ve R^2 değeri **0.8703** olarak elde edilmiştir. **TSA-YSA** modeli tahmin performansları MSE, MAE ve R değerleri için sırasıyla **0.000008**, MAE değeri **0.006893**, R değeri **0.998** ve R^2 değeri **0.987** olarak elde edilmiştir. Bu sonuçlara göre **TSA-YSA** modelinin tahmin performansının oldukça yüksek olduğu görülmektedir. Ayrıca, **TSA** ve **AKA** yöntemleri ile gerçekleştirilen ön işlemlerin tahmin performansını önemli derecede artırdığı görülmektedir.

Kızılırmak üzerindeki Yamula akım rasat istasyonunda aylık debi verileri üzerinde gerçekleştirilen tahmin çalışmasında, 3 giriş - 1 çıkışlı **TSA-YSA** ve **YSA** modeli ile bir, iki, üç, dört, beş ve altı ileri tahmin gerçekleştirilmiştir. Tahmin işlemi performans sonuçları incelendiğinde, **TSA-YSA** modeli ile, **YSA** modeline göre, 6 ileri tahminde bile oldukça başarılı sonuçlar alındığı görülmektedir. **TSA-YSA** modeli ile örnek olarak, üç ileri tahmin performans MSE, MAE ve R değerleri sırasıyla **0.149**, **0.0827** ve **0.6370** iken, **YSA** modeli ile 3 ileri zamanlı tahmin performans MSE, MAE, R ve R^2 değerleri sırasıyla; **0.0006**, **0.019825**, **0.992** ve **0.985** olarak elde edilmiştir. Bu sonuçlara göre **TSA-YSA** modelinin ileri zamanlı tahminlerde oldukça verimli olduğunu görmekteyiz.

Meriç Havzasındaki Şeytan Deresinin günlük akımlar kesikli verisi üzerinde bir, iki ve üç ileri zamanlı yapılan tahmin çalışmasında; **YSA**, **AKA-YSA**, **TSA-AKA-YSA** ve **TSA-YSA** modelleri kullanılmıştır. İki gruba ayrılan eğitim ve test kesikli verilerinin **YSA** modeli ile en iyi tahmini gerçekleştirmek üzere giriş sayıları, ara katman sayısı ve ara katmandaki nöron sayıları, iterasyonlarla artırılmıştır. Bir, iki ve üç ileri tahmin çalışması için dört giriş iki ara katman 1 çıkışlı **YSA** yapısı kullanılmıştır. **AKA-YSA** modeli ile gerçekleştirilen tahmin çalışmasında kesikli hidrolojik veriler, tahmin performansı en iyi, işlem yükünün artırılmadığı 13 adet altbant sinyaline ayrıştırılmıştır.

