



**T.C.**  
**NECMETTİN ERBAKAN ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**AYLIK ORTALAMA AKIM VERİLERİNİN**  
**YAPAY SİNİR AĞLARI KULLANILARAK**  
**TAHMİN EDİLMESİ**

**Mustafa ASAAD**

**YÜKSEK LİSANS TEZİ**

**İnşaat Mühendisliği Anabilim Dalı**

**Mart-2021**  
**KONYA**  
**Her Hakkı Saklıdır**

## ÖZET

### YÜKSEK LİSANS TEZİ

#### AYLIK ORTALAMA AKIM VERİLERİNİN YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ

Mustafa ASAAD

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Kağan ERYÜRÜK

2021, 65 Sayfa

Jüri

Dr. Öğr. Üyesi Kağan ERYÜRÜK

Doç. Dr. Ş. Yurdağül KUMCU

Dr. Öğr. Üyesi Vahdettin DEMİR

Geçmiş verilere dayalı akım tahmini, hidroloji mühendisliğinde önemli bir konudur. Zaman serisi verilerinin gelecekteki değerlerinin doğru tahmin edilmesi, dizayn, bakım, su yapılarının yönetimi, sel ve kuraklık gibi doğal afetlerin belirlenmesi için çok önemlidir. Hidrolojik süreçlerin incelenmesinde ve modelleme problemlerin çözülmesini amaçlayan, birçok farklı yapay zekâ tekniği geliştirilmiştir. Çalışmada, yapay sinir ağının en sık kullanılan modeli olan Çok Katmanlı Algılayıcı (ÇKA), derin öğrenme metodu olarak yeni geliştirilen Uzun Kısa Süreli Bellek (UKSB) ve yapay sinir ağı ile bulanık mantığın özelliklerini birlikte kullanan Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) gibi farklı yapay zekâ teknikleri kullanılmıştır.

Meram Çayı üzerindeki Küçükmuhsine AĞI'ndan ölçülen 1981-2017 yılları arasındaki ortalama aylık debileri kullanarak, gelecekteki 1 yıl, 2 yıl ve 3 yıl gibi uzun süreli tahminlerde bulunulmuştur. Oluşturulan modellerin performansları, üç istatistiksel kriter Ortalama Kare Hatası (OHK), Karekök Ortalama Kare Hatası (KOKH) ve Determinasyon katsayısı ( $R^2$ ) kullanılarak değerlendirilmiştir. Toplam 432 adet aylık verinin 346 adedi %80'i eğitim seti, kalan 86 adet %20 ise test veri setine ayrılmıştır. Her modelin optimum yapısını elde etmek için farklı girdiler ve eğitim parametreleri kullanılmış, en düşük hatayı verenler bu çalışmada değerlendirilmiştir. Sonuçlar, UKSB modelinin, ÇKA ve ASBÇS modellerine kıyasla daha yüksek tahmin doğruluğu ve daha düşük hata verdiğini göstermektedir. Ek olarak, UKSB tekniğinin gelecekteki uzun süreli tahminler için uygun olduğu görülmüştür.

**Anahtar Kelimeler:** Adaptif Sinirsel Bulanık Çıkarım Sistemi, Çok Katmanlı Algılayıcı, Uzun Kısa Süreli Bellek, Yapay Sinir Ağları, Zaman Serileri.

## **ABSTRACT**

## **MS THESIS**

# **FORECASTING MONTHLY AVERAGE STREAMFLOW USING ARTIFICIAL NEURAL NETWORKS**

**Mustafa ASAAD**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE  
OF NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE IN CIVIL ENGINEERING**

**Advisor: Assist. Prof. Kağan ERYÜRÜK, Ph. D.**

**2021, 65 Pages**

### **Jury**

**Assist. Prof. Kağan ERYÜRÜK, Ph. D.  
Assoc. Prof. Dr. Yurdagül KUMCU  
Assist. Prof. Vahdettin DEMİR, Ph. D.**

Streamflow forecasting based on past records is an important issue in hydrologic engineering. Estimating future values of time series data is critical for design, maintenance, and management of water structures, as well as determination natural disasters like floods and drought. Many different artificial intelligence techniques have been developed to investigate hydrological processes and solve modeling problems. In the study, different artificial intelligence techniques have been used such as, Multi Layer Perceptron (MLP), the most commonly used model of ANN, Long Short Term Memory (LSTM) which is newly developed as a deep learning method, and Adaptive Neuro Fuzzy Inference System (ANFIS), which uses the properties of artificial neural network and fuzzy logic together.

The average monthly streamflow between 1981-2017 years, measured from Küçükmuhsine AĞI on Meram Stream was used for future long term forecasting such as 1 year, 2 years and 3 years with the time series method. Three statistical criteria were used to evaluate the performance of the constructed models: Mean Square Error (MSE), Square Root Mean Square Error (RMSE), and Determination coefficient ( $R^2$ ). Of the total 432 monthly data, (346) 80% were used as training set, and the rest (86) 20% were used as test set. The optimal structure of each model was defined using various inputs and training parameters, and the models with the lowest error were evaluated in this study. The results show that the LSTM model has a better prediction accuracy and lower error compared to the MLP and ANFIS models. Additionally, the LSTM method has been found to be suitable for future long term predictions.

**Keywords:** Adaptive Neuro Fuzzy Inference System, Artificial Neural Network, Long Short Term Memory, Multi Layer Perceptron, Time Series.

## TEŐEKKÜR

Tez alıőmam sırasında kıymetli bilgi ve birikimleri ile bana yol gsterici ve yardımcı olan deęerli danıőman hocam sayın Dr. ęr. Üyesi Kaęan ERYÜRÜK'e, gerek tecrübesi ile gerekse fikirleri ile bana katkıları olan yardımcı danıőman hocam Dr. ęr. Üyesi Őule ERYÜRÜK'e teőekkür ederim.

alıőmam boyunca yanımda olan, desteklerini hiçbir zaman esirgemeyen aileme, her zaman bana destek olan ve bu günlere gelmemi saęlayan anneme teőekkürlerimi sunarım.

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>i</b>
<b>ABSTRACT.....</b>	<b>ii</b>
<b>TEŞEKKÜR.....</b>	<b>iii</b>
<b>İÇİNDEKİLER.....</b>	<b>iv</b>
<b>TABLolar LİSTESİ .....</b>	<b>vi</b>
<b>ŞEKİLLER LİSTESİ .....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>viii</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1. Akarsu Akım Tahmini .....	4
1.2. Zaman Serileri Modeli .....	5
<b>2. LİTERATÜR TARAMASI.....</b>	<b>7</b>
<b>3. YAPAY SİNİR SİSTEMLERİNİN TEMEL KAVRAMLARI VE YÖNTEMLERİ... 13</b>	
3.1. Yapay Sinir Sistemlerinin Gelişme Tarihi .....	14
3.2. Biyolojik Nöron .....	15
3.3. Yapay Nöron .....	17
3.4. Sinir Ağlarının Eğitimi.....	18
3.4.1. Denetimli eğitim.....	18
3.4.2. Denetimsiz eğitim.....	19
3.4.3. Takviyeli eğitim.....	19
3.5. Aktivasyon Fonksiyonları .....	19
3.5.1. Hiperbolik tanjant fonksiyonu .....	20
3.5.2. Sigmoid fonksiyon.....	21
3.5.3. Doğrusal aktivasyon fonksiyonu .....	20
3.6. Eğitim Algoritmaları .....	21
3.6.1. Levenberg-Marquardt (LM) .....	21
3.6.2. Bayesian Regülasyonu (BR).....	22
3.7. Metot .....	22
3.7.1. Yapay Sinir Ağları (YSA).....	22
3.7.1.1. Çok Katmanlı Algılayıcı (ÇKA).....	23
3.7.2. Tekrarlanan Sinir Ağları (TSA).....	25
3.7.2.1. Uzun-Kısa Süreli Bellek (UKSB).....	25
3.7.3. Bulanık mantık (BM) .....	27
3.7.3.1. Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS).....	29

<b>4. ÇALIŞMA ALANI, KULLANILAN VERİLER VE YAPILAN ÇALIŞMALAR .....</b>	<b>32</b>
4.1. Konya Kapalı Hazvası .....	32
4.1.1. Meram Çayı .....	32
4.2. Çalışmada Kullanılan Veriler.....	33
4.3. Modelin Performans Kriterleri.....	35
4.4. Yapılan Çalışmalar.....	36
<b>5. BULGULAR.....</b>	<b>44</b>
5.1. Geleceğe Yönelik Tahminler .....	44
5.1.1. Geleceğe yönelik 1 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi.....	44
5.1.2. Geleceğe yönelik 2 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi.....	46
5.1.3. Geleceğe yönelik 3 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi.....	48
<b>6. SONUÇLAR VE ÖNERİLER .....</b>	<b>51</b>
<b>KAYNAKLAR .....</b>	<b>54</b>
<b>EKLER .....</b>	<b>60</b>

## TABLULAR LİSTESİ

<b><u>Tablo</u></b>	<b><u>Sayfa</u></b>
4.1 Küçükmuhsine AGİ bilgileri .....	34
4.2 Küçükmuhsine AGİ aylık ortalama verilerin istatiksel parametreleri .....	34
4.3 Modelerin girdi kombinasyonları .....	37
4.4 ÇKA ve UKSB modellemelerinde kullanılan parametreler .....	38
4.5 ASBÇS modellemesinde kullanılan parametreler .....	38
4.6 Kurulan modellerin performans kriterleri .....	39

## ŞEKİLLER LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
3.1 Biyolojik nöron .....	16
3.2 Yapay nöron .....	17
3.3 Yapay sinir ağlarının yapısı .....	24
3.4 Tekrarlayan sinir ağındaki sıralı işlem .....	25
3.5 Uzun-Kısa Süreli Bellek (UKSB) sinir ağının yapısı .....	26
3.6 Bulanık sistemin şematik diagramı .....	28
3.7 ASBÇS mimarisi .....	30
4.1 Çalışma alanı lokasyonu .....	33
4.2 Eğitim ve test verilerinin aylık akım değerinin zaman serileri .....	34
4.3 ÇKA modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b) .....	40
4.4 UKSB modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b) .....	41
4.5 ASBÇS modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b) .....	42
5.1 ÇKA modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri .....	45
5.2 UKSB modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri .....	45
5.3 ASBÇS modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri .....	46
5.4 ÇKA modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri .....	47
5.5 UKSB modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri .....	47
5.6 ASBÇS modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri .....	48
5.7 ÇKA modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri .....	49
5.8 UKSB modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri .....	49
5.9 ASBÇS modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri .....	50

## SİMGELER VE KISALTMALAR

### Simgeler

$b$	Hücre durumu sapması
$b_f$	Unutma kapısı sapması
$b_o$	Çıkış kapısı sapması
$e$	Hata vektörü
$f_t$	Unutma kapısı
$g$	Gradyan
$H$	Hessian matrisi
$I$	Kimlik matrisi
$J$	Jakobiyen matrisi
$N$	Gerçek ve tahmin edilen değerlerin toplam sayısı
$Q_i$	Akım değeri
$Q_{ort}$	Ortalama akım değeri
$R^2$	Determinasyon katsayısı
$W$	Hücre durumu ağırlık matrisi
$W_f$	Unutma kapısı ağırlık matrisi
$W_o$	Çıkış kapısı ağırlık matrisi
$w_{ij}$	Bağlantı ağırlığı
$x_i$	Giriş parametresi
$X_{nor}$	Normalize edilen girdi
$X_{sta}$	Standardize edilen girdi
$\theta_i$	Eşik değeri
$\mu$	Öğrenme sabiti
$\sigma$	Sigmoid fonksiyonu

## Kısaltmalar

ADALINE	Adaptive Linear birleřtirici
AGİ	Akım Gözlem İstasyonu
ASBÇS	Adaptif Sinirsel Bulanık Çıkarım Sistemi
BÇS	Bulanık Çıkarım Sistemi
BM	Bulanık Mantık
BR	Bayesian Regülasyonu
ÇDOR	Çoklu Doğrusal Olmayan Regresyon
ÇKA	Çok Katmanlı Algılayıcı
DSİ	Devlet Su İşleri
GA	Genetik Algoritma
GPU	Graphics Processing Unit
İBSA	İleri Beslemeli Sinir Ağı
LM	Levenberg-Marquardt
MATLAB	Matris Laboratuvarı
NSV	Nash-Sutcliffe Verimliliği
OEHO	Otoregresif Entegre Hareketli Ortalama
OKH	Ortalama Kare Hatası
OMH	Ortalama Mutlak Hata
ORM	Otoregresif Model
R	Korelasyon Katsayısı
RE	Bağıl Hata
RTYSA	Radyal Tabanlı Yapay Sinir Ağı
SYİ	Standartlaştırılmış Yağış İndeksi
TSA	Tekrarlayan Sinir Ağı
UKSB	Uzun Kısa Süreli Bellek
ÜF	Üyelik Fonksiyonu
VK	Verimlilik Katsayısı
YSA	Yapay Sinir Ağları
YZ	Yapay Zeka

## 1. GİRİŞ

Akım veya kanal akışı, akarsu, nehir ve diğer kanallardaki su akışıdır ve su döngüsünün önemli bir unsurudur [1]. Akımın geçmiş ölçümler kullanılarak belirlenmesi; dizayn, plan, proje, yapım, bakım, özellikle su kaynaklarının yönetimi, sel ve kuraklık gibi doğal afetlerin belirlenmesinde gereklidir. Böylece, geçmişte ölçülen akım verilerine dayalı hidrolojik modelleme çalışmaları giderek daha önemli hale gelmektedir. Ölçüm cihazında bozulma olması ve ölçüm istasyonunda arazi koşullarının oluşmaması durumunda, eksik akım verilerinin tamamlanması önemlidir. Eksik akım ölçümlerinin uygun modellerle tahmin edilmesi, model performansının iyileştirilmesi ve daha iyi tahmin sonuçlarının elde edilmesi hem ekonomik hem de kullanım açısından kolaylık sağlamaktadır. Bu nedenle, son yıllarda akım tahmini için veriye dayalı teknikler gibi hidrolojik zaman serisi modelleri, yaygın olarak kullanılmaktadır. Uzun süreli serileri analiz etme kabiliyetine sahip veriye dayalı teknikler, hidrolojide birçok araştırmacı tarafından tercih edilmiştir. Veriye dayalı tekniklerden, yapay sinir ağları ve yetenekleri yerine getirmek amacıyla geliştirilen bilgisayar sistemleri olan uyarlanabilir sinir tabanlı bulanık çıkarım sistemi, su araştırmaları ve meteoroloji çalışmalarındaki sorunlar için incelenmiştir [2].

Yapay sinir ağları (YSA), insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışan yaklaşımlardır. İstisnasız tüm YSA yapılarının esin kaynağı biyolojik sinir ağlarının işleyiş yöntemleridir. Beynin işleyiş kuralları bir çok YSA modelinin geliştirilmesinde kullanılmıştır. Pek çok araştırmacı beyin fonksiyonlarını taklit edebilen YSA modelleri üzerinde çalışmıştır. YSA'nın, öğrenme özelliği bu yaklaşımın cazibesini arttırmıştır [3]. Sayısal bir hesaplama ortamı kullanılarak geliştirilen belirli matematiksel algoritmalara dayanan yapay beyin benzeri bir ağ, "Yapay Sinir Ağı (YSA)" olarak adlandırılır. MATLAB gibi araçlarla hesaplamalar yapılabilir. YSA sistemi insan beyni gibi modellenmiştir. Problemleri çözerken insan beyninin karar verme performansına benzer bir performans elde etmeye çalışır. Harici girişlere dinamik durum tepkisi ile bilgiyi işleyen çok sayıda basit ve çok iyi bağlantılı olan işlem elemanından oluşur. YSA, bir öğrenme işlemi aracılığıyla belirli uygulamalar için yapılandırılır. YSA, özel donanım veya gelişmiş yazılım içinde simüle edilebilir. YSA'lar

bilgisayarda yazılım paketleri olarak uygulanır veya Yapay Zekayı kontrol sistemlerine dahil etmek için kullanılır [4].

Karmaşık yapıda gerçekleşen hidrolojik süreçlerin incelenmesinde, deneysel yöntemlerin modellemesinin zor olması ve modellerin küçük değişikliklerden fazla etkilenmesi nedeniyle alternatif yöntemler araştırılmıştır. Deneysel yöntemlere alternatif olarak, hidrolojik ve hidrolik eşitliklerden yararlanarak geliştirilen ampirik yöntemler geliştirilmiş ve uygulanmıştır. Bu yöntemlerin uygulanması için uzun süreli düzenli şekilde ölçülmüş veriye ihtiyaç duyulması ve ölçümlerin ekonomik olmaması nedeniyle hidrolojik süreçleri açıklamak konusunda yapay zekâ modelleri tercih edilmiştir [5,6].

Sinir ağları tipik olarak katmanlar halinde düzenlenir. Aktivasyon fonksiyonların içeren katmanlar bir dizi birbirine bağlı nöron'dan oluşur. YSA, belirli sorunları çözmek için nöronlar aracılığıyla bilgileri paralel bir şekilde işler ve öğrenme yoluyla bilgi edinir. YSA yöntemi, kusursuz öğrenme kapasitesi nedeniyle çeşitli sorunları çözmek için güçlü bir teknik olarak belirlenmiştir. Bu yöntem kümeleme, tahmin ve tanımlama gibi çeşitli alanlarda başarıyla uygulanmıştır [7]. Ancak öğrenmenin çok iyi olmasına rağmen sonuç kesinliği yoktur. Bazen eğitim aşaması tamamen ezberleme mantığı ile de çalışabilmektedir. Bu yüzden mutlaka test verisi ayrılmalı ve öğrenme aşamasında elde edilen fonksiyonlar test için ayrılan verilerle denetlenmelidir. Eksik bilgi ile çalışabilmesi ve benzerlikler olduğunda karar verebilmesi bu sistemin birçok alanda kullanılabilmesine olanak sağlamaktadır [8,9].

Çeşitli bilim alanlarındaki modelleme ve optimizasyon problemlerinin çözümünde yapay zeka algoritmalarının kullanımı gün geçtikçe artmıştır. Aynı zamanda mevcut algoritmalara yeni yöntemlerin eklendiği görülmektedir. Örneğin Yapay Sinir Ağları (YSA), Bulanık Mantık, Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) ve Genetik Algoritmalar (GA) en çok kullanılan yapay zeka uygulamalarındandır [10].

Bulanık Mantık modelleri ile diğer modellerin arasındaki fark uzman görüşü tarafından eğitilmeleri olmasıdır. Uzmanların görüşü alınarak oluşturulan modeller deneysel veya matematiksel sonuçlarla karşılaştırılarak doğruluğu tespit edilir. Bu yöntemin çıkış mantığı kümeleme sisteminin daha esnek olması üzerine kurulmuştur. Herhangi bir olayın doğruluğu veya yanlışlığı belli ağırlıklar çerçevesinde kabul edilebilir [9].

