

T.C.  
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

YSA, DSA VE USBÇS MODELLERİ KULLANARAK GÜNLÜK  
AKIM TAHMİNİ

Said Ali HASHİMİ

Danışman: Dr. Öğr. Üyesi Hüseyin Yıldırım DALKILIÇ

İNŞAAT MÜHENDİSLİĞİ  
ANABİLİM DALI

ERZİNCAN  
2020

Her Hakkı Saklıdır.

### Bilimsel Etięe Uygunluk Sayfası

“YSA, DSA, USBÇS Modelleri Kullanarak Günlük Akım Tahmini” isimli “Yüksek Lisans” tezim tarafımda intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 24.07.2020



Said Ali HASHİMİ

## ÖZET

Yüksek Lisans Tezi

### YSA, DSA VE USBÇS MODELLERİ KULLANARAK GÜNLÜK AKIM TAHMİNİ

Said Ali HASHİMİ

Erzincan Binali Yıldırım Üniversitesi  
Fen Bilimleri Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Hüseyin Yıldırım DALKILIÇ

Önemi zamanla artan su kaynakların yönetimi ve kullanımı günümüzdeki en önemli haberlerden biri olmayı başlamıştır. Bu çalışmada uygulanabilir ve aynı zamanda güvenilir sonuçlar veren Yapay Sinir Ağları (YSA), Dalgacık Sinir Ağları (DSA) ve Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi (USBÇS) günlük akım tahmini için en etkili ve yaygın olan yöntemleri kullanılmıştır. Akım tahmini için sonuçlarına etkileyen birçok parametreler mevcuttur ve bu nedenle kesin bir sonuca varmak zor olmaktadır. Ancak çalışmada kullanılan yöntemlerle ve geliştirilen modeller ile gerçeğe çok yakın sonuçlar elde edilmiştir. Modellerin performansını doğrulamak amaçlı verilerin %70'i (1996-2007) eğitmek için ve verilerin %30'u (2008-2011) test etmek için kullanılmıştır. Modellerin sonuçları birbirine yakın olmasına rağmen, DSA modeli, YSA ve USBÇS modelleri arasında en iyi performansı sergilemiştir. Bu da orijinal verilerin alt serilere ayrıştırılması, gürültülerini teşhis edilip temizlenmesi sonuçlara önemli ölçüde etkilediğini göstermektedir.

**2020, 47 Sayfa**

**Anahtar Kelimeler:** Günlük Akım, Hidrolojik Modelleme Tahminleri, Yapay Sinir Ağları

## **ABSTRACT**

Master Thesis

### **PREDICTION OF DAILY STREAMFLOW USING ANN, WNN AND ANFIS MODELS**

Said Ali HASHİMİ

Erzincan Binali Yıldırım University  
Graduate School of Natural and Applied Sciences  
Department of Civil Engineering

Supervisor: Assist. Prof. Dr. Hüseyin Yıldırım DALKILIÇ

The management and use of water resources, which have become increasingly important over time, has become one of the significant news today. In this study, Artificial Neural Networks (ANN), Wavelet Neural Networks (WNN) and Adaptive Neural Fuzzy Inference System (ANFIS), which provide feasible and reliable results, were used for daily streamflow estimation. For streamflow estimation, there are many parameters that affect the results and therefore, it is difficult to conclude exactly the same as the observed data. However, realistic results were obtained with the methods and models developed in the study. To verify the performance of the models, 70% of the data (1996-2007) were used to train and 30% of the data (2008-2011) were used for testing. Although the results of the models were close to each other, WNN model showed the best performance among ANN and ANFIS models. This shows that the decomposition of the original data into sub-series, identified and cleaning the noises significantly affect the results.

**2020, 47 Pages**

**Keywords:** Artificial Neural Network, Daily Streamflow, Forecasting Hydrological Modeling

## TEŐEKKÖR

Erzincan Binali Yıldırım Üniversitesi İnőaat Mühendisliđi bölümünde en deđerli hocalardan biri ve alıőmamın her aőamasında beni bilgilendiren, yönlendiren ve destek veren deđerli Danıőman Hocam Sayın Dr. Öđr. Üyesi Hüseyin Yıldırım DALKILI'a teőekkürlerimi sunarım.

Eđitim ve Tezimin her aőamasında beni yalnız bırakmayan maddi, manevi desteđini sađlayan, dualarını hiç eksik etmeyen aileme sonsuz sevgi ve sayđlarımı sunarım.