Bu altbant verileri; IMF1, IMF2, IMF3, IMF4, IMF5, IMF6, IMF7, IMF8, IMF9, IMF10, IMF11, IMF12, IMF13 olarak isimlendirilmiştir. Altbant verilerini tahmin edebilmek için geliştirilen YSA modeli de; 4 giriş, 2 ara katman ve 1 çıkıştan oluşmaktadır. AKA-YSA modeli ile altbantların tahmini sırasında IMF2 altbantının tahmin performansının düşük olduğu görülmüştür. Bu bileşenin tahmin performansını artırmak üzere TSA kullanılarak, en yüksek özdeğerine ait olan özvektör bileşenine göre yeniden yapılandırılmıştır. TSA kullanarak yeniden yapılandırılan IMF bileşeninin YSA ile tahmin performansının kesikli veriler içinde arttığı görülmüştür. Tahmin çalışması için önerilen; AKA-YSA modelinde; bir, iki ve üç ileri veri tahmini için elde edilen korelasyon katsayıları sırası ile; **0.7384, 0.7116 ve 0.6575** olarak elde edilmiştir. R^2 değerleri ise **0.9375, 0.8616 ve 0.8404** olarak elde edilmiştir. MSE değerleri ise; **3.80×10^{-4} , 5.08×10^{-4} , 5.22×10^{-4}** olarak elde edilmiştir. MAE değerleri; **0.0089, 0.0119 ve 0.0107** olarak elde edilmiştir. AKA-TSA-YSA modelinde ise korelasyon katsayıları sırası ile; **0.824, 0.7424 ve 0.6578** olarak elde edilmiştir. R^2 değerleri ise **0.7021, 0.5990 ve 0.5248** olarak elde edilmiştir. MSE değerleri ise; **2.90×10^{-4} , 3.95×10^{-4} , 5.04×10^{-4}** olarak elde edilmiştir. MAE değerleri; **0.0077, 0.0090 ve 0.0133** olarak elde edilmiştir. Buna karşın YSA modelinde; bir, iki ve üç giriş için korelasyon katsayısı sırasıyla **0.698, 0.6068 ve 0.5522**, R^2 değeri sırasıyla **0.5810, 0.3772 ve 0.1471**, MSE değeri sırasıyla; **3.91×10^{-4} , 4.48×10^{-4} ve 5.20×10^{-4}** , MAE değeri ise sırasıyla; **0.0053, 0.0063 ve 0.0093** olarak elde edilmiştir. TSA-YSA modeli kullanarak bir, iki ve üç ileri veri tahmini için elde edilen korelasyon katsayıları sırası ile; **0.9672, 0.8717 ve 0.8605** iken, R^2 değerleri **0.9375, 0.8616, ve 0.8404**, MSE değerleri sırasıyla; **1.28×10^{-4} , 1.93×10^{-4} ve 2.45×10^{-4}** , MAE değerleri ise sırasıyla; **0.0053, 0.0060, 0.0072** olarak elde edilmiştir. Bu sonuçlara göre; TSA-YSA modelinin kesikli verilerin tahmininde oldukça yüksek performans sergilediği görülmektedir.

Eğirdir Gölü aylık ortalama su seviyesi verilerinin bir, iki, üç, dört, beş ve altı ileri zamanlı tahmini için YSA, AKA-YSA ve TSA-YSA modelleri kullanılmıştır. Su seviyesinin YSA modeli ile tahmini çalışmasında, 1 giriş 1 ara katman ve 1 çıkışlı yapı kullanılmıştır. AKA-YSA modeli ile gerçekleştirilen tahmin çalışmasında, hidrolojik veriler 3 altbileşene ayrıştırılmıştır. Bunlardan ikisi IMF bileşeni, diğeri ise artık veri altbileşenidir. Bu altbileşenler IMF1, IMF2 ve R olarak isimlendirilmektedir. IMF1, IMF2 ve R altbant verilerin tahmini için 1 giriş - 1 çıkışlı YSA kullanılmıştır. TSA-

YSA modeli ile gerçekleştirilen tahmin çalışmasında, hidrolojik veriler 3 altbileşene ayrıştırılmıştır. Bu altbant verileri; birinci en yüksek değerli özvektörüne ait altbant verisi RC1, ikinci en yüksek değerli özvektörüne ait altbant verisi RC2 ve diğer özvektörlerinin toplamı olan altbant verisi RC3 olarak isimlendirilmektedir. RC1, RC2 ve RC3 altbant verilerinin tahmini için, 1 giriş 1 çıkışlı YSA modeli kullanılmıştır. Su seviyesi tahmini için geliştirilen modellerden, örnek olarak altı ileri zamanlı tahmin çalışmasında MSE, MAE, R ve R^2 performans parametreleri YSA modeli için sırasıyla; **0.0136, 0.0982, 0.8317** ve **0.6897**, TSA-YSA modeli için; **0.0053, 0.0583, 0.9529** ve **0.9520**, AKA-YSA modeli için; **0.0027, 0.0405, 0.9698** ve **0.9429** olarak elde edilmiştir. Su seviyesine ait hidrolojik verilerin tahmini çalışmasında; AKA-YSA ve TSA-YSA modeli ile gerçekleştirilen tahmin çalışmalarının performansının, YSA modeli ile gerçekleştirilen tahmin performansına göre yüksek olduğu, özellikle iki ve daha sonrası ileri tahmin çalışmalarında AKA-YSA ve TSA-YSA modellerinin performansının oldukça iyi olduğu görülmektedir.