Son yıllarda, sinir ağlarının ve bulanık mantığın entegrasyonu, nöro-bulanık sistemlere yeni araştırmalar doğurmuştur. Nöro-bulanık sistemler, bu iki alanın faydalarını tek bir yapıda yakalama potansiyeline sahiptir. Nöro-bulanık sistemler, otomatik bulanık if-then kuralı oluşturma ve parametre optimizasyonu için YSA'nın öğrenme yeteneğini etkili bir şekilde kullanarak, bulanık sistem yapısındaki temel sorunu ortadan kaldırır. Bu sistemler uzmanlardan gelen dil bilgisini ve modelleme sırasında ölçülen verileri kullanabilir. YSA ve BM yöntemlerinin entegrasyonu olan Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) doğrusal olmayan mühendislikte ve su kaynakları problemlerinin modellenmesinde kullanılmaktadır [11].

Diğer yapay zekâ tekniklerinde de olduğu gibi, bulanık mantık ve yapay sinir ağları tekniklerinin önemli özelliklerinden birisi, yoğun miktarda matematiksel – mantıksal teorem ve işlevleri beraberlerinde getirmeleridir. Bu durum, tekniklerin farklı problemlere uygulanabilmesi ve sürekli geliştirilebilir bir yapıda olmaları açısından önemli avantajlar sunmasına rağmen, yine ilgili tekniklerin öğrenilmesi aşamasında çeşitli dezavantajları da gün yüzüne çıkarmaktadır [12].

Akarsuların herhangi bir aşamasındaki bilgiler (rezervuar akışı, barajlar, taşkın kontrolleri), kanallar ve akarsu akım tahmini gibi su kaynakları projelerinin analizi, tasarımı ve inşasında çok önemlidir. Derin öğrenme algoritmalarında, UKSB adı verilen biyolojik sinir sisteminden esinlenen yapay sinir ağlarının bir model sınıfı olan girdi, unutma ve çıktı kapılarını kullanarak, bilgi akışını kontrol edip kaybolan gradyan problemlerini çözmek için kullanılır. UKSB modelinin diğer bir varsayılan davranışı, geçmiş bilgileri uzun süre hatırlama yeteneğidir. Ayrıca, zaman serisi verilerini işlemenin yanı sıra tahmin etme yeteneğine de sahiptirler. Akımın kısa veya uzun vadeli tahmini, gelecekteki genişletme veya azaltma için optimize etmeye ve planlamaya yardımcı olur. Bu veriler, geleceği tahmin etmek veya bazı analiz biçimlerini gerçekleştirmek, uzun vadeli eğilimleri belirlemek için analiz edilir. Su kaynakları planlaması dünyadaki birçok bölgede çok hassastır ve bu nedenle sürdürülebilir bir şekilde yönetilmesi gerekir [13].

Akım tahmininde bulunmak için son olarak TSA'dan (Tekrarlayan Sinir Ağı) geliştirilen UKSB (Uzun Kısa Süreli Bellek) modeli kullanılmıştır. Gelişmiş bir makine öğrenim modeli olan UKSB, gerçek ortamın karmaşıklığından, orta veya küçük nehirlerin istikrarsızlığından

kaynaklanan kaotik verilere karşı iyi çalışır. Üstelik, UKSB kullanımını içeren tahmin yöntemimi, UKSB'in belleğe sahip olduğundan dolayı geleneksel modelleri kullanan yöntemlere kıyasla yeniliğe sahiptir ve her çıktı önceki çıktılara dayanmaktadır. Bu nedenle zaman serisi verileri arasındaki bilgilerden yararlanma becerisine ve zaman içinde trend olan akım değişikliklerini tahmin etmede daha iyi çalışır [14]. UKSB modeli ayrıca Yapay Zeka ve Derin Öğrenme alanında çok gelişmiş bir model olarak kullanılmıştır. Bununla birlikte, hidroloji alanında zaman serisi verilerini işlemek için sadece birkaç çalışma TSA'ları veya UKSB'leri uygulamıştır [15].

Çalışmanın amacı, zaman serisi yöntemiyle geçmiş akım verilerini kullanarak geleceğe yönelik tahminler bulmaya çalışmaktır. Akım tahmini için en yaygın yapay sinir ağı olan Çok Katmanlı Algılayıcı (ÇKA), yapay sinir ağı ile bulanık mantık özelliklerinin birlikte kullanıldığı Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) ve Tekrarlamalı Yapay Sinir Ağının (TSA) bir türü olan Uzun Kısa Vadeli Bellek (UKSB) modelleri geliştirilmiştir. Her model için farklı girişler ve parametreler kullanılmıştır. Eğitilen modellerin çıktıları üç performans kriterleri ile karşılaştırılarak tahmin sonuçları değerlendirilmiştir. Belirlenen en iyi modelin tahmin sonucu gelecekte oluşacak akım değerleri olarak öngörülmüştür.

### **1.1. Akarsu Akım Tahmini**

Akım tahmini, su kaynakları sisteminin önemli bir unsuru ve su kaynakları mühendisleri için zorlu bir görevdir. Akarsu akımının tahmin edilmesi, su kaynaklarının ekonomik, yasal, teknik ve politik gibi öncelikler altındaki sistematik işleyişinin geliştirilmesine yardımcı olur. Su kaynağı yönetiminin verimli ve hassas bir kontrolü, tüm akım alanlarının mekansal değişkenliğini ve zamansallığını hesaba katan bir tahmin sistemi ile elde edilebilir. Su kaynağı sisteminin gerçek zamanlı olarak saatler ve günler halinde çalıştırılması, akım tahmini ile kolayca uygulanabilir. Haftalar ile aylar arasında değişen tahminler, sistem yönetimi ve planlamasını yani azaltma, kuraklık analizi, hidroelektrik planlaması ve geliştirme, sulama suyunun tahsisini analiz etmek için kullanılır [16].

Su kaynakları yöneticilerinin, yönetim kararlarının dikkate alındığı her konumdaki akım tahminlerine ihtiyacı vardır. Bu akım tahminleri, yağış-akış modellerinin sonuçlarına veya ölçüm sahalarında ölçülen geçmiş akımlara dayanabilir. Alternatif yönetim politikalarını modellemek için ilgi alanlarındaki bu ölçüye dayalı akımlar, doğal koşullar altında meydana gelmelidir. Bunlara, ölçülen akımlardan veya yağış-akış modellerinden türetilen ve daha sonra herhangi bir memba düzenlemesi ve sapmaları hesaba katacak şekilde ayarlanan “doğallaştırılmış akım” denir. Akım değeri, membada meydana gelen sapmalar ve rezervuar salınımları gibi akıntı yönündeki akımları değiştiren eylemleri yansıtır. Bu tür memba su yönetimi ve kullanım politikaları devam etmeyecekse, ölçülen akımları yönetim modellerinde kullanılmadan önce düzensiz veya doğal akımlara dönüştürülmelidir.

Ölçeksiz sahalardaki akımları tahmin etmek için kullanılan yöntem, su havzası veya nehir havzasının özelliklerine bağlıdır. Nemli bölgelerde akarsu akımlarının akıntı yönündeki akımın, yağış akışına bağlı olarak arttığı ve ortalama aylık veya mevsimsel yağışların mekansal dağılımının nehir havzasının bir bölümünden diğerine aşağı yukarı aynı olduğu, birim arazi alanı başına düşen akış tipik olarak sabit varsayılır.

## **1.2. Zaman Serileri Modeli**

Düzenlenmemiş doğal akımları zaman ve mekana dağıtmak için tasarlanmış çeşitli su yönetimi planlarını analiz ederken ve değerlendirirken, genellikle ayrı zaman serileri içindeki ortalama koşulları dikkate almak yeterlidir. Optimizasyon modellerinde, günlük akımların aksine haftalık, aylık veya mevsimsel akımlar yaygın olarak kullanılır. Alternatif su yönetimi planlarını ve işletme politikalarını belirlemek ve değerlendirmek için geliştirilen optimizasyon modellerinde genellikle dikkate alınan en kısa zaman serisi, suyun uygulanabilir nehir havzasının üst ucundan alt ucuna akması için geçen süreden daha az olmayan bir süredir. Modelde tanımlanan her bir yıl içindeki dönemin gerçek uzunluğu veya süresi, dönemden döneme değişebilir. Modellenmiş zaman serisi zaman serilerinin eşit olmasını gerektirmez. Genel olarak önemli olan modelde, arz ve taleplerdeki çeşitlilik tarafından büyük ölçüde belirlenen gerekli altyapı kapasitelerini ele almaktır. Zaman serilerinin sayısı ve süresi uygun şekilde seçilerek bu varyasyonlar modelde ele alınmalıdır.

Herhangi bir modele dahil edilecek zaman serilerinin sayısı ve süresiyle ilgili bir karar verirken dikkate alınması gereken bir diğer önemli faktör, modelin kullanılacağı amaçtır. Bazı analizler, yalnızca gelecekte belirli bir zamanda (örneğin tipik bir yıl) su kaynaklarını yönetmek için çeşitli mühendislik projelerinin tasarımlarını ve işletim politikalarını belirlemekle ilgilidir. Genellikle simülasyon modellerinde, bir sistemin o gelecek zaman diliminde en azından istatistiksel anlamda ne kadar iyi performans gösterebileceğine dair bir tahmin elde etmek için birçok yıllık hidrolojik kayıtlar kullanılır.

Zaman içinde değişen koşulların etkilerini tahmin etmek için dinamik planlama modelleri kullanılır. Sonuç olarak, dinamik modeller genellikle statik modellere göre çok daha uzun yıllara yayılır, ancak yıl içindeki dönemleri daha az olabilir [17].

## 2. LİTERATÜR TARAMASI

Aichouri [18], çalışmasında Cezayir’de yarı kurak ve Akdeniz ikliminde bulunan bir havzada yağış-akış ilişkisini modellemek için YSA geliştirilmiş ve kullanılmıştır. Geliştirilen sinir ağı modelin performansı, aynı verileri kullanarak gözlemlenen çoklu doğrusal regresyon modelleri ile karşılaştırılmıştır. Sinir ağı modelinin sürekli olarak üstün tahminler verdiği bulunmuştur. Yapay sinir ağı modellemesi yarı kurak ve Akdeniz bölgelerindeki havzalarınakımını tahmin edilmesinde umut verici bir teknik olarak görülmüştür.

Kişi [19], çeşitli YSA modelleri kurarak akarsu debi tahmini yapmaya çalışmıştır. Kısa süreli ve uzun süreli tahminin gelecek için önemini belirttiği çalışmasında, North Platte nehrine ait 2001 yılının günlük akım değerleri eğitim, 2002 yılının günlük akım değerleri ise test olarak kullanılmıştır. İleriye yönelik 1, 2 ve 3 gün sonraki akım değerleri tahmin edilmeye çalışılmış ve en iyi sonucu bulmak için 6 adet model kurulmuştur. Çalışmada dört farklı YSA algoritması kullanılmıştır. Sonuçlar YSA’ nın kullanılabilir olduğunu göstermiştir.

Erol Keskin vd. [20], çalışmalarında meteorolojik kuraklık analizi için Türkiye’nin Göller Bölgesi’nin çevresinde bulunan beş istasyonda standartlaştırılmış yağış indeksi (SYİ) uygulamışlardır. Analizler 3, 6, 9 ve 12 aylık veri setlerinde yapılmıştır. SYİ kuraklık sınıflandırmaları yapay sinir ağları (YSA) tarafından modellenmiştir. Modelin zaman serisi modelleme tekniklerinin çoğunun aksine, model yapısının önceden bilinmesini gerektirmemesi avantajına sahiptir. Gözlemlenen değerlerin ve modelleme sonuçlarının karşılaştırılması, SYİ-12 ve YSA modelleriyle daha iyi uyum sağladığını göstermektedir. SYİ-12 değerlerinin ortalama kare hata (OKH) değerleri eğitim aşamasında 0,061 ile 0,153 arasında değişirken, test aşamasında 0,09 ile 0,147 arasında değişmiştir.

Othman ve Naseri [21], yaptıkları çalışmada uzun vadeli rezervuar girişini tahmin etmek için mevcut aylık giriş verileri kullanarak, Yapay Sinir Ağı (YSA) yaklaşımını sunmuşlardır. YSA modellerini geliştirmek için Levenberg-Marquardt (LM) geri yayılım algoritması kullanılmıştır. YSA modellerinin geliştirilmesinde, farklı sayıda nöron gizli katmanına sahip farklı ağlar değerlendirilmiştir. Ağları eğitmek ve test etmek için toplam 21 yıllık geçmiş veriler kullanılmıştır. (4-5-1) yapısına sahip ağ optimum YSA ağı olarak seçilmiştir. Önerilen modelin

doğruluğunu değerlendirmek için Ortalama Kare Hatası (OKH) ve Korelasyon Katsayısı (R) kullanılmıştır. Ağ sonuçları eğitim ve test veri setleri için sırasıyla, 0.0188 ile 0.0283 OKH değerleri, 0.7282 ile 0.7228 R değerlerini elde etmiştir.

Motamednia vd. [22], çalışmalarında İran'ın kuzeybatısında Razavi Horasan Eyaleti'nde bulunan yarı kurak bir bölge olan Bar havzasının günlük akımlarını tahmin etmek için YSA modellerinin kullanımını değerlendirmişlerdir. İki farklı sinir ağı modeli, çok katmanlı algılayıcı (ÇKA) ve radyal tabanlı yapay sinir ağı (RTYSA) geliştirilmiş, elli beş yıllık bir süre için (1951-2006) akım tahmin etme yetenekleri karşılaştırılmıştır. En iyi performans üç istatistiksel kriterlere dayanarak elde edilmiştir. ÇKA'nın yağış-akış ilişkisinin iyi bir genellemesini gösterdiğini ve RTYSA'dan daha iyi olduğu bulunmuştur. Ayrıca, ÇKA'nın bağıl hata (RE) ve karekök ortalama kare hatası (KOKH) değerleri dikkate alındığında en iyi model 46.21 ve 0.75 değerlerini elde ederken, RTYSA modeli sırasıyla 177.60 ve 0.82 değerlerini elde etmiştir.

Olawoyin ve Chen [23], yaptıkları çalışmada dört farklı çok katmanlı algılayıcı (ÇKA) yapay sinir ağları tartışılmış ve bu görev için Otoregresif Entegre Hareketli Ortalama (OEHO) ile karşılaştırmışlardır. Modeller, iki istatistiksel performans değerlendirme ölçüsü Karekök Ortalama Kare Hatası (KOKH) ve Determinasyon katsayısı ( $R^2$ ) kullanılarak değerlendirilmiştir. Sonuçlar, her bir gizli katmanda tanh aktivasyon fonksiyonunu kullanan 4 katmanlı bir ÇKA mimarisinin, çıktı katmanında en düşük doğrusal tahmin hatasına ve yapılandırılmış fonksiyonun çok katmanlı algılayıcı sinir ağları arasında en yüksek belirleme katsayısına sahip olduğunu göstermiştir. Ek olarak, performans sonucunun karşılaştırmalı analizi, çok katmanlı algılayıcı sinir ağı ÇKA'nın OEHO modelinden daha düşük bir tahmin hatasına sahip olduğunu ortaya koymuştur.

Cigizoglu [24] çalışmasında, Türkiye'nin Doğu Akdeniz bölgesindeki nehirlerle ait günlük akım verilerinin tahmin, öngörü ve uyarılmasında yapay sinir ağlarının (YSA) uygulanabilirliği araştırılmıştır. Çalışma boyunca YSA yapısı olarak çok katmanlı algılayıcı ağ kullanılmış, bir gün ve altı gün sonraki tahminler incelenmiştir. YSA'lar daha sonra genelleme yeteneklerini, yani eğitilmiş modelle farklı bir zaman serisinin tahminini araştırmak için uygulanmıştır. Sonuçlar bir sinir ağı çözümünün geleneksel modellere göre verilerle daha sıkı uyum sağlayabileceğini göstermiştir.

El-Shafie vd. [25], çalışmalarında adaptif sinirsel bulanık çıkarım sistemi (ASBÇS) modeli, Malezya'daki Klang Nehri'nin yağış miktarını aylık olarak tahmin etmek için önerilmiştir. ASBÇS ve YSA modellerini eğitmek ve test edebilmek için 1997-2008 yıllarına ait istatistiksel veriler Klang baraj'ın geçit verilerinden elde edilmiştir. Modelin optimum yapısı ve optimum girdi örüntüsü deneme ve yanılma yoluyla belirlenmiştir. Girdi olarak farklı yağış kombinasyonları üretilmiştir. Her ağın etkinliğini ve kesin tahmin yapabilme yeteneğini değerlendirmek için beş farklı kriter kullanılmıştır. ASBÇS modelinin performansı, yapay sinir ağı (YSA) ile karşılaştırılmıştır. Sonuç, ASBÇS modelinin YSA modeline kıyasla daha yüksek yağış tahmin doğruluğu ve daha düşük hata verdiğini göstermektedir.

Nawaz vd. [26], ASBÇS yöntemi ile nehir aşaması tahmini yapmışlardır. Malezya'daki Bekok Nehri'nin tropikal havzasındaki yağmur ve önceki aşamaları girdi olarak kullanılmıştır. ASBÇS modelinin performansını değerlendirmek için harici girdilere sahip otoregresif model (ORM) olarak bilinen geleneksel bir modelleme tekniği ile karşılaştırılmıştır. Çalışmanın sonuçları, verimlilik katsayısı (VK), determinasyon katsayısı ( $R^2$ ), karekök ortalama kare hata (KOKH) ve ortalama mutlak hata (OMH) gibi çeşitli istatistiksel ölçütlere göre değerlendirilmiştir. Sonuçlar, ASBÇS'in nehir aşamasını başarıyla tahmin edebildiğini ve ORM modelinden önemli ölçüde daha iyi performans verdiğini göstermiştir. ASBÇS'in ORM modeline kıyasla pik nehir aşamalarını tahmin etmede daha iyi olduğu bulunmuştur.

Aldrian ve Setiawan Djamil [27], yağış miktarını tahmin etmek için hava durumu verilerine dayanarak ASBÇS modelini kullanmışlardır. Bu çalışmada, Endonezya' nın PT Timika lokasyonundaki günlük yağış tahmini için çok parametrelili Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) uygulamışlardır. Bağıl nem, sıcaklık, basınç ve yağış verilerini kullanmışlardır. Sonuç olarak ASBÇS'in farklı büyüklüklere ve ölçek boyutlarına duyarlı olduğunu, fakat yağış gibi stokastik süreç için uygun bir araç olmadığını bulmuşlardır.