Tez çalışmasında, hidrolojik verilerin tahmini için yaygın olarak kullanılan ÖB, ÖBHO ve YSA modellerine alternatif, TSA-YSA ve AKA-YSA gibi hibrit yaklaşımlar önerilmiştir. Bu yaklaşımların performansı hidrolojik verilerle test edilmiştir.

Elde edilen sonuçlara göre; yüksek standart sapması ve çarpıklık katsayısına sahip kesikli verilerin tahmininde bile, TSA-YSA modelinin performansının oldukça yüksek olduğu görülmüştür. Bunun sebebi; kesikli verilerde, TSA yöntemi ile ayrıştırılmış (öz vektörlerine göre, dolayısıyla istatistiksel özelliklerine göre gruplandırılmış) altbant sinyallerinin standart sapmasının kendi içerisinde düşük olmasıdır. TSA yöntemi ile veri daha düşük standart sapmalı ve çarpıklık katsayılı altbant sinyallerine ayrıştırılmaktadır. Böylece, altbant sinyallerinin tahmini kolaylaştırılmaktadır. TSA-YSA modeli ile hidrolojik verilerin tahmin performansının, hibrid olmayan YSA modeline göre oldukça iyi olduğu bu tez çalışmasında görülmektedir.

İleriye yönelik çalışmalarda; bu tez çalışmasında önerilen ön işlemle altbantlara ayrıştırılan sinyallerin tahmini, literatürde yeralan farklı yapay zeka teknikleri de (Karar Destek Makinaları, Fuzzy Yaklaşımlar vs.) kullanılarak gerçekleştirilebilir.

Önerilen modellerin meteorolojik tahmin çalışmaları gibi farklı alanlarda da kullanılması önerilebilir.

KAYNAKLAR

1. Bayazıt M, (1998). Hidrolojik Modeller, İTÜ İnşaat Fakültesi Matbaası, İstanbul,
2. Chow V.T., Maidment D.R., Mays L.W., (1988) Applied Hydrology, McGraw-Hill, NY
3. Okman, C. (1994). Hidroloji. Ankara Üniversitesi Ziraat Fakültesi Yay.1388, Ankara, 359 s.
4. Ekmekçi M. “Hacettepe Ders Notları” <http://www.dsi.gov.tr/faaliyetler/turkiye-ulusal-hidroloji-komisyonu>
5. Box, G.E.P., Jenkins, G.M., (1970), Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco.
6. Carlson, R.F., MacCormick, A.J.A., & Watts, D. G. (1970). Application of linear random models to four annual streamflow series. **Water Resources Research**, 6(4), 1070-1078.
7. Granger, C.W., & Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing. **Journal of time series analysis**, 1(1), 15-29.
8. Noakes, D.J., McLeod, A.I., & Hipel, K.W. (1985). Forecasting monthly riverflow time series. **International Journal of Forecasting**, 1(2), 179-190.
9. Montanari, A., Rosso, R., & Taqqu, M.S. (1997). Fractionally differenced ARIMA models applied to hydrologic time series: Identification, estimation, and simulation. **Water resources research**, 33(5), 1035-1044.
10. Grimaldi, S. (2004). Linear parametric models applied to daily hydrological series. **Journal of Hydrologic Engineering**, 9(5), 383-391.
11. Padmanabhan, G., & Rao, A.R. (1988). Maximum entropy spectral analysis of hydrologic data. **Water Resources Research**, 24(9), 1519-1533.
12. Cahill, A.T. (2002). Determination of changes in streamflow variance by means of a wavelet-based test. **Water Resources Research**, 38(6).

13. Neupauer, R.M., Powell, K.L., Qi, X., Lee, D.H., Villhauer, D.A., (2006). Characterization of permeability anisotropy using wavelet analysis. **Water Resour. Res.** **42**, W07419.
14. Labat D., Ababou R., Mangin A., (2000). Rainfall–runoff relations for karstic springs, Part II: continuous Wavelet and discrete orthogonal multiresolution analysis, **Journal of Hydrology**, **238**(3–4): 149–178.
15. Smith, L. C., Turcotte, D. L., & Isacks, B. L. (1998). Stream flow characterization and feature detection using a discrete wavelet transform. **Hydrological processes**, **12**(2), 233-249.
16. Adamowski, J., (2007). Development of a short-term river flood forecasting method based on wavelet analysis. Polish Academy of Sciences Publication, Warsaw, 172.
17. Adamowski, J., (2008a). Development of a short-term river flood forecasting method for snowmelt driven floods based on wavelet and cross-wavelet analysis. **Journal of Hydrology**, **353**, 247–266.
18. Adamowski, J., (2008b). River flow forecasting using wavelet and cross-wavelet transform models. **Journal of Hydrological Processes**, **22**, 4877–4891.
19. Adamowski, J., & Sun, K. (2010). Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. **Journal of Hydrology**, **390**(1), 85-91.
20. Sang YF., 2013, A review on the applications of wavelet transform in hydrology time series analysis, **Atmospheric Research**, **122**, 8–15
21. Yakowitz, S. J. (1973). A stochastic model for daily river flows in an arid region. **Water Resources Research**, **9**(5), 1271-1285.
22. Yakowitz, S. J. (1979). A nonparametric Markov model for daily river flow. **Water Resources Research**, **15**(5), 1035-1043.
23. Yakowitz, S., & Karlsson, M. Nearest neighbor methods with application to rainfall/runoff prediction. *Stochastic Hydrology*, 149-160.

24. Shamseldin, A. Y., & O'Connor, K. M. (1996). A nearest neighbour linear perturbation model for river flow forecasting. **Journal of Hydrology**, 179 (1-4), 353-375.
25. Kember, G., Flower, A. C., & Holubeshen, J. (1993). Forecasting river flow using nonlinear dynamics. **Stochastic Hydrology and Hydraulics**, 7(3), 205-212.
26. Lall, U., Sangoyomi, T., & Abarbanel, H.D. (1996). Nonlinear dynamics of the Great Salt Lake: Nonparametric short-term forecasting. **Water Resources Research**, 32(4), 975-985.
27. Porporato, A., Ridolfi, L., 2001. Multivariate nonlinear prediction of river flows. **Journal Hydrology**, 248, 109–122.
28. Zealand CM., Burn DH., Simonovic SP., 1999, Short term streamflow forecasting using artificial neural networks, **Journal of Hydrology**, 214, 32–48
29. Kişi, Ö. (2004). River flow modeling using artificial neural networks. **Journal of Hydrologic Engineering**, 9(1), 60-63.
30. Kentel, E. (2009). Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. **Journal of hydrology**, 375(3), 481-488.
31. Terzi, Ö., & Ergin, G. (2014). Forecasting of monthly river flow with autoregressive modeling and data-driven techniques. **Neural Computing and Applications**, 25(1), 179-188.
32. Yaseen, Z.M., El-Shafie, A., Afan, H.A., Hameed, M., Mohtar, W.H.M.W., Hussain, A., 2015. RTFSA versus FFNN for daily river flow forecasting at Johor River, Malaysia. *Neural Comput. Appl.*
33. Task, A., 2000. Artificial neural networks in hydrology. **By the ASCE Task Committee on Application of Artificial Neural Networks in Hydrology**, 1, 124–137.
34. Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. **Neural Networks**, 359-266.