Bacanli vd. [28], Adaptif Sinirsel Bulanık Çıkarım Sisteminin (ASBÇS) kuraklık tahmini ve kuraklık indekslerinin nicel değeri olan Standardize Yağış Endeksi (SYİ) için uygulanabilirliği araştırılmıştır. Türkiye' nin İç Anadolu bölgesinde bulunan 10 yağış ölçüm istasyonu çalışma alanı olarak seçilmiştir. ASBÇS tahmin modellerini oluşturmak için aylık ortalama yağış ve SYİ değerleri kullanılmıştır. Veri setleri tüm istasyonlar için 1964-2006 yılları arasında ölçülen toplam 516 veri kaydını içerir. Veri setleri eğitim ve test olmak üzere iki alt

gruba ayrılmıştır. SYİ için 1-12 aylık zaman ölçeklerinde farklı ASBÇS tahmin modelleri eğitilmiş ve test edilmiştir. ASBÇS tahmin modellerinin sonuçları ile gözlemlenen değerler karşılaştırılmış ve modellerin performansları değerlendirilmiştir. Aynı zamanda, en uygun modeller İleri Beslemeli Sinir Ağları (İBSA) tarafından eğitilmiş ve test edilmiştir. Sonuçlar ASBÇS'in başarıyla uygulanabileceğini, kuraklık tahmini için yüksek doğruluk ve güvenilirlik sağlayabileceğini göstermektedir.

Anusree ve Varghese [29], Thrissur bölgesinde bulunan Karuvannur nehri havzasının çıkışındaki günlük akımı tahmin etmek için yapay sinir ağları (YSA), adaptif sinirsel bulanık çıkarım sistemleri (ASBÇS) ve çoklu doğrusal olmayan regresyon (ÇDOR) yöntemlerini kullanmışlardır. Modelleri geliştirmek için dokuz yağış ölçüm istasyonundan ölçülen yağış verileri kullanılmıştır. Simülasyonlar giriş vektörleri, önceki yağış ve akımın farklı kombinasyonları ile farklı zaman gecikmeleri içermiştir. Modellerin performansları karekök ortalama kare hataları KOKH ve Nash-Sutcliffe model verimlilik değerleri ile değerlendirilmiştir. Sonuçlar, ASBÇS modelinin YSA ve ÇDOR modellerine göre günlük akımı daha doğru tahmin ettiğini göstermiştir.

Lohani vd. [30], çalışmalarında aylık rezervuar giriş tahminlerinde otoregresif (ORM), yapay sinir ağları (YSA'lar) ve adaptif sinir tabanlı bulanık çıkarım sistemine (ASBÇS) bağlı aylık rezervuar giriş tahmin modelleri geliştirmişler ve sonuçları karşılaştırılarak incelemişlerdir. Akım verilerinde aylık periyodikliğin etkisine dikkat etmek için YSA ve ASBÇS modellerine döngüsel terimler dahil edilmiştir. Hindistan'nın, Bhakra Baraj'ındaki Sutlej Nehri'nin zaman serisi akım verileriyle çalışan birkaç YSA ve uyarlanabilir nöro-bulanık model, farklı giriş vektörleriyle eğitilmiştir. Seçilen YSA ve uyarlanabilir sinir bulanık çıkarım sistemi (ASBÇS) modellerinin performansını değerlendirmek için otoregresif (ORM) modellerle karşılaştırma yapılmıştır. Sürekli olarak ASBÇS, ORM ve YSA modellerinden daha doğru tahmin vermiştir. Döngüsel terimlerle birleştirilen önerilen ASBÇS modelinin, rezervuarın planlanması ve işletilmesi için aylık giriş tahminlerinin daha iyi temsilini sağladığını göstermiştir.

Gemici vd. [31], Kızılırmak nehrinin debi tahminleri için çok katmanlı yapay sinir ağları (ÇKYSA), radyal tabanlı yapay sinir ağları (RTYSA) ve adaptif ağ tabanlı bulanık çıkarım sistem (ASBÇS) modelleri geliştirilmiştir. Taban eğimi, taban pürüzlülük katsayısı, enkesit

dilim genişliği, dilimden geçen su seviyesi ve nehir enkesit genişliği değerleri giriş verisi olarak kullanılmıştır. Ölçülen değerlerle modellerin tahminleri arasındaki hatalar belirlenmiş, model performansları karşılaştırılmıştır. Debinin belirlenmesinde YSA ve bulanık mantık modellerinin oldukça başarılı olduğu, model performanslarının birbirine yakın olduğu görülmüştür. En iyi performans ASBÇS modelinden elde edilmiştir.

Sahoo vd. [32], düşük akımlı zaman serisi tahmini için tekrarlayan sinir ağı olan uzun kısa süreli bellek (UKSB) ve yapay zeka (YZ) yönteminin elverişliliğini araştırmışlardır. Bu çalışmada, Hindistan'ın Mahanadi Nehri havzasında bulunan Basantapur ölçme istasyonundan toplanan günlük debi verileri kullanılmıştır. Modelin performansını değerlendirmek için karekök ortalama kare hatası (KOKH), Nash-Sutcliffe verimliliği (NSV), korelasyon katsayısı (R) ve ortalama mutlak hata (OMH) gibi farklı kriterler seçilmiştir. Ek olarak, UKSB'in TSA'na ve diğer yonteme uyarlanabilirliğini karşılaştırmak için tekrarlayan sinir ağı (TSA) modeli kullanılmıştır. Sonuçlar, UKSB modelinin (R = 0.943, NSV = 0.878, KOKH = 0.487), TSA modelinden (R = 0.935, NSV = 0.843, KOKH = 0.516) ve diğer yöntemden (R = 0.866, NSV = 0.704, KOKH = 0.793) daha üstün olduğunu göstermiştir.

Hu vd. [14], çalışmalarında tahmin yapmak için zaman serisi verileri alanını hedefleyen Uzun-Kısa Süreli Bellek (UKSB) derin öğrenme modelini kullanmışlardır. Akarsu akım verilerini tahmin etmek için Çin'nin Tunxi bölgesindeki bir hidrolojik istasyondan akarsu akım verileri ve civarda bulunan 11 yağış istasyonundan yağış verileri kullanılmıştır. Tahmin sonuçları karekök ortalama kare hatası (KOKH), ortalama mutlak hata (OMH) ve determinasyon katsayısı ( $R^2$ ) kriterlerini kullanarak değerlendirilmiştir. UKSB'in tahmin değerlerini, diğer modellerin tahminleriyle karşılaştırarak UKSB 'in daha iyi performansa 82.007 KOKH, 27.752 OMH ve 0.970  $R^2$  sahip olduğunu göstermiştir.

Xu vd. [33], ağ yapılarının ve parametrelerinin nehir akım tahminleri üzerindeki etkisini anlamak için UKSB ağlarının performansını değerlendirmişlerdir. Sırasıyla 10 günlük ortalama akım tahminleri ve günlük akım tahminleri için farklı özelliklere sahip iki nehir havzası Hun nehri ve yukarı Yangtze nehir havzaları, durum çalışmaları olarak kullanılmıştır. UKSB ağı birkaç hidrolojik modelle kıyaslandığında, hidrolojik modellemede doğrusal olmayan ve karmaşık süreçleri öğrenmedeki güçlü kapasitesini gösteren belirleme katsayısı, Nash-Sutcliffe

Verimliliği ve bağıl hata gibi üç değerlendirme kriteri açısından iyi bir performans elde etmektedir.

Zhang vd. [15], yaptıkları çalışmada yeraltı su tabakası derinliğini tahmin etmek için UKSB modeli önermişlerdir. Önerilen model, Çin'in Kuzeybatı'sındaki kurak Hetao Sulama Sementi'nin beş alt bölgesinden 14 yıllık (2000-2013) veriler kullanılarak uygulanmış ve değerlendirilmiştir. Önerilen modelde, aylık su saptırma, buharlaşma, yağış, sıcaklık ve zaman girdi verileri olarak kullanılmıştır. Verileri aynı ölçekte sağlamak, verileri önceden işlemek için standardizasyon yöntemi kullanılmıştır. 14 yıllık veriler eğitim seti (2000-2011) ve doğrulama seti (2012-2013) olmak üzere iki gruba ayrılmıştır. UKSB modeli, nispeten düşük  $R^2$  değerlerine (0.004-0.495) ulaşan ileri beslemeli sinir ağının (İBSA) sonuçlarıyla karşılaştırıldığında, daha yüksek  $R^2$  değerleri (0.789-0.952) elde etmiştir. Sonuçlar UKSB modelinin daha başarılı olduğunu göstermiştir.

Kratzert vd. [34], 241 havzanın günlük akışını simüle etmek için UKSB ağını uygulamışlardır. UKSB ağının sonuçları, hem bölgesel düzeyde hem de bireysel havza düzeyinde kalibre edilmiş hidrolojik modellere kıyasla daha iyi performans gösterdiği gözlemlenmiştir.

Le vd. [35], sel tahmini için Uzun Kısa Süreli Bellek (UKSB) sinir ağı modelini önermişlerdir. Girdi verileri için günlük debi ve yağış değerleri kullanılmıştır. Çalışma alanı olarak Vietnam'daki Da River havzası seçilmiş ve iki farklı girdi veri seti kombinasyonu, Hoa Binh İstasyonu'nun bir gün, iki gün ve üç gün sonraki akış oranı tahmini için kullanılmıştır. Modelin öngörü yeteneği oldukça başarılı bulunmuş ve Nash – Sutcliffe verimliliği (NSV) sırasıyla % 99, % 95 ve % 87'ye ulaşmıştır. Sonuç olarak UKSB modelinin sel tahmini için uygun bir yöntem olduğu görülmüştür.

Hu vd. [36], sel olaylarına dayalı yağış-akış sürecini simüle etmek için YSA ve UKSB modellerini uygulamışlardır. Veriler 1971-2013 yılları aralığında Fen Nehri havzasında 14 yağış istasyonu ve havzadaki hidrolojik istasyonu aracılığıyla gözlemlenmiştir. Bu sürede veriler 98 yağış-akış olayından alınmıştır. Verilerin 86 yağış-akış olayı eğitim seti olarak ve geri kalanı test seti olarak kullanılmıştır. Sonuçlar, her iki ağın yağış akış modelleri için uygun olduğunu, kavramsal ve fiziksel tabanlı modellerden daha iyi olduğunu göstermiştir. UKSB modelleri, YSA modellerine kıyasla daha iyi performans göstermiştir.

### 3. YAPAY SİNİR SİSTEMLERİNİN TEMEL KAVRAMLARI VE YÖNTEMLERİ

Sinir ağlarının nasıl tanımlanacağı sorusuna verilebilecek bir çok farklı yanıt vardır. Bir taraftan cevap, sinir ağlarının basitçe matematiksel algoritmalar sınıfı olabilir, çünkü bir ağ temelde büyük bir algoritma sınıfı için bir grafik gösterimi olarak görülebilir. Bu tür algoritmalar, bir dizi özel soruna çözümler üretir. Diğer taraftan cevap, bunların canlı organizmalarda bulunan biyolojik sinir ağlarını taklit eden sentetik ağlar olabilirler. Günümüzün biyolojik sinir ağları ve organizmalar hakkındaki sınırlı bilgisi ışığında daha makul cevap, algoritmik olana daha yakın görünüyor [37].

Yapay sinir ağının genel bir tanımının yapılması gerekirse; yapay sinir ağı, insan beyninin çalışma ve düşünebilme yeteneğinden yola çıkılarak oluşturulmuş bir bilgi işlem teknolojisidir. YSA'ların öğrenme özelliği sayesinde geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmektedirler. Yine öğrenme yeteneği sayesinde, bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir.

Sadece sayısal bilgilerle çalışan, bilgiyi saklama, örnekleri kullanarak öğrenme ve görülmemiş örnekler hakkında bilgi üretebilme, sınıflandırma ve şekil tamamlama gibi özelliklere sahip olan Yapay Sinir Ağları, günlük hayatımızda finansal konulardan mühendislik ve tıp bilimine, üretim uygulamalarından arıza tespit ve analizine kadar birçok alanda uygulanabilmektedir [38].

Biyolojik sistemlerin, açık sayısal işlemlere başvurmadan karmaşık görevleri yerine getirebildiği iyi bilinmektedir. Özellikle biyolojik organizmalar, zaman içinde kademeli olarak öğrenme yeteneğine sahiptir. Bu öğrenme yeteneği, biyolojik nöronların dış uyarıcılara maruz kalarak öğrenme ve genelleme yeteneklerini yansıtır. Sinir sistemlerinin bu tür özellikleri, karmaşık verileri işlemek için tasarlanabilen hesaplama modelleri olarak onları çekici kılar. Örneğin, biyolojik organizmaların örneklerden öğrenme yeteneği, makine öğrenimi için olasılıkları önerir.

Sinir ađları veya daha spesifik olarak yapay sinir ađları, biyolojik sinir sistemleri anlayışımızdan ilham alan matematiksel modellerdir. Çok sayıda girdiyi kabul edebilen ve yalnızca eğitim örneklerinden öğrenebilen hesaplama yöntemleri olarak caziptirler. Yapay sinir ađları, biyolojik sinir sistemleri için matematiksel modeller olarak, her türlü sistemin girdileri ve çıktıları arasındaki ilişkileri kurmada yararlı olurlar [39].

### 3.1. Yapay Sinir Sistemlerinin Gelişme Tarihi

1943 yılı genellikle yapay sinir sistemlerinin gelişiminde ilk yıl olarak kabul edilir. McCulloch ve Pitts [40] temel bir bilgisayar nöronun ilk biçimsel modelini özetledi. Model, mantık işlemlerini gerçekleştirmek için gerekli tüm öğeleri içeriyordu ve bu nedenle bir aritmetik-mantık hesaplama ögesi olarak işlev görebiliyordu.

Donald Hebb [41] ilk olarak, şimdi Hebbian öğrenme kuralı olarak adlandırdığımız nöronun bağlantılarını güncellemek için bir öğrenme planı önerdi. Bilginin bağlantılarda saklanabileceğini ve bu alanda gelecekteki gelişmeler üzerinde derin etkisi olan öğrenme tekniğini öne sürdü. Hebb'in öğrenme kuralı, sinir ađları teorisine birincil katkılarda bulundu.

Bu aşamada, algılayıcı adı verilen nöron benzeri öge 1958'de Frank Rosenblatt tarafından icat edildi. Bu, eşik öğeleriyle bağlantıları değiştirerek belirli modelleri sınıflandırmayı öğrenebilen eğitilebilir bir makineydi [42]. Fikir, mühendislerin ve bilim adamlarının hayal gücünü yakaladı ve bugün hala kullandığımız temel makine öğrenimi algoritmalarının temelini oluşturdu. 1960'ların başında ADALINE (Adaptive Linear birleştirici) adlı bir cihaz tanıtıldı ve Widrow-Hoff öğrenme kuralı adı verilen yeni, güçlü bir öğrenme kuralı Bernard Widrow ve Marcian Hoff [43,44] tarafından geliştirildi. Kural, eğitim sırasında örüntü sınıflandırmasını içeren toplanan kare hatasını en aza indirdi [37].


1980'lerde ve 1990'ların başlarında hesaplama gücünün eklenmesi sinir ađlarının görevleri yerine getirmesine yardımcı olmuş gibi görünüyordu, ancak bu dönemin donanım ve eğitim algoritmaları birçok katmana sahip sinir ađlarını etkili bir şekilde eğitemedi.

Sinir ağlarının yükselişi, Hinton 2006 yılında derin sinir ağlarını eğitmek için radikal yeni bir yol sağladığında gerçekleşti. Yüksek hızlı Graphics Processing Unit (GPU)'deki son gelişmeler, programcıların üç veya daha fazla katmanlı sinir ağlarını eğitmesine izin verdi. Böylece, programcılar derin sinir ağlarının faydalarını fark ettikçe bu teknolojide yeniden canlanmaya yol açtı [45].

### 3.2 Biyolojik Nöron

Nöron adı verilen temel sinir hücresi, biyolojik sinir ağının temel yapı taşıdır. Şematik diyagramı Şekil 3.1 de gösterilmiştir. Tipik bir hücrenin üç ana bölgesi vardır: soma, akson ve dendritler olarak da adlandırılan hücre gövdesi. Dendritler, nöronun gövdesi etrafında çok ince liflerden oluşan bir çalı olan dendritik bir ağaç oluşturur. Dendritler, iletim hatları görevi gören akson uzunluğundaki lifler aracılığıyla nöronlardan bilgi alır. Akson, nörondan gelen uyarıları taşıyan uzun silindirik bir bağlantıdır. Bir aksonun uç kısmı ince bir arborizasyona ayrılır. Her bir dalı, neredeyse komşu nöronların dendritlerine dokunan küçük bir uç ampulde sonlanır. Akson-dendrit temas organı sinaps olarak adlandırılır. Sinaps, nöronun sinyalini komşu nörona ilettiği yerdir. Bir sinapsa ulaşan ve dendritler tarafından alınan sinyaller elektriksel dürtülerdir.

Bir nörona gelen dürtüler yalnızca komşu nöronlar ve nöronun kendisi tarafından üretilebilir. Genellikle, hedef hücreyi ateşlemek için belirli sayıda gelen dürtü gerekir. Zamanla yakın aralıklı olan ve eşzamanlı olarak gelen dürtülerin nöronun ateşlenmesine neden olma olasılığı daha yüksektir. Daha önce de belirtildiği gibi, biyolojik ağların gelen sinyallerin zamansal entegrasyonunu ve toplamasını gerçekleştirdiği gözlemlenmiştir. Biyolojik nöronun karakteristik özelliği, üretilen sinyallerin büyüklük bakımından önemli ölçüde farklılık göstermemesidir; sinir lifindeki sinyal ya yoktur ya da maksimum değere sahiptir. Bilgi sinir hücreleri arasında ikili sinyaller aracılığıyla iletilir [37].