35. Broomhead, D. S., & Lowe, D. (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks (No. RSRE-MEMO-4148). Royal Signals and Radar Establishment Malvern (United Kingdom).
36. Specht, D. F. (1991). A general regression neural network. **IEEE transactions on neural networks**, 2(6), 568-576.
37. Cigizoglu, H. K. (2005). Application of generalized regression neural networks to intermittent flow forecasting and estimation. **Journal of Hydrologic Engineering**, 10(4), 336-341.
38. Hsu, K. L., Gupta, H. V., Gao, X., Sorooshian, S., & Imam, B. (2002). Self-organizing linear output map (SOLO): An artificial neural network suitable for hydrologic modeling and analysis. **Water Resources Research**, 38(12).
39. Chiang, Y. M., Chang, L. C., & Chang, F. J. (2004). Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling. **Journal of hydrology**, 290(3), 297-311.
40. Moradkhani, H., Hsu, K. L., Gupta, H. V., & Sorooshian, S. (2004). Improved streamflow forecasting using self-organizing radial basis function artificial neural networks. **Journal of Hydrology**, 295(1), 246-262.
41. Hu, T. S., Lam, K. C., & Ng, S. T. (2005). A Modified Neural Network for Improving River Flow Prediction/Un Réseau de Neurones Modifié pour Améliorer la Prévision de L'Écoulement Fluvial. **Hydrological sciences journal**, 50(2), 299-318.
42. Wu, J. S., Han, J., Annambhotla, S., & Bryant, S. (2005). Artificial neural networks for forecasting watershed runoff and stream flows. **Journal of hydrologic engineering**, 10(3), 216-222.
43. Kişi, Ö. (2007). Streamflow forecasting using different artificial neural network algorithms. **Journal of Hydrologic Engineering**, 12(5), 532-539.
44. Ahmed, J.A., & Sarma, A.K. (2007). Artificial neural network model for synthetic streamflow generation. **Water resources management**, 21(6), 1015-1029.
45. Jain, A., & Kumar, A. M. (2007). Hybrid neural network models for hydrologic time series forecasting. **Applied Soft Computing**, 7(2), 585-592.

46. Toth, E., & Brath, A. (2007). Multistep ahead streamflow forecasting: Role of calibration data in conceptual and neural network modeling. **Water Resources Research**, **43**(11), 1–11.
47. Mutlu, E., Chaubey, I., Hexmoor, H., & Bajwa, S. G. (2008). Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. **Hydrological processes**, **22**(26), 5097-5106.
48. Kagoda, P. A., Ndiritu, J., Ntuli, C., & Mwaka, B. (2010). Application of radial basis function neural networks to short-term streamflow forecasting. **Physics and Chemistry of the Earth, Parts A/B/C**, **35**(13), 571-581.
49. Yonaba, H., Anctil, F., & Fortin, V. (2010). Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. **Journal of Hydrologic Engineering**, **15**(4), 275-283.
50. Mehr, A. D., Kahya, E., Şahin, A., & Nazemosadat, M. J. (2015). Successive-station monthly streamflow prediction using different artificial neural network algorithms. **International Journal of Environmental Science and Technology**, **12**(7), 2191-2200.
51. Veintimilla-Reyes, J., Cisneros, F., & Vanegas, P. (2016). Artificial Neural Networks applied to flow prediction: A use case for the Tomebamba river. **Procedia Engineering**, **162**, 153-161.
52. Sivapragasam, C., Maheswaran, R., & Venkatesh, V. (2008). Genetic programming approach for flood routing in natural channels. **Hydrological processes**, **22**(5), 623-628.
53. Li, P. H., Kwon, H.H., Sun, L., Lall, U., & Kao, J.J. (2010). A modified support vector machine based prediction model on streamflow at the Shihmen Reservoir, Taiwan. **International Journal of Climatology**, **30**(8), 1256-1268.

54. Noori, R., Karbassi, A. R., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M. H., Farokhnia, A., & Gousheh, M. G. (2011). Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. **Journal of Hydrology**, **401**(3), 177-189.
55. Ch, S., Anand, N., Panigrahi, B.K., Mathur, S., 2013. Streamflow forecasting by KDM with quantum behaved particle swarm optimization. **Neurocomputing**, **101**, 18–23.
56. He, Z., Wen, X., Liu, H., & Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. **Journal of Hydrology**, **509**, 379-386.
57. El-Shafie, A., Taha, M. R., & Noureldin, A. (2007). A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. **Water resources management**, **21**(3), 533-556.
58. Nayak, P. C., Sudheer, K. P., & Jain, S. K. (2007). Rainfall-runoff modeling through hybrid intelligent system. **Water Resources Research**, **43**(7).
59. Özger, M. (2009). Comparison of fuzzy inference systems for streamflow prediction. **Hydrological Sciences Journal**, **54**(2), 261-273.
60. Sanikhani, H., & Kisi, O. (2012). River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. **Water resources management**, **26**(6), 1715-1729.
61. Greco, R., 2012. A fuzzy-Autoregressive model of daily river flows. **Comput. Geosci.** **43**, 17–23.
62. Babovic, V., & Keijzer, M. (2002). Rainfall runoff modelling based on genetic programming. **Hydrology Research**, **33**(5), 331-346.
63. Babovic, V., & Keijzer, M. (2000). Genetic programming as a model induction engine. **Journal of Hydroinformatics**, **2**(1), 35-60.
64. Holland, J., 1975. Adaptation in Natural and Artificial Systems. Ann Arbor, Univ Michigan Press.

65. Schwefel, H.-P., 1981. Numerical Optimization of Computer Models. John Wiley & Sons, Inc.
66. Koza, J.R., 1992. Genetic Programming: on the Programming of Computers by Means of Natural Selection. MIT Press.
67. Whigham, P. A., & Crapper, P. F. (2001). Modelling rainfall-runoff using genetic programming. **Mathematical and Computer Modelling**, **33**(6-7), 707-721.
68. Dorado, J., Rabuñ AL, J.R., Pazos, A., Rivero, D., Santos, A., & Puertas, J. (2003). Prediction and modeling of the rainfall-runoff transformation of a typical urban basin using ANN and GP. **Applied Artificial Intelligence**, **17**(4), 329-343.
69. Makkeasorn, A., Chang, N. B., & Zhou, X. (2008). Short-term streamflow forecasting with global climate change implications—A comparative study between genetic programming and neural network models. **Journal of hydrology**, **352**(3), 336-354.
70. Sifuzzaman, M., Islam, M.R., Ali, M.Z., 2009. Application of wavelet transform and its advantages compared to fourier transform. **J. Phys. Sci.**, **13**, 121–134.
71. Partal, T. (2008). River flow forecasting using different artificial neural network algorithms and wavelet transform. **Canadian Journal of Civil Engineering**, **36**(1), 26-38.
72. Shiri, J., & Kisi, O. (2010). Short-term and long-term streamflow forecasting using a wavelet and neuro-fuzzy conjunction model. **Journal of Hydrology**, **394**(3), 486-493.
73. Yazar, A. (2014). A hybrid wavelet and neuro-fuzzy model for forecasting the monthly streamflow data. **Water resources management**, **28**(2), 553-565.
74. Adamowski, J., & Sun, K. (2010). Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. **Journal of Hydrology**, **390**(1), 85-91.