Şekil 3.1 Biyolojik nöron [37]

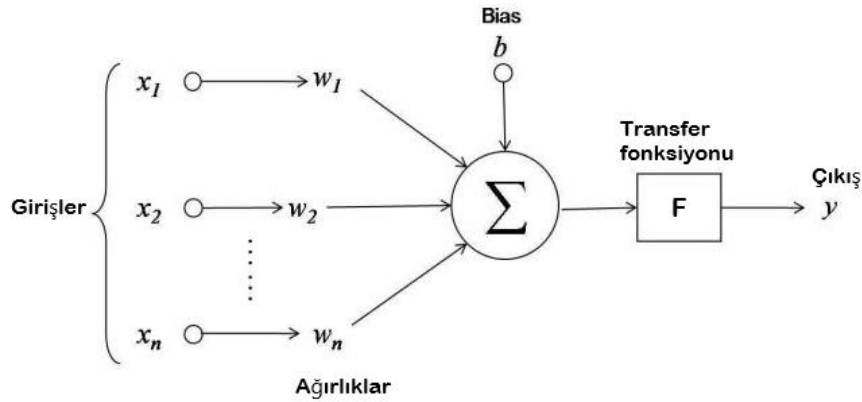
Nöron tarafından iletilen bu sinyal bir analog sinyaldir. Modern bilgisayarların çoğu dijital makinelerdir ve bu nedenle dijital bir sinyale ihtiyaç duyar. Dijital bilgisayar, sırasıyla 0 ve 1 rakamları kullanarak bilgileri kapalı veya açık olarak işler. Bir elektrik sinyalinin varlığı 1 değeriyle gösterilirken, elektrik sinyalinin olmaması 0 değeriyle gösterilir.

Biyolojik sinir ağları analogdur. Analog sinir ağlarını dijital bir bilgisayarda simüle etmek bazı zorlukları ortaya çıkarabilir. Nöronlar, dendritlerinden bir analog sinyali kabul eder. Bu sinyal analog olduğu için her sinyalin voltajı değişecektir. Voltaj belirli bir aralık dahilindeyse, nöron ateşlenecektir. Bir nöron ateşlendiğinde, ateşleyen nörondan diğer nöronlara yeni bir analog sinyal iletilir. Bu sinyal, ateşleyen nöronun aksonu üzerinden iletilir.

Nöronu ateşleyerek veya ateşlemeyerek karar verir. Alınan kararlar son derece düşük düzeyli kararlardır. Daha yüksek seviyeli kararlar, birçok nöronun kolektif girdisinin ve çıktısının sonucudur [46].

### 3.3. Yapay Nöron

Bir yapay nöron temel olarak girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere beş kısımdan oluşmaktadır. Bir işlemci nöronun gösterimi Şekil 3.2 de verilmiştir.



Şekil 3.2 Yapay nöron [47]

Burada  $x$  girişleri,  $y$  çıkışı,  $F$  fonksiyonu,  $w$  ise ağırlıkları ifade etmektedir. Bu girişler dış kaynaklardan veya diğer işlem elemanlarından gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıklarında farklıdır.

YSA'da girilen giriş değerlerine önce toplama fonksiyonları uygulanır ve her bir işlem elemanının çıkış değeri  $y$ 'nin hesaplanması için ilk önce;

$$v = \sum_{i=1}^n x_i w_{ij} - \theta_i \quad (3.1)$$

Burada  $x_i$   $i$ 'inci girişi,  $w_{ij}$   $j$ 'inci elemandan  $i$ 'inci elemana bağlantı ağırlığını ve  $\theta_i$  eşik değerini göstermektedir. Daha sonra bu çıkış değerleri sigmoid bir aktivasyon fonksiyonuna uygulanırsa, sonuçta çıkış değeri;

$$y = F(v) = \frac{1}{1 + e^{-v}} \quad (3.2)$$

İşlemci eleman çıkışında kullanılan sigmoid fonksiyona göre çıkış değerinin hesaplanması gösterilmiştir. Bu işlemci elemanının çıkış değeri diğer işlemci elemanlarına giriş veya ağın girişi olabilir [3].

### 3.4. Sinir Ağlarının Eğitimi

Bir sinir ağını oluşturan nöronlar, sinapslar aracılığıyla birbirine bağlanır. Bu bağlantılar, bilgi işlenirken nöronların birbirlerine sinyal göndermesine izin verir. Tüm bağlantılar eşit değildir. Her bağlantıya bir bağlantı ağırlığı verilir. İki nöron arasında bağlantı yoksa bağlantı ağırlıkları sıfırdır. Bu ağırlıklar, sinir ağının çıktısını belirler; bu nedenle bağlantı ağırlıkları sinir ağının hafızasını oluşturduğu söylenebilir.

Eğitim, bu bağlantı ağırlıklarının belirlendiği süreçtir. Çoğu eğitim algoritması, ağırlık matrisine rastgele sayılar atayarak başlar. Daha sonra sinir ağının geçerliliği incelenir. Daha sonra ağırlıklar sinir ağının ne kadar iyi performans gösterdiğine ve sonuçların geçerliliğine göre ayarlanır. Doğrulama hatası olarak kabul edilen bu işlem, bir limit dahilinde oluncaya kadar tekrar edilir. Sinir ağlarını eğitmenin birçok yolu vardır. Sinir ağı eğitim yöntemleri genellikle denetimli, denetimsiz ve çeşitli hibrit yaklaşım kategorilerine ayrılır [46].

#### 3.4.1. Denetimli eğitim

Denetimli eğitimde, hem girdi hem de çıktı sağlanır. Ağ daha sonra girdileri işler ve elde ettiği çıktıları istenen çıktılarla karşılaştırır. Hatayı belirlemek için ağın hesaplanan çıktısı ile düzeltilmiş beklenen çıktı arasında bir karşılaştırma yapılır. Hata daha sonra ağ parametrelerini değiştirmek için kullanılabilir ve bu da performansta bir iyileşme ile sonuçlanır. Başka bir deyişle, girdilerin başlangıçta ve çıktıların nedensel dizinin sonunda olduğu varsayılır. Modeller, girdiler ve çıktılar arasında aracı değişkenler içerebilir. Denetimli eğitim, sinir ağı eğitiminin en yaygın şeklidir.

### 3.4.2. Denetimsiz eğitim

Diğer eğitim türü, denetimsiz eğitim olarak adlandırılır. Denetimsiz eğitimde, ağa girdiler sağlanır ancak istenen çıktılar verilmez. Sistemin kendisi daha sonra giriş verilerini gruplamak için hangi özellikleri kullanacağına karar vermesi gerekir. Denetimsiz öğrenme, denetimli öğrenmeden çok daha zor görünür ve bu tür bir eğitim genellikle karar sorunu yapısına uyar. Denetimsiz bir öğrenme görevi, sınıflandırılmamış verilerdeki gizli yapıyı bulmaya çalışmaktır [7]. Denetimsiz eğitim, beklenen çıktılar sağlanmaması dışında denetimli eğitime benzer. Denetimsiz eğitim genellikle, sinir ağı kullanıldığında girdileri birkaç gruba ayırmak için gerçekleşir. Eğitim ilerledikçe, sınıflandırma grupları sinir ağı tarafından "keşfedilir".

### 3.4.3. Takviyeli eğitim

Hem denetimli hem de denetimsiz eğitimin yönlerini birleştiren birkaç hibrit yöntem vardır. Böyle bir yonteme pekiştirme (takviyeli) eğitimi denir. Bu yöntemde denetimsiz eğitimde yapıldığı gibi, beklenen çıktıları içermeyen örnek verilerle bir sinir ağı sağlanır. Bununla birlikte sinir ağı her çıktı için girdiye göre çıktının doğru veya yanlış olduğu söyler [46].

## 3.5. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, sinir ağlarında yaygın olarak kullanılmaktadır. Bir sinir ağı için birkaç önemli işlevi yerine getirirler. Bir aktivasyon fonksiyonu kullanmanın birincil nedeni, sinir ağına doğrusallık olmayışı tanıtmaktır. Sinir ağlarının öğrenmesini beklediğimiz çıktı nadiren doğrusaldır.

En yaygın iki aktivasyon fonksiyonu sigmoid ve hiperbolik tanjant aktivasyon fonksiyonudur. Hiperbolik tanjant aktivasyon fonksiyonu, daha geniş sayı aralığına izin verdiği için sigmoid fonksiyonuna kıyasla daha yaygındır [48]. Bu aktivasyon veya transfer

fonksiyonları, sinir ağının çıktısını uygun aralıklarda ölçeklendirir. Sinir ağı için aktivasyon fonksiyonu seçmek önemli bir husustur, çünkü giriş verilerini nasıl biçimlendirmeniz gerektiğini etkileyebilir. Sinir ağı programlamasında kullanılan aktivasyon fonksiyonları aşağıdaki gibi belirtilmiştir.

1-Doğrusal Aktivasyon Fonksiyonu

2- Hiperbolik Tanjant Fonksiyonu

3-Sigmoid Fonksiyon

### 3.5.1. Doğrusal aktivasyon fonksiyonu

En temel aktivasyon fonksiyonu doğrusal fonksiyonudur, çünkü nöron çıktısını hiçbir şekilde değiştirmez. Denklem 3.5, programın tipik olarak bir doğrusal aktivasyon fonksiyonu nasıl uyguladığını gösterir:

$$f(x) = x \quad (3.5)$$

Gözlemleyebileceğiniz gibi, bu aktivasyon fonksiyonu sadece nöron girdilerinin kendisine aktardığı değeri geri gönderir.

Regresyon sinir ağları, sayısal değerler sağlamayı öğrenenler, genellikle çıktı katmanlarında doğrusal bir aktivasyon fonksiyonu kullanır [45].

### 3.5.2. Hiperbolik tanjant fonksiyonu

Hiperbolik tanjant fonksiyonu, aslında trigonometrik bir fonksiyondur. Bu fonksiyon, denklem 3.3'de gösterilmiştir.

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3.3)$$

Aralığı -1 ile 1 arasındadır. Bu daha geniş bir sayı aralığını kabul etmesine izin verir.

### 3.5.3. Sigmoid fonksiyon

Sigmoid fonksiyonu aynı zamanda lojistik fonksiyon olarak da adlandırılır. Sigmoid aktivasyon fonksiyonu, ileri beslemeli sinir ağları için çok yaygın bir fonksiyondur. Tipik olarak hiperbolik tanjant fonksiyonu kadar iyi performans göstermez. Bununla birlikte eğitim verilerindeki değerlerin tümü pozitifse, iyi performans gösterebilir. Sigmoid fonksiyonu denklem 3.4'de gösterilmiştir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.4)$$

Burada sayılar 0-1 aralığında ölçeklendirilir. Ayrıca yalnızca pozitif sayıları içeren bir aralığında vardır.

## 3.6. Eğitim Algoritmaları

### 3.6.1. Levenberg-Marquardt (LM)

Levenberg-Marquardt algoritması (LM), sinir ağları için çok verimli bir eğitim yöntemidir. LM, hem Newton Metoduna hem de gradyan inişine (geri yayılım) dayalı karma algoritmadır [48]. Daha hızlı çözümlene yapmaları, sağlamlıkları ve iyi yerel minimumlar bulma yetenekleri onları YSA eğitiminde çekici kılar [49]. Performans fonksiyonu toplam kareler biçimindedir (ileri beslemeli ağların eğitiminde olduğu gibi). Hessian matrisinin yaklaşımını aşağıdaki gibidir.

$$H = J^T \quad (3.6)$$

Gradyan ise şu şekilde hesaplanabilir:

$$g = J^T e \quad (3.7)$$

Jacobian matrisi, Hessian matrisini hesaplamaktan daha az karmaşık olan standart bir geri yayılma tekniği ile hesaplanabilir. Levenberg – Marquardt algoritmasının bu yaklaşımı, aşağıdaki Newton benzeri güncellemede Hessian matrisi için kullanılır:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (3.8)$$

Burada  $J^T J$  Hessian matrisini,  $J$  Jakobiyen matrisini,  $\mu$  öğrenme sabitini,  $I$  kimlik matrisini ve  $e$  hataların vektörünü temsil eder. Sayısal  $\mu$  sıfır olduğunda, bu sadece Newton'un yöntemidir. Yaklaşık Hessian matrisini kullanır.  $\mu$  büyük olduğunda, bu küçük adım boyutu ile gradyan inişli olur Bu çalışmada, ÇKA ağını eğitmek için Levenberg – Marquardt (LM) algoritması kullanılmıştır [19].

### 3.6.2. Bayesian Regülasyonu (BR)

Bayesian Regülasyonu (BR) eğitim fonksiyonu, eğitim sürecinde büyük ağırlıkların olumsuz etkilerini azaltmak için kullanılan bir yöntemdir. Düzenleme, Bayesian çıkarım tekniklerine dayalı etkili bir genelleme sağlamak için optimal performans fonksiyonunu ayarlayarak modelin aşırı öğrenme olasılığını azaltır [50]. BR fonksiyonunda optimum düzenleme parametrelerini bulmak için Hessian matrisinin hesaplanması gerekir. Düzenlemeyi optimize etmek için Hessian matrisi ( $J^T J$ )'nin Gauss-Newton yaklaşımı, David MacKay [51]'in Bayes tekniklerini izleyerek uygulanmıştır [52]. Bu çalışmada UKSB modelini eğitmek için MATLAB' taki trainbr fonksiyonu kullanılmıştır.

## 3.7. Metot

### 3.7.1. Yapay Sinir Ağları (YSA)


Yapay sinir ağları (YSA), biyolojik nöron sisteminin basitleştirilmiş modelleridir. Büyük ölçüde paralel dağılmış bilgiyi depolamak ve kullanıma hazır hale getirmek için doğal bir eğilime sahip işlemcilerdir. Sinir ağlarının sınıflandırılması; katman sayısı, bilgi akışının yönü, düğümlerden çıktıları almak için kullanılan doğrusal olmayan denklem ve farklı katmanların düğümleri arasındaki ağırlıkların belirlenme yöntemiyle gerçekleşir. Katmanlar içindeki ve arasındaki nöronlar iki şekilde bağlanabilir: (1) İleri beslemeli ağlar, (2) Tekrarlayan ağlar. İleri beslemeli ağlarda, nöronlar birkaç katman halinde düzenlenir. Bilgi giriş katmanından çıktı

katmanına yalnızca tek yönde akar. Tekrarlayan ağlarda, nöronlar bir veya daha fazla katmanda düzenlenir ve nöronlarda geri bildirim, aynı katmandaki diğer nöronlara veya önceki katmanlardaki nöronlara dahili olarak sunulur [30].

Yapay sinir ağları, girdi ve çıktı veri setleri arasındaki doğrusal olmayan karmaşık ilişkileri tanımlayabilen esnek matematiksel yapılardır. Bir sinir ağı, genellikle nöronlar, birimler, hücreler veya düğümler olarak adlandırılan çok sayıda basit işlem ögesinden oluşur. Her nöron, problemi çözmek için ağ tarafından kullanılan bilgileri temsil eden ortak bir ağırlığa sahip olan doğrudan iletişim bağlantıları aracılığıyla diğer nöronlara bağlanır. Ağ genellikle, her katmandaki her bir işlem biriminin, komşu katmanlardaki tüm işleme birimlerine bağlı olduğu iki veya daha fazla işlem birimi katmanına sahiptir [5].

### **3.7.1.1. Çok Katmanlı Algılayıcı (ÇKA)**

Çok katmanlı algılayıcılar (ÇKA), bir veya daha fazla gizli katmana sahip ileri beslemeli ağlardır. ÇKA sinir ağı, Şekil 3.3 te gösterildiği gibi giriş katmanı, gizli katman ve çıktı katmanından oluşan üç katmanlı öğrenme ağına sahiptir. Girdi-çıkı verilerinin eğitim seti verildiğinde, çok katmanlı algılayıcılar için en yaygın öğrenme kuralı geri yayılma algoritmasıdır (GYA). Geriye yayılma iki aşamadan oluşur: giriş düğümlerindeki harici giriş bilgilerinin, çıkış birimindeki çıkış bilgi sinyalini hesaplamak için ileri doğru yayıldığı bir ileri besleme aşaması ve bağlantı güçlerinde değişikliklerin çıkış ünitelerinde hesaplanan ve gözlemlenen bilgi sinyalleri arasındaki farklara bağlı olarak yapıldığı bir geriye doğru aşama [24,53].



Şekil 3.3. Yapay sinir ağlarının yapısı [24]

Eğer,  $w_m$ 'nin iterasyonu  $m$  sonraki bir  $w$  ağırlığının değerini temsil etmesine izin verirse, bu gizli düğüm ağırlığı  $w_{ij}$  veya çıkış düğüm ağırlığı  $w_{jk}$  olabilir, o zaman:

$$w_m = w_{m-1} + \Delta w_m \quad (3.9)$$

$\Delta w_m$ , iterasyon  $m$  sonucunda ağırlıktaki  $w$  değişimidir ve şu şekilde hesaplanır:

$$\Delta w_m = -\varepsilon d_m \quad (3.10)$$


burada  $\varepsilon$ , ağırlıkların değişim oranını kontrol eden parametredir. Kullanıcı bu parametrenin değerini ayarlar ve  $d_m$  terimi şu şekilde verilir:

$$d_m = \sum_{n=1}^N \left( \frac{\partial E}{\partial w_m} \right)_n \quad (3.11)$$

$N$  toplam örnek sayısıdır ve  $E$  simülasyon çıktı hatasıdır [5].

### 3.7.2. Tekrarlanan Sinir Ağları (TSA)

Yapısı bir girdi katmanından, bir veya daha fazla gizli katmandan ve bir çıktı katmanından oluşur. TSA'lar, önceki işlem adımlarından önemli bilgileri depolamak için bu modülleri bir bellek olarak kullanma fikriyle birlikte, zincir benzeri yinelenen modül yapılarına sahiptir. TSA'lar, İleri beslemeli sinir ağlarının aksine, sinir ağının bir dizi girişi kabul etmesine izin veren bir geri bildirim döngüsü içerir. Bu, adım  $t-1$ 'in çıktısının, adım  $t$ 'nin sonucunu etkilemek ve sonraki her adım için ağa geri beslendiği anlamına gelir. Bu nedenle, TSA'lar öğrenme dizilerinde başarılı olmuştur. Şekil 3.4'te TSA'daki sıralı işlemi göstermektedir.




Şekil 3.4. Tekrarlayan sinir ağındaki sıralı işlem [35]

Şekil 3.4 girdi birimi, çıktı birimi ve ağ boyunca yayılmış tekrarlanan gizli birimi olan basit bir TSA'nı gösterir; burada  $X_t$ ,  $t$  zaman adımıdaki girdidir ve  $h_t$ ,  $t$  zaman adımıdaki çıktıdır. Eğitim süreci sırasında TSA, YSA'da gradyanların hesaplanmasında ve ağırlık matrislerinin ayarlanmasında uygulanan yaygın bir algoritma olan geri yayılım algoritmasını kullanır. Ancak, geri bildirim sürecinin değiştirilmesinin ardından ağırlıkları ayarlayacak ve güncelleyecektir.

#### 3.7.2.1. Uzun-Kısa Süreli Bellek (UKSB)

UKSB'ler, uzun süreli bağımlılıkları öğrenebilen ve varsayılan olarak zamanın uzatılmış periyodları için bilgileri hatırlayabilen özel bir TSA türüdür. Ancak tekrarlanan modül farklı bir

yapıya sahiptir. Tek bir sinir ağı yerine, standart bir TSA gibi benzersiz bir iletişim yöntemine sahip dört etkileşimli katmana sahiptir. UKSB sinir ağının yapısı Şekil 3.5 te gösterilmektedir.



Şekil 3.5. Uzun-Kısa Süreli Bellek (UKSB) sinir ağının yapısı [35]

Tipik bir UKSB ağı, hücreler adı verilen bellek bloklarından oluşur. İki durum bir sonraki hücreye, hücre durumuna ve gizli duruma geçer. Hücre durumu, verilerin esasta değişmeden ilerlemesine izin veren ana veri akış zinciridir. Bununla birlikte, bazı doğrusal dönüşümler meydana gelebilir.

Bir UKSB ağı oluşturmanın ilk adımı, gerekli olmayan ve bu adımda hücreden çıkarılacak olan bilgileri belirlemektir. Bu veri tanımlama ve hariç tutma işlemi,  $t - 1$  zamanında son UKSB biriminin ( $h_{t-1}$ ) çıktısını ve  $t$  zamanında mevcut girdiyi ( $X_t$ ) alan sigmoid işlevi tarafından karar verilir. Bu kapıya unutma kapısı (veya  $f_t$ ) denir; burada  $f_t$ , 0 ile 1 arasında değişen, hücre durumundaki her sayıya karşılık gelen  $C_{t-1}$  bir vektördür.

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (3.12)$$

Burada,  $\sigma$  sigmoid fonksiyonudur ve  $W_f$  ile  $b_f$  sırasıyla, unutma kapısının ağırlık matrisleri ve sapmasıdır.

Hücre durumunda yeni girişten ( $X_t$ ) gelen bilgileri kararlaştırmak, depolamak ve ayrıca hücre durumunu güncellemek için aşağıdaki adım verilmiştir. Bu adım, sigmoid katmanı ve ikinci tanh katmanı olmak üzere iki bölümden oluşur.

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i), \quad (3.13)$$

$$N_t = \tanh(W_n[h_{t-1}, X_t] + b_n), \quad (3.14)$$

$$C_t = C_{t-1} f_t + N_t i_t \quad (3.15)$$

Burada,  $C_{t-1}$  ve  $C_t$ ,  $t - 1$  ve  $t$  zamanlarındaki hücre durumlarıdır,  $W$  ve  $b$  ise sırasıyla hücre durumunun ağırlık matrisleri ve sapmasıdır.

Son adımda, çıkış değerleri ( $h_t$ ) çıkış hücresi durumuna ( $O_t$ ) bağlıdır, ancak filtrelenmiş bir versiyondur. İlk olarak sigmoid katmanı, hücre durumunun hangi kısımlarının çıktıya ulaşacağına karar verir. Daha sonra sigmoid geçidin ( $O_t$ ) çıktısı, tanh katmanı tarafından hücre durumundan ( $C_t$ ) oluşturulan yeni değerlerle (-1 ile 1 arasında değişen bir değerle) çarpılır [35].

$$O_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (3.16)$$

$$h_t = O_t \tanh(C_t) \quad (3.17)$$

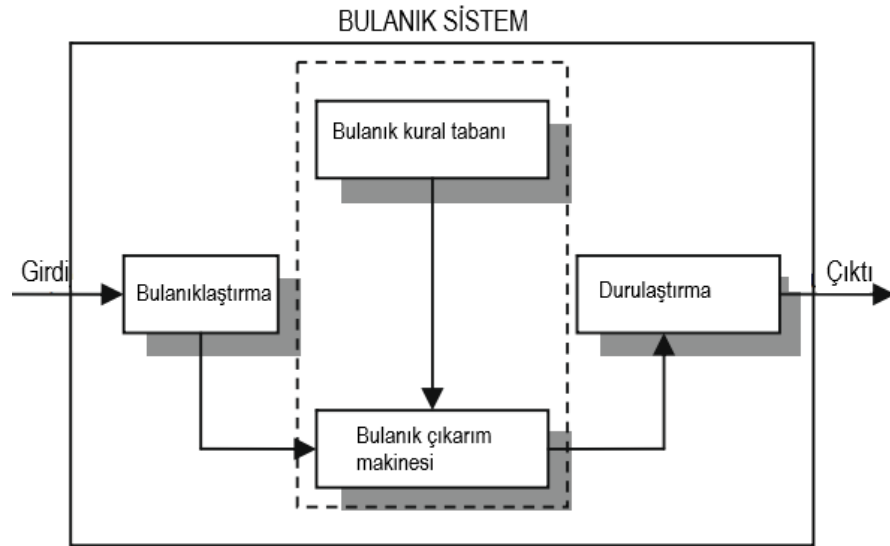
Burada  $W_o$  ve  $b_o$ , sırasıyla çıkış kapısının ağırlık matrisleri ve sapmasıdır.

### 3.7.3. Bulanık mantık (BM)

Bulanık mantık (BM) kavramı ilk kez 1965 yılında Lotfi Zadeh tarafından ortaya atılmıştır [3]. Şekil 3.6 da gösterildiği gibi Tayfur [54]'a göre genel bir bulanık sistemi: bulanıklaştırma, bulanık kural tabanı, bulanık çıkarım makinesi ve durulaştırma bileşenlerine sahiptir. Bulanıklaştırma, her girdi verisi parçasını bir veya daha fazla üyelik fonksiyonunda arama yaparak üyelik derecelerine dönüştürür. Bulanık mantıktaki temel fikir, tamamen tek bir kümeye ait olmak yerine, herhangi bir geniş kapsamlı kümenin farklı alt kümelerine kısmi ait olmalarına izin verilmesidir. Bir kümeye kısmen ait olma, 0 ile 1 arasında değerler içeren bir üyelik fonksiyonu ile sayısal olarak tanımlanabilir. Bulanık kural tabanı, girdiler ve çıktılar

arasındaki tüm olası bulanık ilişkileri içeren bulanık kuralları içerir. Bu kurallar “if-then” formatında ifade edilir. Bulanık yaklaşımda matematiksel denklemler ve model parametreleri yoktur, ancak tüm belirsizlikler ve model komplikasyonları, “if-then” ifadeleri şeklinde tanımlayıcı bulanık çıkarım prosedürüne dahil edilmiştir.

Bu yöntemde, kural tabanı uzmanın deneyimleri olmadan oluşturulabilir ve beş adımdan oluşur: 1. Adım, girdi ve çıktı alanlarını bulanık bölgelere ayırır; 2. Adım, istenen giriş-çıkış veri çiftlerinden bulanık kurallar üretir; 3. Adım, oluşturulan her kurala bir derece atar; 4. Adım, birleşik bulanık kural tabanını oluşturur; ve 5. Adım, birleşik bulanık kural tabanına dayalı bir eşleştirme elde etmek için durulaştırma prosedürünü sunar. Kurallar, her bir veri kümesine göre oluşturulmuştur. Her kurala üyelik fonksiyonları tarafından bir derece atanır [55]. Çalışmada hem yapay sinir ağlarının hem de bulanık mantığın entegrasyonu olan ASBÇS kullanılmıştır.



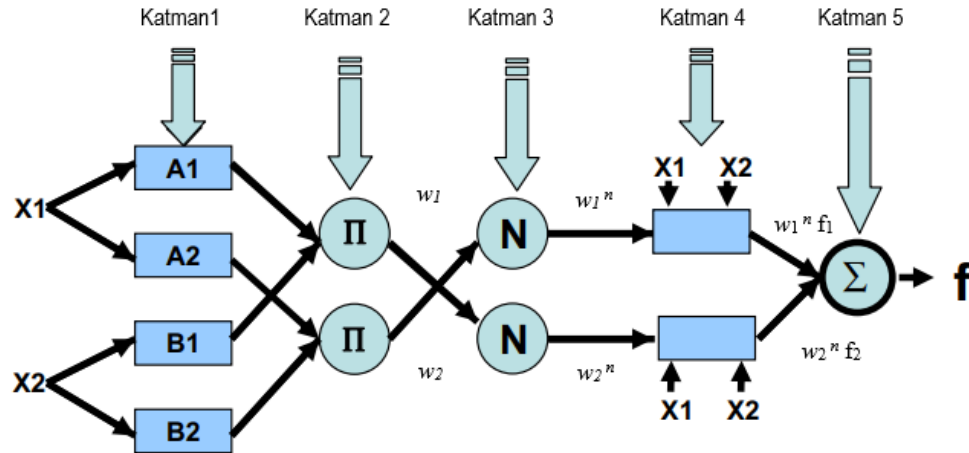
Şekil 3.6. Bulanık sistemin şematik diagramı [55]

### 3.7.3.1. Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS)

Nöro-bulanık modelleme, sinir ağı literatüründe geliştirilen çeşitli öğrenme tekniklerini bulanık modellemeye veya bulanık bir çıkarım sistemine (BÇS) uygulama yolunu ifade eder. Bir BÇS'in temel yapısı üç kavramsal bileşenden oluşur: bir dizi bulanık kural içeren bir kural tabanı; bulanık kurallarda kullanılan üyelik fonksiyonunu (ÜF) tanımlayan bir veritabanı; ve bir çıktı türetmek için kurallar üzerine sonuç prosedürünü gerçekleştiren bir mantık mekanizması. BÇS, girdi alanından çıktı alanına doğrusal olmayan bir eşleştirme uygular. Bu eşleştirme, her bir eşleşmenin lokal davranışını tanımlayan bir dizi bulanık if-then kuralıyla gerçekleştirilir. If-then kurallarının parametreleri, girdi alanının bulanık bir bölgesini tanımlar ve çıktı parametreleri (bulanık modellemenin sonuçları) karşılık gelen çıktıyı belirtir. Bu nedenle, BÇS'in verimliliği tahmin edilen parametrelere bağlıdır.

Uyarlanabilir bir ağ, genel çıktı davranışı değiştirilebilir parametreler koleksiyonunun değeriyle belirlenen çok katmanlı ileri besleme yapısıdır. Daha spesifik olarak uyarlanabilir bir ağın konfigürasyonu, çeşitli bağlantılar yoluyla bağlanan bir dizi düğümden oluşur; burada her düğüm, tek bir düğüm çıkışı oluşturmak için gelen sinyali üzerinde statik düğüm işlevi gerçekleştiren bir işlem birimidir. Düğüm işlevi değiştirilebilir parametreleri olan parametrelili bir işlevdir. Uyarlanabilir bir ağdaki bağlantıların yalnızca düğümler arasındaki sinyallerin akım yönünü gösterdiği ve bu bağlantılarla hiçbir ağırlığın ilişkilendirilmediği not edilebilir. Uyarlanabilir sinir ağları yapısını kullanarak bir BÇS geliştirme prosedürüne uyarlanabilir nöro bulanık çıkarım sistemi (ASBÇS) denir [11].

ASBÇS'in genel yapısı Şekil 3.7 de sunulmuştur. ASBÇS tasarlanırken, belirli bir hedef sistemi modellemek için BÇS seçimi en önemli husustur. Literatürde çeşitli BÇS türleri sunulmuş ve her biri yalnızca kendi sonuç parametreleriyle karakterize edilmiştir. Mevcut çalışmada Sugeno bulanık modeli (Takagi ve Sugeno [56]; Sugeno ve Kang [57]) kullanılmaktadır.



Şekil 3.7. ASBÇS mimarisi [30]

Örneğin, BÇS'in iki  $x_1$  ve  $x_2$  girişi ve bir  $z$  çıkışı olduğunu düşünün: Birinci dereceden Sugeno bulanık modeli için iki bulanık eğer-ise kuralına sahip tipik bir kural kümesi şu şekilde ifade edilebilir:

Kural 1: Eğer  $x_1, A_1$  ve  $x_2, B_1$  ise o zaman,

$$f_1 = p_1 x_1 + q_1 x_2 + r_1 \quad (3.18)$$

Kural 2: Eğer  $x_1, A_2$  ve  $x_2, B_2$  ise o zaman,

$$f_2 = p_2 x_1 + q_2 x_2 + r_2 \quad (3.19)$$

burada  $A_1, A_2$  ve  $B_1, B_2$ ;  $x_1$  ve  $x_2$  girişleri için ÜF'lardır. Sırasıyla;  $p_1, q_1, r_1$  ve  $p_2, q_2, r_2$ , çıkış fonksiyonunun parametreleridir.

Katman 1: Bu katmandaki her düğüm, giriş değişkeninin üyelik derecelerini oluşturur. Düğüm çıkışı  $OP_i^1$  şu şekilde tanımlanır:

$$OP_i^1 = \mu_{A_i}(x_1) \quad i = 1,2 \text{ ise yada} \quad (3.20)$$

$$OP_i^1 = \mu_{B_{i-2}}(x_2) \quad i = 3,4 \text{ ise} \quad (3.21)$$

burada  $x_1$  (veya  $x_2$ ) düğümün girdisidir;  $A_i$  (veya  $B_{i-2}$ ), bu düğümdeki ÜF'ların şekli ile karakterize edilen ve Gaussian, genelleştirilmiş çan şekilli, yamuk şekilli ve üçgen şekilli fonksiyonlar gibi sürekli ve parça parça ayırt edilebilen herhangi bir uygun fonksiyon olan, bu düğümle ilişkili bulanık bir kümedir.

Katman 2: Bu katmandaki her düğüm, gelen sinyalleri  $\prod$  olarak çarptırır ve kuralın ateşleme gücünü temsil eden  $OP_i^2$  çıkışı şu şekilde hesaplanır:

$$OP_i^2 = w_i = \mu_{A_i}(x_1)\mu_{B_i}(x_2), i = 1,2 \quad (3.22)$$

Katman 3: Bu katmanın  $i$ . inci düğümü  $N$  olarak sınıflandırılmıştır, normalleştirilmiş ateşleme gücünü şu şekilde hesaplar:

$$OP_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2 \quad (3.23)$$

Katman 4: Bu katmandaki  $i$  düğümü, aşağıdaki düğüm işlevi ile  $i$ . inci kuralın model çıktısına olan katkısını hesaplar:

$$OP_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (3.24)$$

burada  $\bar{w}$  3'üncü katmanın çıktısıdır ve  $\{p_i, q_i, r_i\}$  parametre kümesidir.

Katman 5: Bu katmandaki tek düğüm, ASBÇS 'in genel çıktısını şu şekilde hesaplar [11]:

$$OP_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.25)$$

## 4. ÇALIŞMA ALANI, KULLANILAN VERİLER VE YAPILAN ÇALIŞMALAR

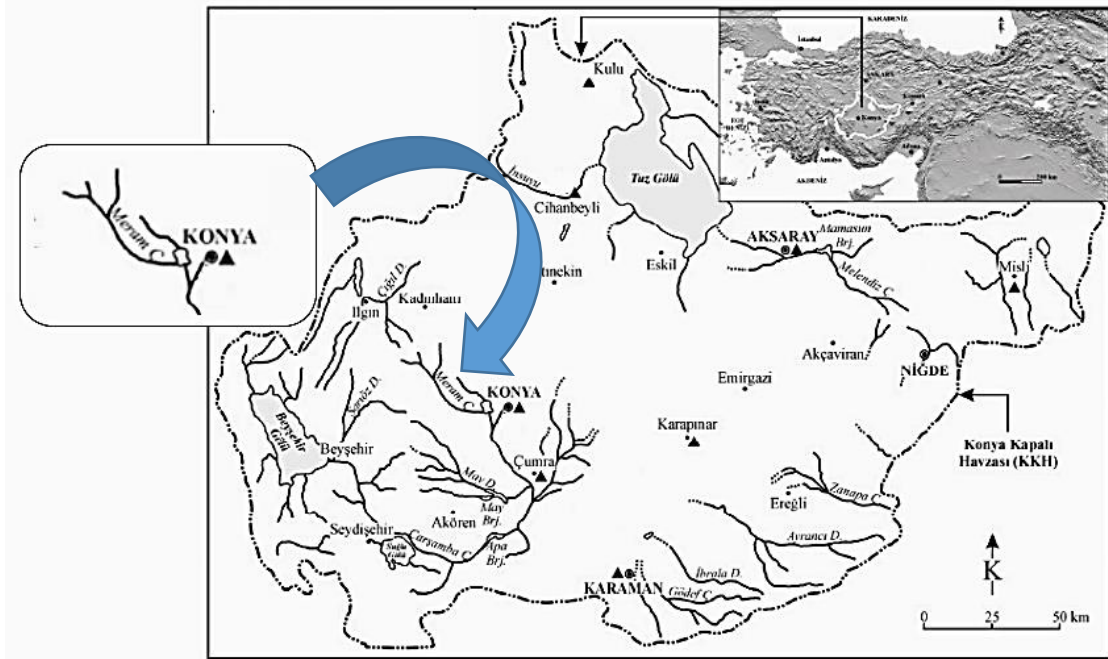
### 4.1. Konya Kapalı Havzası

Konya kapalı havzası: yaklaşık olarak Türkiye'nin ortasında bulunan kapalı havza, milyon hektarlık alanıyla Türkiye'nin yaklaşık %7'sini kaplar. Konya kapalı havzasını; Sakarya ve Kızılırmak havzaları kuzeyden, Kızılırmak ve Seyhan havzaları doğudan, Doğu Akdeniz havzası güneyden, batıdan Akarçay ve Anta havzası ile kaplıdır. Konya kapalı havzası genel olarak ova ve platolar ile kaplıdır. Konya kapalı havzasındaki akarsular çoğunlukla mevsimlik ve sel karakterlidir. Kapalı havza ve topoğrafyadan dolayı boyları kısadır, ovadaki bataklıklarda kaybolurlar. Düzensiz yağışlardan dolayı akarsu rejimleri düzensizdir, çoğu yaz mevsiminde ise kurur. Yükseklerden kaynaklanan akarsular Tuz Gölü, Beyşehir Gölü, Akgöl (Ereğli ovası), Hotamış Sazlığında son bulur [58].

Bölgenin yıllık yağış ortalaması 398 mm olmakla birlikte ovanın büyük bir kesiminde yıllık yağış oranı 270 - 320 mm arasında kalmaktadır. Bölge 2 750 000 ha tarım arazisine, 1 670 hm<sup>3</sup> yeraltı, 5 950 hm<sup>3</sup> yerüstü olmak üzere 7.620 hm<sup>3</sup> su potansiyeline sahiptir. Havza, önemli su potansiyeline sahiptir, ancak son yıllarda yağışların azlığı ve bilinçsiz kullanım nedeniyle yeraltı su seviyeleri gittikçe düşmekte, yeraltı suyu rezervleri tükenmekte ve havzadaki şartlar kuraklığa doğru yaklaşmaktadır [59,60].