75. Mehr, A. D., Kahya, E., Şahin, A., & Nazemosadat, M. J. (2015). Successive-station monthly streamflow prediction using different artificial neural network algorithms. **International Journal of Environmental Science and Technology**, **12**(7), 2191-2200.
76. Guo, J., Zhou, J., Qin, H., Zou, Q., & Li, Q. (2011). Monthly streamflow forecasting based on improved support vector machine model. **Expert Systems with Applications**, **38**(10), 13073-13081.
77. Kalteh, A. M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. **Computers & Geosciences**, **54**, 1-8.
78. Danandeh Mehr, A., Kahya, E., Bagheri, F., Deliktas, E., 2013a. Successive-station monthly streamflow prediction using neuro-wavelet technique. **Earth Sci. Informatics**, 1–13.
79. Makwana, J.J., & Tiwari, M.K. (2014). Intermittent streamflow forecasting and extreme event modelling using wavelet based artificial neural networks. **Water resources management**, **28**(13), 4857-4873.
80. Sahay, R. R., & Srivastava, A. (2014). Predicting monsoon floods in rivers embedding wavelet transform, genetic algorithm and neural network. **Water resources management**, **28**(2), 301-317.
81. Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998, March). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. In *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences* (Vol. 454, No. 1971, pp. 903-995). The Royal Society.
82. Huang, N. E., Shen, Z., & Long, S. R. (1999). A new view of nonlinear water waves: the Hilbert spectrum. **Annual review of fluid mechanics**, **31**(1), 417-457.
83. Karthikeyan L., Kumar D.N., (2013). Predictability of nonstationary time series using wavelet and EMD based ARMA models, **Journal of Hydrology**, **502**, 103–119

84. Huang S., Chang J., Huang Q., Chen Y., (2014). Monthly streamflow prediction using modified EMD-based support vector machine, **Journal of Hydrology**, **511**, 764–775
85. Wang, J., & Wang, J. (2017). Forecasting stochastic neural network based on financial empirical mode decomposition. **Neural Networks**, **90**, 8-20.
86. Zhang H., Singh V. P., Wang B., Yu Y. (2016). CEREF: A hybrid data-driven model for forecasting annual streamflow from a socio-hydrological system, **Journal of Hydrology**, **540**, 246–256
87. Marques, C. A. F., Ferreira, J. A., Rocha, A., Castanheira, J. M., Melo-Goncalves, P., Vaz, N., & Dias, J. M. (2006). Singular spectrum analysis and forecasting of hydrological time series. **Physics and Chemistry of the Earth, Parts A/B/C**, **31**(18), 1172-1179.
88. Hassani, H., Soofi, A. S., & Zhigljavsky, A. A. (2010). Predicting daily exchange rate with singular spectrum analysis. **Nonlinear Analysis: Real World Applications**, **11**(3), 2023-2034.
89. Rocco S, C. M. (2013). Singular spectrum analysis and forecasting of failure time series. **Reliability Engineering and System Safety**, **114**, 126-136.
90. Wang, X., Wu, J., Liu, C., Wang, S., & Niu, W. (2016). A Hybrid Model Based on Singular Spectrum Analysis and Support Vector Machines Regression for Failure Time Series Prediction. **Quality and Reliability Engineering International**, **32**(8), 2717-2738.
91. Marques, C. A. F., Ferreira, J. A., Rocha, A., Castanheira, J. M., Melo-Goncalves, P., Vaz, N., & Dias, J. M. (2006). Singular spectrum analysis and forecasting of hydrological time series. **Physics and Chemistry of the Earth, Parts A/B/C**, **31**(18), 1172-1179.
92. Hayes M.,1996, Statistical Digital Signal Processing and Modeling, Wiley, ISBN: 978-0-471-59431-4