#### 4.1.1. Meram Çayı

Meram Çayı, Konya ilinde bulunan bir akarsudur. Meram'ın önemli su kaynaklarından biri olan Meram Çayı, Konya'nın kuzeybatısında Başarakavak Köyü civarında bulunan Akdağ yamaçlarındaki kaynaklardan çıkmaktadır. Altınapa Barajı'ndan sonra Meram Çayı adı altında Konya'nın Meram mevkiinde ovaya ulaşır [59]. Meram Çayı'nın yağış alanı 454 km<sup>2</sup> olup ortalama akım debisi 0.99 m<sup>3</sup>/sn dir. Yıllık toplam akışı 51 hm<sup>3</sup> tür. Yağışın az olduğu yıllarda kurumaktadır. Daha önce Alakova Bataklığı'nı oluşturan Meram Çayı, Altınapa Barajı'nın yapılmasından sonra suyu azalmıştır. Meram Deresi tarafından beslenen bu baraj, DSİ tarafından sulama, içme suyu ve taşkın koruma amaçlı inşa edilmiştir [61].



Şekil 4.1. Çalışma alanı lokasyonu [60]

Çalışma bölgesi olarak Orta Anadolu'daki Büyük Konya Kapalı Havzası'nın kuzeybatısında yer alan Meram Çayı seçilmiştir. Çalışma bölgesi, Enlem:  $37^{\circ}55'28''$  Boylam:  $32^{\circ}16'9''$  koordinatlarında bulunmaktadır. Rakımı ise 1261 m'dir.


#### 4.2. Çalışmada Kullanılan Veriler

Çalışmada Konya Kapalı Havzası'nın kuzeybatısında yer alan Meram Çayı'nın 1981-2017 yılları arasındaki günlük akım değerlerinin ortalama aylık değerleri kullanılmıştır. Bu veriler Ulumuhsine köprüsünün 50 m membasında bulunan Küçükmuhsine Akım Gözlem İstasyonu'ndan DSİ tarafından temin edilmiştir. Meram Çayı'nın üzerinde bulunan Küçükmuhsine AGİ'nun bilgileri Tablo (4.1) de verilmiştir.

**Tablo 4.1. Küçükmuhsine AGİ bilgileri**

İstasyon no.	İstasyon Adı	Akarsu Adı	İşletme	Rakım (m)	Yağış alanı(Km <sup>2</sup> )	Açılış	Durumu
D16A100	Küçükmuhsine	Meram çayı	DSİ	1261	504.2	1975	Aktif

Veriler daha sonra eğitim ve test setine ayrılmıştır. Aylık verilerin zamanla dağılımı Şekil 4.2 de Gösterilmiştir.

**Şekil 4.2. Eğitim ve test verilerinin aylık akım değerinin zaman serileri**

Çalışmada kullanılan Küçükmuhsine AGİ'dan ölçülen ortalama aylık verilerin istatistiksel parametreleri eğitim, test ve tüm veriler için Tablo 4.2 de verilmiştir.

**Tablo 4.2. Küçükmuhsine AGİ aylık ortalama verilerin istatistiksel parametreleri**

İstatistiksel parametreler	Tüm veri	Eğitim	Test
----------------------------	----------	--------	------

Ortalama	1.006	0.612	1.055
Ortanca	0.612	0.032	0.601
Minimum deęer	0.003	0.003	0.04
Maksimum deęer	8.095	7.719	8.095
Standart sapma	1.099	1.045	1.294
Çarpıklık	2.468	2.189	2.938
Veri adedi	432	346	86

Geleceęe yönelik tahmin için Meram Çayı üzerindeki Küçükmuhsine AGİ'ndan 1981-2017 dönemine ait 36 yıllık ortalama aylık verileri kullanılmıştır. Toplam 432 adet ortalama aylık akım verisinin, 346 adedi (%80) eğitim, dięer kalan 86 adet (%20) ise test için ayrılmıştır. Şekil 4.2 bakıldığında maksimum akım deęerinin test veri setinde olduğunu, minimum akım deęerinin ise eğitim veri setinde olduğu görülmektedir.

### 4.3. Modelin Performans Kriterleri

Akım tahmini için Küçükmuhsine AGİ istasyonundan ölçülen 432 adet ortalama aylık debi verileri kullanılmıştır. Tüm modellerde verilerin %80'i eğitim, kalan %20 ise test için seçilmiştir. Tüm veri seti ve her set için istatistiksel parametreler Tablo 2'de sunulmuştur. YSA (ÇKA) modelinin eğitilmesinden önce verilere 0-1 aralığında normalleştirme uygulanmıştır. Normalleştirme, verileri boyutsuz hale getiren ve onları belirli bir aralıkta sınırlayan YSA için çok önemlidir. Normalleştirme aşağıdaki denklem kullanılarak yapılır.

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.1)$$

Burada,  $X_{nor}$  girdinin normalleştirilmiş deęeridir.  $X_{min}$  ve  $X_{max}$  sırasıyla, tüm gözlemlerde gerçek deęerlerin minimum ve maksimumudur.  $X$  orijinal veri kümesidir.

UKSB modelinde ise normalleştirmenin dięer yöntemi olan standardizasyon yöntemi uygulanmıştır. Burada verilerin aritmetik ortalaması ve standart sapması hesaplanarak normalleştirilir. Bununla birlikte, hem ortalama hem de standart sapma, aykırı deęerlere duyarlıdır. Veri matrisini standartlaştırmanın ana nedeni, deęişkenlerin genellikle farklı birimlerde ölçülmesidir [18].

$$X_{sta} = \frac{X - X_{ort}}{X_{std}} \quad (4.2)$$

Performans ölçüleri; Determinasyon Katsayısı ( $R^2$ ), Ortalama Kare Hatası (OKH) ve Karekök Ortalama Kare Hatası (KOKH) olarak belirlenmiş ve aşağıdaki denklemlerde gösterilmiştir.

$$R^2 = \frac{(\sum_{i=1}^n (Q_{i(o)} - Q_{ort(o)})(Q_{i(p)} - Q_{ort(p)}))^2}{\sum_{i=1}^n (Q_{i(o)} - Q_{ort(o)})^2 \sum_{i=1}^n (Q_{i(p)} - Q_{ort(p)})^2} \quad (4.3)$$

$$OKH = \frac{\sum_{i=1}^n (Q_{i(o)} - Q_{i(p)})^2}{N} \quad (4.4)$$

$$KOKH = \sqrt{\frac{\sum_{i=1}^n (Q_{i(o)} - Q_{i(p)})^2}{N}} \quad (4.5)$$

Burada,  $Q_{i(p)}$  modellerden tahmin edilen akım değeri,  $Q_{i(o)}$  gerçek akım değeri,  $Q_{ort(p)}$  ve  $Q_{ort(o)}$  sırasıyla modellerden tahmin edilen akımın ve gerçek günlük akımın ortalama değeridir.  $N$  ise gerçek ve tahmin değerinin toplam sayısıdır. Ortalama Kare Hatası (OKH) ile Karekök Ortalama Kare Hatası (KOKH) 0'a, Determinasyon Katsayısı 1'e yakın olması tahmin başarısının yüksek olduğunun göstergesidir [62].

#### 4.4. Yapılan Çalışmalar

Çalışmada geleceğe yönelik akım tahmini için MATLAB R2019a programı kullanılmıştır. ÇKA ve UKSB modelleri ile tahminde bulunmak için MATLAB'ta uygun yazılım dili uygulanmıştır. ASBÇS modeli ile tahminde bulunmak için MATLAB Neuro-Fuzzy Designer uygulaması kullanılmıştır. Oluşturulan her model için farklı kombinasyonda girdi değerleri girilmiş ve en iyi performansı veren modeller çalışmada değerlendirilmiştir. Literatürde Anusree [29] akım tahmini için farklı girdi kombinasyonları kullanmış, başarılı sonuçlar elde etmiştir. Zaman serisi modellemesinde farklı giriş değerleri kullanılabilir. YSA olarak

geliştirilen ÇKA da 1,2,3,4,5,6,7,10,16,20,24 ve 36 ay geciktirmeli akım değerleri girdi olarak kullanıldığında ağ başarılı performansı elde etmiştir. Bu nedenle, akım tahmini için ÇKA modelinde farklı girdi kombinasyonları seçilmiştir. UKSB için birer ay geciktirmeli 36 girdi kullanılmıştır. Son olarak ASBÇS için birer ay geciktirmeli 12 girdi kullanılmıştır. Sonuç olarak UKSB ve ASBÇS de eşit aralıkta girdi, ÇKA da farklı aralıkta girdi tercih edilmiştir. Yapılan tahmin yöntemi, zaman serisi tahmini olduğundan dolayı modellere çok sayıda girdi uygulanmıştır. Her modele uygulanan geciktirme ve girdi sayısı Tablo 4.3 gösterilmiştir.

**Tablo 4.3. Modellerin girdi kombinasyonları**

	Gecikme	Girdi sayısı
ÇKA	1,2,3,4,5,6,7,10,16,20,24,36	12
UKSB	1-36	36
ASBÇS	1-12	12

Her model için zaman serisi yöntemiyle, gelecekteki 1 yıl, 2 yıl ve 3 yıl sonraki akım değerlerini tahmin edilmeye çalışılmıştır. İlk olarak yapay sinir ağlarında yaygın olan, ÇKA modeli geliştirilmiştir. Model eğitilmeden önce, veriler 0-1 aralığında normalleştirilmiştir. Eğitim aşamasında farklı ara katmanlar denenmiş, 3 ara katmanlı ağ iyi sonuç vermiştir. Gizli katmanlardaki optimum nöron sayısı deneme ve yanılma yoluyla seçilmiştir. İlk katmanda 20, ikinci ve üçüncü katmanda 15 nöronun kullanıldığı ağ diğerlerine göre başarılı sonuçlar vermiştir. ÇKA modelinde Levenberg Marquardt eğitim algoritması olarak seçilmiştir. Daha sonra iterasyon sayısı 1000 olarak belirlenmiş, 9 deneme sonrası ağın eğitimi tamamlanmıştır.

Tekarlayan sinir ağı yöntemi olan UKSB modelinde, modelin duyarlılığını kontrol etmek için verilere ön işleme uygulanmıştır. Uygulanan standardizasyon yönteminde veriler belirli aralıkta ölçeklendirilmiştir. Ölçeklenen veriler 1 ile 36 ay geciktirmeli olarak UKSB modeline girilmiştir. Eğitim aşamasında farklı gizli katmanlar ve nöron sayıları kullanarak, en düşük hata veren model seçilmiştir. Ara katman sayısı 2 olan, birinci ara katmanda 50 ve ikinci ara katmanda 30 nörona sahip ağ diğerlerine göre daha üstün performans göstermiştir. Grup boyutu ve epok gibi optimize ediciler modelin performansını etkileyen parametrelerdir. Kayıp fonksiyonunu en aza indirmek için çalışmada grup boyutu 42 ve epok sayısı da 500

uygulanmıştır. Eğitim algoritması olarak Bayesien Regülasyon eğitim algoritması kullanılmıştır. Öğrenme oranı 0.01 ve dropout değeri 0.4 seçilmiş, modelin eğitimi tamamlanmıştır

MATLAB R2019a'nın Neuro-Fuzzy Designer uygulamasını kullanarak ASBÇS yöntemi ile geleceğe yönelik tahminde bulunulmuştur. ASBÇS modelinde kullanılan verilere herhangi bir normalizasyona gerek duyulmadan, ağın eğitimi yapılmıştır. Girdi değerleri 1 ile 12 ay geciktirmeli olarak ASBÇS'e eklenmiştir. Modelin eğitim aşamasında alt kümeleme yöntemiyle BÇS oluşturulmuştur. Alt kümeleme için etki aralığı 0.45 seçilmiş, diğer parametreler ise varsayılan olarak kullanılmıştır. Her girdi için 7 gaussian üyelik fonksiyonu, toplamda 7x12 (84) giriş üyelik fonksiyonu uygulanmıştır. Çıkış üyelik fonksiyonu ise linear seçilmiştir. Ardından optimizasyon metodu olarak hibrit seçilmiş ve 500 epok kullanarak BÇS eğitilmiştir.

ÇKA ve UKSB modellerinin yapısı, aktivasyon fonksiyonu ve iterasyon sayısı Tablo 4.4 te sunulmuştur. Tablo 4.5 te ise ASBÇS'in yapısı, üyelik fonksiyonu ve epok sayısı verilmiştir.

**Tablo 4.4. ÇKA ve UKSB modellemelerinde kullanılan parametreler**

	Girdiler	Model yapısı	Çıktı	Aktivasyon fonksiyonu	İterasyon /Epok
ÇKA	Q(1),Q(2),Q(3),Q(4), Q(5), Q(6), Q(7), Q(8), Q(16), Q(20), Q(24), Q(36)	(12-20-15-15-1)	Q(37)	Levenberg Marquardt	1000 (İterasyon)
UKSB	Q(1), Q(2), Q(3),....., Q(36)	(36-50-30-1)	Q(37)	Bayesien Regülasyon	500 (Epok)

**Tablo 4.5. ASBÇS modellemesinde kullanılan parametreler**

	Girdiler	Giriş üyelik fonksiyonu	Çıktı	Çıkış üyelik fonksiyonu	Epok
ASBÇS	Q(1), Q(2), Q(3),....., Q(12)	gaussmf	Q(13)	linear	500


Farklı girdilere sahip ÇKA, UKSB ve ASBÇS modellerinin eğitiminden sonra elde ettiği OKH, KOKH ve R<sup>2</sup> değerleri Tablo 4.6'da sunulmuştur.

**Tablo 4.6. Kurulan modellerin performans kriterleri**


	OKH	KOKH	R <sup>2</sup>
ÇKA	0.487	0.698	0.41
UKSB	0.261	0.51	0.73
ASBÇS	0.815	0.902	0.43

Tablo 4.6 de sunulan hata kriterleri incelendiğinde UKSB modelinin ÇKA ve ASBÇS modellerine göre daha iyi sonuçlar elde etmiştir. OKH karşılaştırıldığında 0.261 değeri ile UKSB'nin, 0.487 değeri veren ÇKA ve 0.815 değeri veren ASBÇS modellerinden daha düşük hata bulmuştur. KOHK değerleri karşılaştırıldığında 0.51 ile UKSB modelinin, 0.698 ile ÇKA modeli ve 0.902 ile ASBÇS modelinden daha iyi sonuç vermiştir. R<sup>2</sup> değerleri karşılaştırıldığında 0.51 ile UKSB modelinin, 0.698 ile ÇKA modeli ve 0.902 ile ASBÇS modelinden daha iyi sonuç verdiği görülmüştür. Böylece, UKSB'in performans kriterleri diğer modellere göre daha üstündür.

Kurulan modellerin eğitiminden sonra elde ettiği çıktıları grafiksel olarak gösterilmiştir. ÇKA, UKSB ve ASBÇS modellemelerinde tahmin edilen ve gözlemlenen verilerin, zaman varyasyonu Şekil 4.3 (a), Şekil 4.4 (a) ve Şekil 4.5 (a) da sunulmuştur. Şekil 4.3 (b), Şekil 4.4 (b) ve Şekil 4.5 (b) de tahmin edilen ve gözlemlenen verilerin saçılımı sunulmuştur. Üç farklı yöntemle elde edilen veriler, gözlenen veriler ile hangisinin daha fazla benzerlik gösterdiğini grafiksel olarak analiz edilmiştir.




(a)

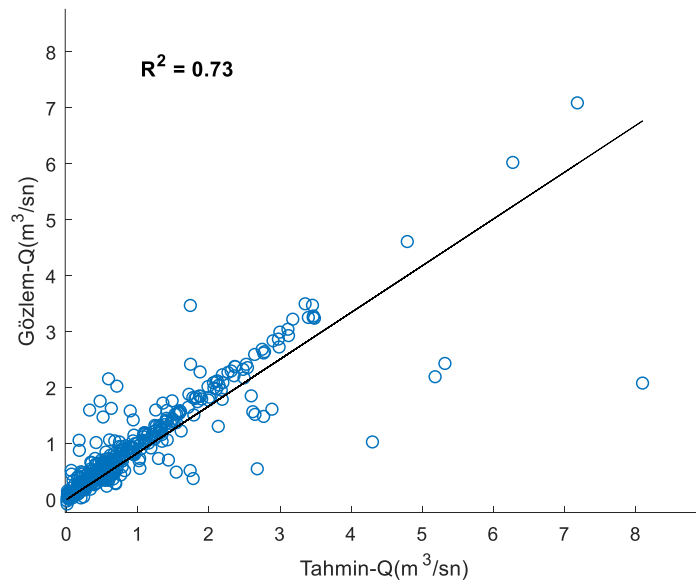


(b)

Şekil 4.3. ÇKA modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)




(a)




(b)

Şekil 4.4. UKSB modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)



(a)



(b)

Şekil 4.5. ASBÇS modeli ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)

Şekil 4.3 (a), Şekil 4.4 (a) ve Şekil 4.5 (a)'ya bakıldığında, UKSB modellemede gözlenen ve tahmin edilen verilerin zaman serisi diğer modellemelere kıyasla başarılı grafik elde etmiştir. Şekil 4.3 (b), Şekil 4.4 (b) ve Şekil 4.5 (b)'de sırasıyla ÇKA, UKSB ve ASBÇS'in saçılma diagramları gösterilmiştir. Yine UKSB modelinin gözlemlenen ve tahmin edilen verileri daha üstün saçılma elde etmiştir. ASBÇS'nin elde ettiği veriler ÇKA modeline kıyasla gözlenen verilere daha fazla benzerlik sağladığını ve iyi saçılma göstermiştir.

## 5. BULGULAR


### 5.1. Geleceğe Yönelik Tahminler

Geleceğe yönelik akım tahmini çalışmasında, MATLAB R2019a programı kullanarak üç farklı model kurulmuştur. Her model için veriler, eğitim veri setine ve performanslarını değerlendirmek için test veri setine ayrılmıştır. Çalışmada kurulan üç modelin tahmin ettiği (eğitim ve test veri seti için) aylık akımlar, gelecekteki aylık akım tahminleri için kullanılmıştır. Çalışmada 1 yıl, 2 yıl ve 3 yıl gibi uzun aralıklı tahminlerde bulunulmuş ve sonuçları değerlendirilmiştir.

Gelecekteki tahminlerin doğruluğunu belirtmek için modellerin  $R^2$  değerleri incelenmiştir. Korelasyon katsayısının karesi olarak bilinen determinasyon katsayısı  $R^2$ , 0 ile 1 arasında değişir ve model tarafından açıklanan gözlemlenen varyans miktarını tanımlar. Ayrıca gözlemlenen verilerin doğrusal eğriye ne kadar iyi uyduğunun ölçütüdür. Belirlenen hata değerlerine göre UKSB sinir ağının gelecekteki aylık akım değerlerine daha yakın bir tahminde bulunduğu düşünülmüştür.

#### 5.1.1. Geleceğe yönelik 1 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi

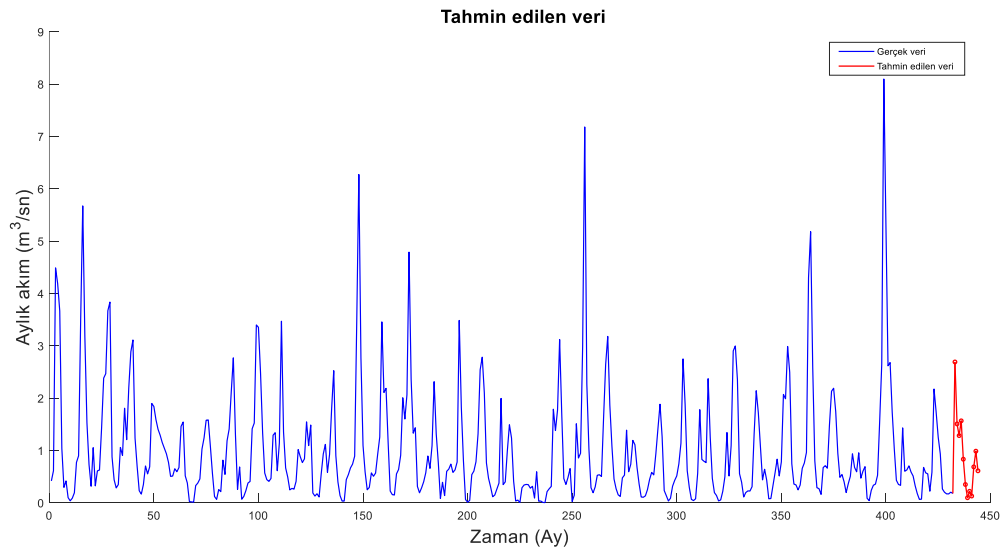
Çalışmada 1 yıl sonraki aylık akım tahmini için geliştirilen ÇKA, UKSB ve ASBÇS modellerinin çıktı değerleri kullanılmıştır. ÇKA modelinin geleceğe yönelik 1 yıllık akım tahmin sonuçları Şekil 5.1 de gösterildiği gibi aylık olarak tahmin edilmiştir.



**Şekil 5.1. ÇKA modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri**

Şekil 5.1 İncelendiğinde aylık akımın pik değerinin 2.45 olduğunu, en düşük değerini 0.17 olduğunu görülmüştür. Tahmin edilen veriler 1 yıl olmak üzere 12 veriden oluşmaktadır.

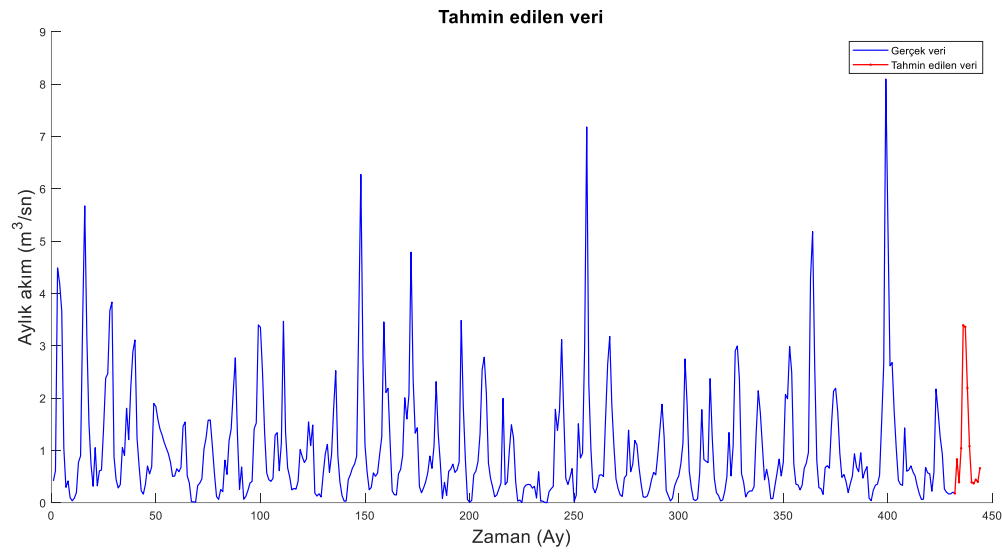
UKSB modelinin geleceğe yönelik 1 yıllık akım tahmin sonuçları Şekil 5.2 de gösterilmiştir. Modelin çıktı değeri gelecekteki aylık akımın tahmini için kullanılmıştır.



**Şekil 5.2. UKSB modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri**

Şekil 5.2 İncelendiğinde aylık akımın pik değerinin 2.69 olduğunu, en düşük değer 0.096 olduğu görülmüştür. Burada akımın pik değerinin ÇKA'ya kıyasla arttığı görülmüştür.

ASBÇS modelinin geleceğe yönelik 1 yıllık akım tahmin sonuçları Şekil 5.3 te gösterilmiştir. Modelin çıktı değeri gelecekteki aylık akımın tahmini için kullanılmıştır.




Şekil 5.3. ASBÇS modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri

Şekil 5.3 İncelendiğinde aylık akımın pik değerinin 3.39, en düşük değerin 0.17 olduğu görülmüştür. Burada akımın pik değerinin ÇKA ile ASBÇS'e göre daha yüksek bulunmuştur.

### 5.1.2. Geleceğe yönelik 2 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi


Çalışmada 2 yıl sonraki aylık akım tahmini için geliştirilen ÇKA, UKSB ve ASBÇS modellerinin çıktı değerleri kullanılmıştır. ÇKA modelinin geleceğe yönelik 2 yıllık akım tahmin sonuçları Şekil 5.4 te gösterildiği gibi aylık olarak tahmin edilmiştir.



**Şekil 5.4. ÇKA modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri**

Şekil 5.4 İncelendiğinde ilk yılda tahmin edilen aylık pik akımın ikinci yılda 1.65'e düştüğünü, en düşük değer 0.12 olduğu görülmüştür. Tahmin edilen veriler 2 yıl olmak üzere 24 veriden oluşmaktadır.

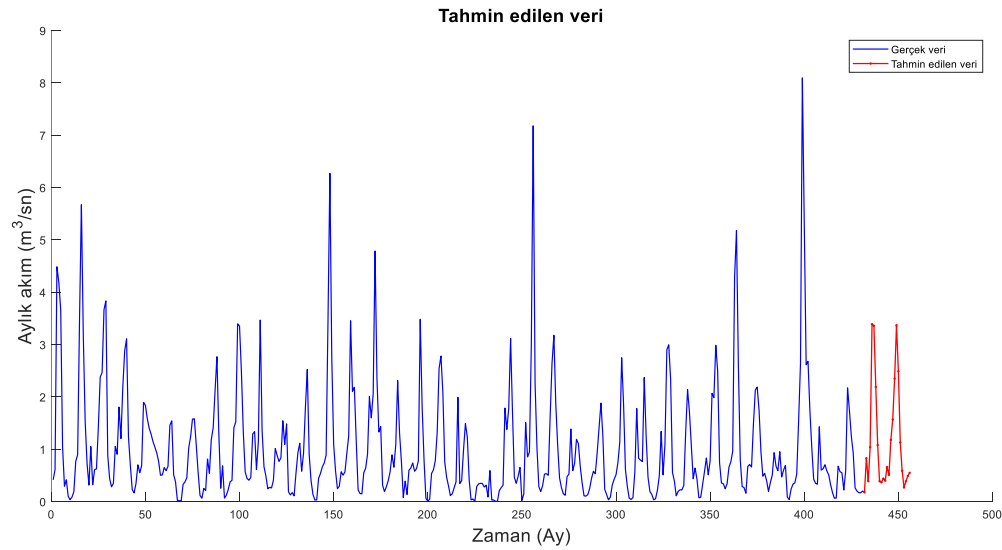
UKSB modelinin geleceğe yönelik 2 yıllık akım tahmin sonuçları Şekil 5.5 te gösterilmiştir. Modelin çıktığı değeri gelecekteki aylık akımın tahmini için kullanılmıştır.



**Şekil 5.5. UKSB modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri**

Şekil 5.5 İncelendiğinde ilk yılda tahmin edilen aylık pik akımın ikinci yılda 2.13'ye düştüğünü, en düşük değer ise yine 0.096 olduğu görülmüştür. Tahmin edilen veriler 2 yıl olmak üzere 24 veriden oluşmaktadır.

ASBÇS modelinin geleceğe yönelik 2 yıllık akım tahmin sonuçları Şekil 5.6 da gösterilmiştir. Modelin çıktı değeri gelecekteki aylık akımın tahmini için kullanılmıştır.




**Şekil 5.6. ASBÇS modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri**

Şekil 5.6 İncelendiğinde ilk yılda tahmin edilen aylık pik akımı ikinci yılda çok az miktarda 3.37'e düştüğünü, en düşük değer yine 0.17 olduğu görülmüştür. Tahmin edilen veriler 2 yıl olmak üzere 24 veriden oluşmaktadır.

### 5.1.3. Geleceğe yönelik 3 yıl sonraki aylık akım tahmin sonuçlarının irdelenmesi


Çalışmada 3 yıl sonraki aylık akım tahmini için geliştirilen ÇKA, UKSB ve ASBÇS modellerinin çıktı değerleri kullanılmıştır. ÇKA modelinin geleceğe yönelik 3 yıllık akım tahmin sonuçları Şekil 5.7 de gösterildiği gibi aylık olarak tahmin edilmiştir.



**Şekil 5.7. ÇKA modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri**

Şekil 5.7 İncelendiğinde tahmin edilen aylık akımın giderek azaldığını, en düşük değerini yine 0.12 olduğu görülmüştür. Tahmin edilen veriler 3 yıl olmak üzere 36 veriden oluşmaktadır.


UKSB modelinin geleceğe yönelik 3 yıllık akım tahmin sonuçları Şekil 5.8 te gösterilmiştir. Modelin çıktısı gelecekteki aylık akımın tahmini için kullanılmıştır.



**Şekil 5.8. UKSB modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri**

Şekil 5.8 İncelendiğinde tahmin edilen aylık akımın giderek azaldığını, en düşük değerin 0.013 olduğu görülmüştür. Tahmin edilen veriler 3 yıl olmak üzere 36 veriden oluşmaktadır.

ASBÇS modelinin geleceğe yönelik 3 yıllık akım tahmin sonuçları Şekil 5.9 da gösterilmiştir. Modelin çıktı değeri gelecekteki aylık akımın tahmini için kullanılmıştır.



**Şekil 5.9. ASBÇS modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri**

Şekil 5.9 İncelendiğinde tahmin edilen aylık akımın birinci ve ikinci yılda yaklaşık aynı olduğu, üçüncü yılda 2.26'a düştüğü görülmektedir. ASBÇS ile tahmin edilen değerler ÇKA ve UKSB'e göre daha üstündür. Tahmin edilen veriler 3 yıl olmak üzere 36 veriden oluşmaktadır.

Şekil 5.7, Şekil 5.8 ve Şekil 5.9 bakıldığında ÇKA ile UKSB'in geleceğe yönelik tahmin edilen değerleri birbirine yakın olduğu, ASBÇS' in akım değerinin yüksek olduğu görülmektedir. Tahmin edilen aylık akımlar geçmiş akım değerlerine göre fazla farklılık göstermemiştir. Modellerin determinasyon katsayısına bakıldığında 0.73 ile 1'e en yakın olan UKSB, yüksek tahmin doğruluğuna sahip olduğunu göstermiştir.  $R^2$  değeri 0.73 olan UKSB'in, verilen veri seti için iyi uyumun olduğunu göstermiştir. Diğer iki modelin determinasyon katsayısı sırasıyla, ASBÇS için 0.43 ve ÇKA için 0.41 olarak hesaplanmıştır.

## 6. SONUÇLAR VE ÖNERİLER

Gelecekteki akarsu akımlarının tahmini, hidrologlar ve su kaynakları mühendisleri için çok önemli bir konudur. Geleceğe yönelik yapılan tahmin, karar vermede riski en aza indirmek ve beklenmeyen maliyeti azaltmak için temel bir karar verme tekniğidir. Akarsu akım tahmini, su altyapısının tasarımı ve işletimi, baraj planlaması, taşkın azaltımı, su rezervuarlarının işletimi, içme suyu dağıtımı, kurak dönemlerde hidroelektrik üretimi ve nehir taşımacılığının planlanması gibi birçok önemli hususta etkilidir. Bu nedenle, gelecekteki nehir akımlarının tahmini hidrolojideki ana araştırma konularından biri olarak kabul edilir.

Bu çalışmada Küçükmuhsine AGİ ait 432 adet aylık akım değerlerinin zaman serisini kullanarak geleceğe yönelik akım tahmini yapılmaya çalışılmıştır. Bu verilerin 346 adedi eğitim seti için kalan 86 adedi test seti için kullanılmıştır. Çalışmada Küçükmuhsine AGİ'nun akım tahmini için Çok Katmanlı Algılayıcı (ÇKA), Uzun Kısa Süreli Bellek (UKSB) ve Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) gibi üç farklı yapay zeka modelleri geliştirilmiş ve karşılaştırılmıştır. Tahmin çalışmaları kapsamında hidrolojik sistemlerin modellenmesinde sıklıkla kullanılan ASBÇS ve yeni yöntem olarak geliştirilen UKSB hidrolojik verilere uygulanabilirliği de incelenmiştir. Geliştirilen ÇKA, UKSB ve ASBÇS modellerinden elde edilen aylık akım tahminleri zaman varyasyonu ve saçılma diyagramlarında gösterilmiştir.

Bu modeller için zaman geciktirmeli olarak çok sayıda farklı kombinasyonlarda girdi verileri seçilmiştir. Giriş verileri ağa eklenmeden önce ÇKA yönteminde normaleştirme, UKSB yönteminde ise standardize uygulanmıştır. ASBÇS için herhangi bir normalizasyon uygulanmamıştır. Bütün modellerde tek çıktı değeri belirlenmiştir. ÇKA ve UKSB yönteminde farklı eğitim algoritmaları denenmiş, ÇKA'da Levenberg-Marquardt algoritması ve UKSB'te Bayesian Regülasyon algoritması kullanıldığında daha başarılı sonuçlar vermiştir. ASBÇS'de üyelik fonksiyonu olarak Gaussian seçilmiştir. Her model için deneme-yanılma yoluyla farklı parametreler ve ara katman sayıları denenmiştir. ÇKA ve UKSB'te kullanılan eğitim algoritması ve ara katmandaki nöron sayıları hata değerleri üzerinde etkili olmuştur. ÇKA modelinde 3 gizli katman sayısına sahip ağ başarılı sonuç vermiştir. Bu gizli katmanlarda sırasıyla 20, 15 ve 15 nöron kullanılmıştır. İterasyon sayısı 1000 belirlenmiş 9 deneme sonra eğitimi tamamlanmıştır.

UKSB modelinde 2 gizli katman sayısına sahip ağ başarılı sonuçlar vermiştir. Birinci katmanda 50 ve ikinci katmanda 30 nöron kullanılmıştır. 500 epok kullanarak ağın eğitimi tamamlanmıştır. ASBÇS'te her giriş fonksiyonu için 7 üyelik fonksiyonu seçilmiştir. 500 epok kullanarak ağın eğitimi tamamlanmıştır.

Çalışmada geliştirilen modellerin performans değerleri kıyaslandığında UKSB'in, ÇKA ve UKSB göre daha iyi sonuçlar verdiği görülmüştür. OKH kıyaslandığında sırasıyla 0.261 ile UKSB, 0.487 ile ÇKA ve 0.815 ile ASBÇS değerleri elde edilmiştir. KOKH kıyaslandığında sırasıyla 0.51 ile UKSB, 0.698 ile ÇKA ve 0.902 ile ASBÇS değerleri elde edilmiştir. Son olarak determinasyon katsayısı ( $R^2$ ) kıyaslandığında 0.73 ile UKSB, 0.43 ile ASBÇS ve 0.41 ile ÇKA değerleri elde edilmiştir. Bu sonuçlara göre UKSB modelinin diğer iki modelden daha düşük hata değerleri hesaplamıştır.

Zaman serisi yöntemi ile uzun süreli tahminlerde bulunmak için aylık akım verileri seçilmiştir. Eğitilen modellerin çıktılarını kullanarak, geleceğe yönelik 1 yıl, 2 yıl ve 3 yıl sonraki akım tahminlerinde bulunulmuştur. Zaman serisi yöntemi ile yapılan bu tahmin gelecekte oluşacak akım değerleri olarak öngörülmüştür. Sonuç olarak, UKSB modelinin ÇKA ve ASBÇS modellerinden üstün tahminler elde etmiştir. ASBÇS diğer iki modele göre daha düşük tahminlerde bulunmuştur. Kullanılan geçmiş akım verileri göz önünde bulduğunda, UKSB'in tahmin ettiği aylık akımlar ileride gözlemlenecek olan gerçek akıma yakın olduğu düşünülmüştür.

Sonuçlar, tezde kullanılan UKSB yönteminin gelecekteki akım tahminlerinde uygulanabilir olduğuna, ÇKA ve ASBÇS'in geliştirilmesi durumunda uygulanabilir olduğunu göstermiştir.

Çalışmada kullanılan geçmiş veriler göz önünde bulduğunda, geleceğe yönelik yapılan tahminlerde fazla farklılık göstermediğini göstermiştir. Dolayısıyla tahmin edilen değerlerin başarılı olduğu söylenebilir.

Geliştirilen modellerde kullanılan girdi sayıları geleceğe dönük tahminlerde etkili olduğu görülmüştür. Girdi sayısı 36 ile en yüksek olan UKSB iyi performans vermiştir. Yapılacak tahminin aralığına göre uygun girdi sayılarının belirlenmesi, başarılı tahmin sonuçları sağlayacaktır.

ÇKA, UKSB ve ASBÇS için belirlenen farklı parametreler modellerin çıktılarını etkilemiştir. İleriki zamanlarda tahmin edilen gelecekteki akım sonuçlarını geliştirmek için farklı ara katman ve nöron sayısı, farklı eğitim algoritmaları (veya üyelik fonksiyonları), iterasyon (veya epok) kullanılabilir, sonuçları farklı değerlendirme kriterleri ile kıyaslayarak daha iyi sonuç veren model belirlenebilir.