93. Pegram, G.G., Peel, M.C., & McMahon, T.A. (2008). Empirical mode decomposition using rational splines: an application to rainfall time series. *In Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences* 464, (2004), 1483-1501.
94. Golyandina, N., Nekrutkin, V., Zhigljavsky, A.A., 2001, *Analysis of Time Series Structure: SSA and Related Techniques*. Chapman & Hall/CRC, Berlin.
95. Golyandina N., Zhigljavsky A., 2013, *Singular Spectrum Analysis for Time Series*, Springer.
96. Öztemel E., 2012, *Yapay Sinir Ağları*, Papatya yayıncılık, ISBN:978-975-6797-39-6
97. Elmas, Ç., 2003, *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Seçkin Yayınları, ISBN:975-347-612-4
98. Hagan, M.T., H.B. Demuth, and M.H. Beale, 1996, *Neural Network Design*, Boston, MA: PWS Publishing.
99. <https://image.slidesharecdn.com/12-140320163511-phpapp01/95/yapay-sinir-alar-3-638.jpg?cb=1395333372>
100. Marquardt, D. W. (1963). An algorithm for least-squares estimation of nonlinear parameters. **Journal of the society for Industrial and Applied Mathematics**, 11(2), 431-441.
101. Devlet Su İşleri Genel Müdürlüğü ARCGIS Veri Tabanı
102. Burnham, K.P., and Anderson, D.R. 2002. *Model selection and inference: a practical information-theoretic approach*, second edition. Springer-Verlag, New York.
103. Kisi, O., Latifoğlu, L., & Latifoğlu, F. (2014). Investigation of empirical mode decomposition in forecasting of hydrological time series. **Water resources management**, 28(12), 4045-4057.
104. Latifoğlu, L., Kişi, Ö., & Latifoğlu, F. (2015). Importance of hybrid models for forecasting of hydrological variable. **Neural Computing and Applications**, 26(7), 1669-1680.

105. Kiři Ö. Latifoęlu L., Latifoęlu F., Genç O., 2013, Ampirik Kip Ayriřim ve Yapay Sinir Aęlari Kullanarak Hidrolojik Verilerin Tahmini , *Tařkın ve Heyelan Sempozyumu / 24-26 Ekim 2013*, pp. 433-441.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Levent LATİFOĞLU

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 03 Mart 1977, Kayseri

Medeni Durumu: Evli

Tel: +90 532 3044777

email: leventlatifoglu@gmail.com

Yazışma Adresi: DSİ 12. BÖLGE MÜDÜRLÜĞÜ, 38010 Kocasinan/KAYSERİ

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Doktora	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı	2017
Yüksek Lisans	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı	2003
Lisans	İstanbul Teknik Üniversitesi, İnşaat Mühendisliği Bölümü	2000
Lise	Nuh Mehmet Küçükçalık Anadolu Lisesi, Kayseri	1995

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2000-2002	Erciyes Üniversitesi,	Asistan
2002-Halen	DSİ 12. Bölge Müdürlüğü	İnşaat Yük. Mühendisi

YABANCI DİL

İngilizce	İyi
Almanca	Orta

Yapılan Tezler

Doktora Tezi

HİDROLOJİK ZAMAN SERİLERİNİN YENİ HİBRİT YÖNTEMLERLE TAHMİNİ,
Erciyes Üniversitesi Fen Bilimleri Enstitüsü, 2017

Yüksek Lisans

BARAJLARDA ÖLÜ HACİM HESABI VE YAMULA BARAJI ÖRNEĞİ,
Erciyes Üniversitesi Fen Bilimleri Enstitüsü, 2003

Çalışmalar:

A. Uluslararası hakemli dergilerde yayımlanan makaleler (SCI ve SCIEExpanded):

A.1. L. Latifoğlu, O. Kisi, F. Latifoglu, Importance of hybrid models for forecasting of hydrological variable, NEURAL COMPUTING & APPLICATIONS, Vol. 26 (7), pp. 1669-1680, 2015

A.2. O. Kisi, L. Latifoğlu, F. Latifoglu, Investigation of Empirical Mode Decomposition in Forecasting of Hydrological Time Series, WATER RESOURCES MANAGEMENT Vol.28(12), pp.4045-4057,2014

Ç. Ulusal bilimsel toplantılarda sunulan ve bildiriler kitabında yayımlanan makaleler:

Ç.1. Kişi Ö. Latifoğlu L., Latifoğlu F., Genç O., Ampirik Kip Ayırışim ve Yapay Sinir Ağlari Kullanarak Hidrolojik Verilerin Tahmini , pp. 433-441, Taşkın ve Heyelan Sempozyumu / 24-26 Ekim 2013, Trabzon