## KAYNAKLAR

- [1] Wikipedia, Streamflow, (2021). <https://en.wikipedia.org/wiki/Streamflow> (erişim 21 Mart 2021).
- [2] Ö. Terzi, G. Ergin, Forecasting of monthly river flow with autoregressive modeling and data-driven techniques, *Neural Computing and Applications*. 25 (2013) 179–188. doi:10.1007/s00521-013-1469-9.
- [3] Ş. Sağıroğlu, E. Beşdok, Mühendislikte yapay zeka uygulamaları-1: Yapay sinir ağları, *Ufuk Kitap Kırtasiye-Yayıncılık*, Kayseri, 2003.
- [4] Z.P. Moreshwar, Application of artificial neural networks to civil engineering, *Indian*, 1-2, 2012.
- [5] Y.B. Dibike, D.P. Solomatine, River Flow Forecasting Using Artificial Neural Networks, *Physics and Chemistry of the Earth, Part B*. 26 (2001) 1–7.
- [6] Ö. Yüksek, H.T. Babacan, F. Saka, Yağış-Akış Modellemesinde Optimum Yapay Sinir Ağı Yapısının Araştırılması, *Türk Hidrolik Dergisi*. 2 (2018) 31–37.
- [7] S. Chakraverty, S. Mall, Artificial neural networks for engineers and scientists: Solving ordinary differential equations, *CRC Press*, Boca Raton, 2017. doi:10.1201/9781315155265.
- [8] E. Öztemel, Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul, 2012.
- [9] K. Saplıoğlu, S. Uzundurukan, Bilimsel çalışmalarda kullanılan bazı yapay zeka uygulamalarının ve trendlerinin incelenmesi, *DÜMF Mühendislik Dergisi*. 10(1) (2019) 249–262. doi:10.24012/dumf.394591.
- [10] M. Saplıoğlu, An Accident Prediction Model for Urban Uncontrolled Intersections, *Natural and Applied Sciences*. (2010).
- [11] P.C. Nayak, K.P. Sudheer, D.M. Rangan, K.S. Ramasastri, A neuro-fuzzy computing technique for modeling hydrological time series, *Journal of Hydrology*. 291 (2004) 52–

66. doi:10.1016/j.jhydrol.2003.12.010.
- [12] U. Köse, Bulanık Mantık ve Yapay Sinir Ağları için Eğitim Yazılımı Geliştirilmesi, *Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Anabilim Dalı*, Afyonkarahisar, 2010.
- [13] A.U. Muhammad, X. Li, J. Feng, Using LSTM GRU and hybrid models for streamflow forecasting, içinde: X.B. Zhai, B. Chen, K. Zhu (Ed.), *International Conference on Machine Learning and Intelligent Communications*, Springer, Nanjing, China, 2019: ss. 510–524. doi:10.1007/978-3-030-32388-2\_44.
- [14] Y. Hu, L. Yan, T. Hang, J. Feng, Stream-flow forecasting of small rivers based on LSTM, *arXiv preprint arXiv:2001.05681*. (2020).
- [15] J. Zhang, Y. Zhu, X. Zhang, M. Ye, J. Yang, Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas, *Journal of Hydrology*. 561 (2018) 918–929. doi:10.1016/j.jhydrol.2018.04.065.
- [16] R. Tanty, T.S. Desmukh, Application of Artificial Neural Network in Hydrology- A Review, *International Journal of Engineering Research and Technology*. 4(6) (2015) 184–188. doi:10.17577/ijertv4is060247.
- [17] E. Loucks, P. D., van Beek, River Basin Modeling, Water resource systems planning and analysis: An introduction to Methods, Models, and Applications, *Springer*, Cham, 2017. doi:10.1007/978-3-319-44234-1.
- [18] I. Aichouri, A. Hani, N. Bougherira, L. Djabri, H. Chaffai, S. Lallahem, River Flow Model Using Artificial Neural Networks, *Energy Procedia*. 74 (2015) 1007–1014. doi:10.1016/j.egypro.2015.07.832.
- [19] Ö. Kişi, Streamflow Forecasting Using Different Artificial Neural Network Algorithms, *Journal of Hydrologic Engineering*. 12 (2007) 532–539. doi:10.1061/(ASCE)1084-0699(2007)12:5(532).
- [20] M.E. Keskin, Ö. Terzi, E.D. Taylan, D. Küçükyaman, Meteorological drought analysis using artificial neural networks, *Scientific Research and Essays*. 6(21) (2011) 4469–4477. doi:10.5897/sre10.1022.

- [21] F. Othman, M. Naseri, Reservoir inflow forecasting using artificial neural network, *International Journal of Physical Sciences*. 6(3) (2011) 434–440. doi:10.5897/IJPS10.649.
- [22] M. Motamednia, A. Nohegar, A. Malekian, H. Asadi, A. Tavasoli, M. Safari, K. Karimi, Daily river flow forecasting in a semi-arid region using twodata-driven, *Desert (Biaban)*. 20 (2015) 11–21. doi:10.22059/jdesert.2015.54078.
- [23] A. Olawoyin, Y. Chen, Predicting the future with artificial neural network, *Procedia Computer Science*. 140 (2018) 383–392. doi:10.1016/j.procs.2018.10.300.
- [24] H.K. Cigizoglu, Estimation, forecasting and extrapolation of river flows by artificial neural networks, *Hydrological Sciences Journal*. 48(3) (2003) 349–361. doi:10.1623/hysj.48.3.349.45288.
- [25] A. El-Shafei, O. Jaafer, S.A. Akrami, Adaptive neuro-fuzzy inference system based model for rainfall forecasting in Klang River, Malaysia, *International Journal of the Physical Sciences*. 6(12) (2011) 2875–2888. doi:10.5897/AJBM11.515.
- [26] N. Nawaz, S. Harun, A. Talei, Application of Adaptive Network-Based Fuzzy Inference System (ANFIS) for River Stage Prediction in a Tropical Catchment, *Applied Mechanics and Materials*. 735 (2015) 195–199. doi:10.4028/www.scientific.net/amm.735.195.
- [27] E. Aldrian, Y.S. Djami, Application of Multivariate Anfis for Daily Rainfall Prediction: Influences of Training Data Size, *MAKARA of Science Series*. 12(1) (2008) 7–14. doi:10.7454/mss.v12i1.320.
- [28] U.G. Bacanli, M. Firat, F. Dikbas, Adaptive Neuro-Fuzzy inference system for drought forecasting, *Stochastic Environmental Research and Risk Assessment*. 23 (2009) 1143–1154. doi:10.1007/s00477-008-0288-5.
- [29] K. Anusree, K.O. Varghese, Streamflow Prediction of Karuvannur River Basin Using ANFIS, ANN and MNLN Models, *Procedia Technology*. 24 (2016) 101–108. doi:10.1016/j.protcy.2016.05.015.
- [30] A.K. Lohani, R. Kumar, R.D. Singh, Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques, *Journal of*

- Hydrology*. 442 (2012) 23–35. doi:10.1016/j.jhydrol.2012.03.031.
- [31] E. Gemici, M. Ardiçlıoğlu, F. Kocabaş, Akarsularda debinin yapay zekâ yöntemleri ile modellenmesi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 29(2) (2013) 135–143.
- [32] B.B. Sahoo, R. Jha, A. Singh, D. Kumar, Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting, *Acta Geophysica*. 67 (2019) 1471–1481. doi:10.1007/s11600-019-00330-1.
- [33] W. Xu, Y. Jiang, X. Zhang, Y. Li, R. Zhang, G. Fu, Using long short-term memory networks for river flow prediction, *Hydrology Research*. 51 (2020) 1358–1376. doi:10.2166/nh.2020.026.
- [34] F. Kratzert, D. Klotz, C. Brenner, K. Schulz, M. Herrnegger, Rainfall-Runoff modelling using Long-Short-Term-Memory (LSTM) networks, *Hydrology and Earth System Sciences Discussions*. (2018) 1–26. doi:10.5194/hess-2018-247.
- [35] X.H. Le, H.V. Ho, G. Lee, S. Jung, Application of Long Short-Term Memory (LSTM) neural network for flood forecasting, *Water (Switzerland)*. 11 (2019). doi:10.3390/w11071387.
- [36] C. Hu, Q. Wu, H. Li, S. Jian, N. Li, Z. Lou, Deep learning with a long short-term memory networks approach for rainfall-runoff simulation, *Water (Switzerland)*. 10 (2018) 1–16. doi:10.3390/w10111543.
- [37] J.M. Zurada, Introduction to Artificial neural systems, *West Publishing Company*, St. Paul, 1992.
- [38] Z. Ağyar, Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama, *Mühendis ve Makine*. 56 (2015) 22–23.
- [39] H.T. Nguyen, N.R. Prasad, C.L. Walker, E.A. and Walker, A First Course in Fuzzy and Neural Control, *CRC Press*, Boca Raton, Florida, 2002.
- [40] W.S. McCulloch, W. Pitts, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*. 5 (1943) 115–133.

- [41] D.O. Hebb, The organization of behavior; a neuropsychological theory., *Science Education*. 34 (1949) 336–337.
- [42] F. Rosenblatt, The perceptron: A probabilistic model for information storage and organization in the brain., *Psychological Review*. 65 (1958) 386–408.
- [43] B. Widrow, M.E. Hoff, Adaptive Switching Circuits, *IRE Western Electric Show and Convention Record*, 96-104, 1960.
- [44] B. Widrow, Generalization and information storage in network of adaline “neurons”, *Spartan Books*, Washington, 1962.
- [45] J. Heaton, AIFH, Volume 3: Deep Learning and Neural Networks, 1. Edition, *Heaton Research, Inc.*, Chesterfield, 2015.
- [46] J. Heaton, Introduction to Neural Networks for C#, 2 Edition, *Heaton Research, Inc*, Chesterfield, 2008.
- [47] Q. Zhao, Potatolemon - Neuron Weights, (2018). <https://qichaozhao.github.io/potatolemon-2/> (erişim 10 Ocak 2021).
- [48] J. Heaton, Introduction to the Math of Neural Networks, *Heaton Research, Inc.*, Chesterfield, 2012.
- [49] G. Zhang, B. Eddy Patuwo, M.Y. Hu, Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*. 14 (1998) 35–62. doi:10.1016/S0169-2070(97)00044-7.
- [50] F.D. Foresee, M.T. Hagan, Gauss-Newton Approximation to Bayesian Learning, *In Proceedings of International Conference on Neural Networks (ICNN'97)*, *IEEE*, Houston, TX, USA, 1997: ss. 1930–1935. doi: 10.1109/ICNN.1997.614194.
- [51] D.J.C. MacKay, Bayesian Interpolation, *Neural Computation*. 4(3) (1992) 415–447.
- [52] S.M. Guzman, J.O. Paz, M.L.M. Tagert, The Use of NARX Neural Networks to Forecast Daily Groundwater Levels, *Water Resources Management*. 31 (2017) 1591–1603. doi:10.1007/s11269-017-1598-5.
- [53] R.C. Eberhart, R.W. Dobbins, Neural Network PC Tools, *Academic Press, Inc.*, San


Diego, California, 1992.

- [54] G. Tayfur, S. Ozdemir, V.P. Singh, Fuzzy logic algorithm for runoff-induced sediment transport from bare soil surfaces, *Advances in Water Resources*. 26 (2003) 1249–1256. doi:10.1016/j.advwatres.2003.08.005.
- [55] M.E. Turan, M.A. Yurdusev, River flow estimation from upstream flow records by artificial intelligence methods, *Journal of Hydrology*. 369 (2009) 71–77. doi:10.1016/j.jhydrol.2009.02.004.
- [56] T. Takagi, M. Sugeno, Fuzzy Identification of Systems and Its Applications to Modeling and Control, *IEEE transactions on systems, man, and cybernetics*. 15(1) (1985) 116–132.
- [57] M. Sugeno, G.T. Kang, Structure identification of fuzzy model, *Fuzzy Sets and Systems*. 28 (1988) 15–33.
- [58] Vikipedi, Konya kapalı havzası, (2020). [https://tr.wikipedia.org/wiki/Konya\\_kapalı\\_havzası](https://tr.wikipedia.org/wiki/Konya_kapalı_havzası) (erişim 24 Aralık 2020).
- [59] Mevlana Kalkınma Ajansı, Konya su potansiyeli ve kuraklığın suya etkilerinin analizi projesi raporu, Konya, 7-16, 2012.
- [60] F. Başçiftçi, S.S. Durduran, C. İnal, Konya Kapalı Havzasında Yeraltı Su Seviyelerinin Coğrafi Bilgi Sistemi (CBS) İle Haritalanması, *Harita Teknolojileri Elektronik Dergisi*. 5(2) (2013) 1–15.
- [61] A.S. Aka, Konya Şehrinin Kuruluş ve Gelişimini Etkileyen Coğrafi Faktörler, Yüksek Lisans Tezi, *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Ortaöğretim ve Sosyal Alanlar Eğitimi Ana Bilim Dalı*, Konya, 2007.
- [62] A. Danandeh Mehr, E. Kahya, A. Şahin, M.J. Nazemosadat, Successive-station monthly streamflow prediction using different artificial neural network algorithms, *International Journal of Environmental Science and Technology*. 12(7) (2015) 2191–2200. doi:10.1007/s13762-014-0613-0.


## EKLER

**EK-1** Modellemeler ile tahmin edilen verilerin zaman serileri ve saçılma diagramı.

**EK 1.A** ÇKA modeli ile tahmin edilen verilerin zaman serileri ve saçılma diagramı.



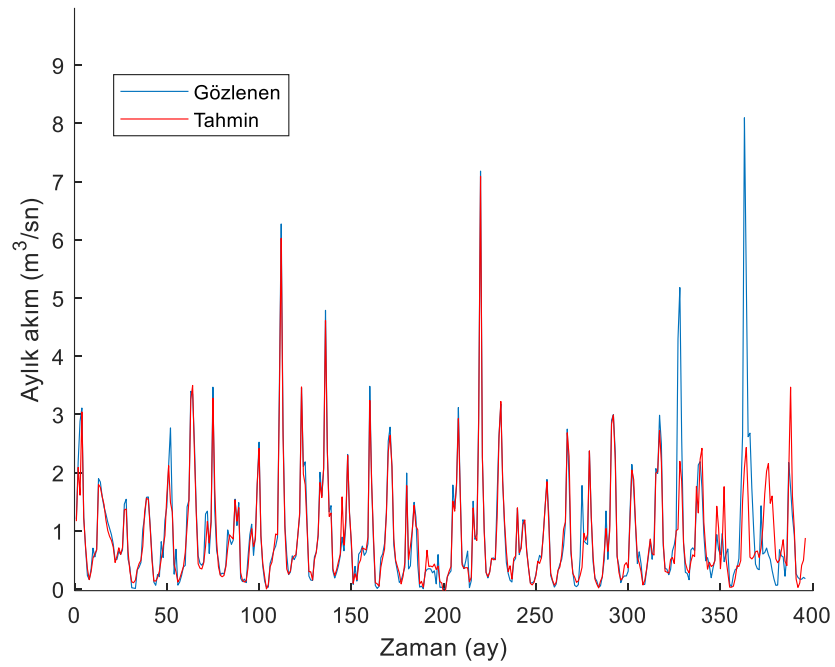
(a)




(b)

**Şekil 1.A** ÇKA ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)

**EK 1.B** UKSB modeli ile tahmin edilen verilerin zaman serileri ve saçılma diagramı.




(a)




(b)

**Şekil 1.B** UKSB ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)

**EK 1.C ASBÇS modeli ile tahmin edilen verilerin zaman serileri ve saçılma diagramı.**



**(a)**

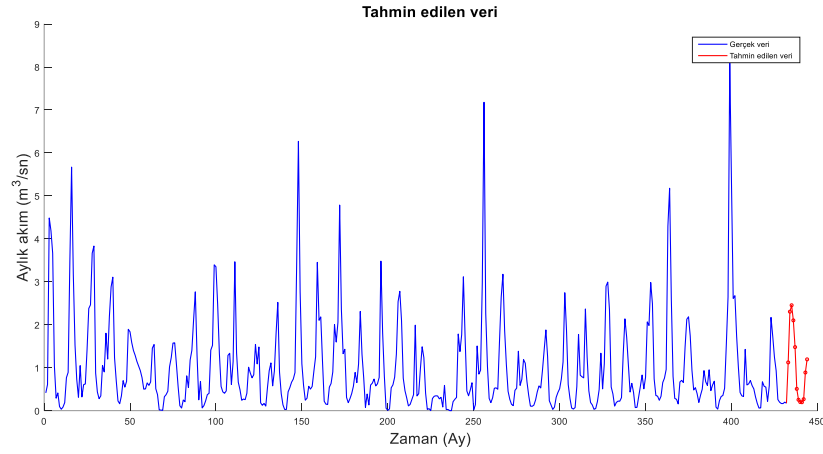


**(b)**


**Şekil 1.C ASBÇS ile gözlenen ve tahmin edilen verilerin zaman serisi (a) ve saçılma diagramı (b)**

## EK-2 Geleceğe yönelik yıllık tahminlerin yapılması.


### EK 2.A Geleceğe yönelik 1 yıl sonraki aylık akım tahmini



Şekil 2.A.1 ÇKA modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri




Şekil 2.A.2 UKSB modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri




Şekil 2.A.3 ASBÇS modeli ile tahmin edilen 1 yıl sonraki aylık akım verileri


## EK 2.B Geleceğe yönelik 2 yıl sonraki aylık akım tahmin



Şekil 2.B.1 ÇKA modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri




Şekil 2.B.2 UKSB modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri




Şekil 2.B.3 ASBÇS modeli ile tahmin edilen 2 yıl sonraki aylık akım verileri

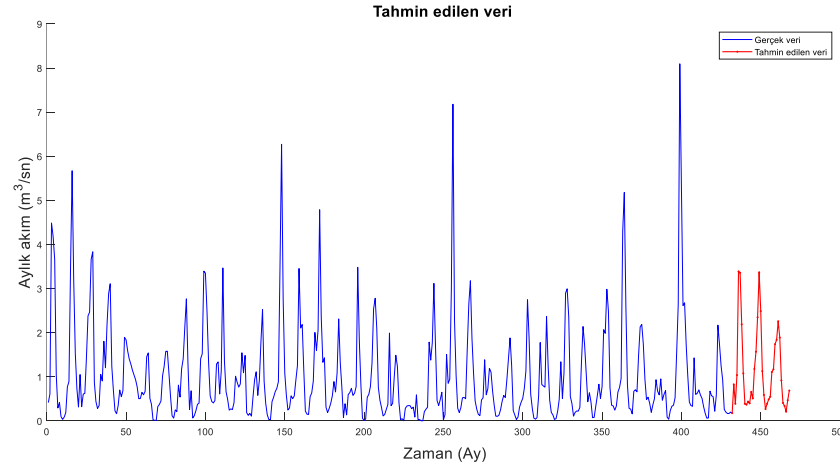
## EK 2.C Geleceğe yönelik 3 yıl sonraki aylık akım tahmini



Şekil 2.C.1 ÇKA modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri



Şekil 2.C.2 UKSB modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri



Şekil 2.C.3 ASBÇS modeli ile tahmin edilen 3 yıl sonraki aylık akım verileri