Said Ali HASHİMİ

06, 2020

## İÇİNDEKİLER

	Sayfa
<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>ŞEKİLLER LİSTESİ</b> .....	<b>vi</b>
<b>TABLolar LİSTESİ</b> .....	<b>vii</b>
<b>SİMGELER ve KISALTMALAR</b> .....	<b>viii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ÖZETLERİ</b> .....	<b>4</b>
2.1. Akım Tahmini ile İlgili Çalışmalar (YSA, DSA, USBÇS).....	4
<b>3. MATERYAL ve YÖNTEM</b> .....	<b>9</b>
3.1. Yapay Sinir Ağları (YSA).....	9
3.1.1. Yapay Sinir Hücresi ve Biyoloji Sinir Hücresi.....	9
3.1.2. Aktivasyon Fonksiyonu.....	11
3.1.3. İleri Beslemeli ve Geri Yayılımlı Sinir Ağları.....	12
3.2. Dalgacık Sinir Ağları (DSA).....	14
3.2.1. Dalgacık.....	15
3.2.2. Ayrık Dalgacık Dönüşümü.....	16
3.3. Uyarlamalı Sinir Bulanık Çıkarım Sistemi (USBÇS).....	17
3.3.1. Bulanık Mantık Kavramı.....	19
3.3.1.1. Bulanık Mantık Terminolojisi.....	20
3.3.1.2. Bulanık Çıkarım Sistemi.....	20
3.4. Modellerin Performansının Değerlendirilmesi.....	21
<b>4. ARAŞTIRMA BULGULARI</b> .....	<b>23</b>
4.1. Yapay Sinir Ağı Modelinin Tasarımı.....	23
4.2. Dalgacık sinir ağının (DSA) çalışma prensibi.....	25
4.3. Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi Çalışma Prensibi.....	28
4.4. Çalışma Alanı.....	30
<b>5. SONUÇLAR</b> .....	<b>33</b>
<b>KAYNAKLAR</b> .....	<b>39</b>
<b>EKLER</b> .....	<b>44</b>

Ek-1. Modellerdeki Zaman Serisi ve Gözlemlenen ve Tahmin Sonuçları (E07A0032).....	44
Ek-2. Tez Çalışması Süresince Yapılan Akademik Çalışma .....	46
<b>ÖZGEÇMİŞ</b> .....	<b>47</b>



## ŞEKİLLER LİSTESİ

### Sayfa

Şekil 3.1. Perseptronun (Algılayıcı) Şeması .....	10
Şekil 3.2. Biyolojik ve Yapay Sinir Hücreleri .....	10
Şekil 3.3. Tipik bir İleri Beslemeli, Geri Yayımlı Şeması.....	13
Şekil 3.4. Dalgacık Türleri .....	14
Şekil 3.5. USBÇS'in Ağ Yapısı .....	18
Şekil 3.6. Bulanık Çıkarım Sistemi.....	21
Şekil 4.7. (Qt-3, Qt-2, Qt-1) Girdiler arasındaki en büyük hata değeri grafiği.....	24
Şekil 4.8. Gözlemlenen ve model çıktısı (Tahmin edilen) arasındaki korelasyon ilişkisi (İstasyon E07A0037) .....	27
Şekil 4.9. USBÇS modelinin yapısı (Üç girdi-Qt-3, Qt-2, Qt-1 ve bir çıktı-Qt) .....	29
Şekil 5.10. Türkiye'deki Büyük Menderes Havzası'nın Konumu .....	30
Şekil 5.11. Büyük Menderes Havzası'nın Haritası .....	30
Şekil 5.12. Çalışma 'da yer alan akım istasyonları ve meteorolojik istasyonu.....	32
Şekil 6.13. YSA için Zaman Serisi (E07A004). .....	36
Şekil 6.14. YSA için Dağılım Diyagramı (E07A004).....	36
Şekil 6.15. DSA için Zaman Serisi (E07A0037) .....	36
Şekil 6.16. DSA için Dağılım Diyagramı.....	37
Şekil 6.17. USBÇS için Zaman Serisi.....	37
Şekil 6.18. USBÇS için Dağılım Diyagramı .....	37
Şekil 6.19. Kullanılan Üç Modelin Zaman Serisi ve Sonuçları (E07A0032) .....	38



## TABLolar LİSTESİ

### Sayfa

Tablo 3.1 Aktivasyon Fonksiyonlarının Türleri.....	11
Tablo 4.2. Orijinal akım serisi ile kullanılan YSA modellerin değişkenleri (İstasyon E07A0037) .....	24
Tablo 4.3. Ölçülen akım veri korelasyon katsayılarına sahip (E07A0037) istasyonu için Yaklaşım ve Detay (YD) bileşenleri .....	26
Tablo 4.4. Akım alt serilerinin toplamını kullanan DSA (Haar) modelleri için değişkenler (İstasyon E07A0037) .....	27
Tablo 4.5. Orijinal akım serisinin' de kullanılan USBÇS modeli için değişkenler (İstasyon E07A0037) .....	28
Tablo 4.6. YSA, DSA ve USBÇS Modelleri için Geçerlilik Yöntemlerinin Özellikleri	29
Tablo 5.7. Büyük Menderes Havzası ile ilgili Bazı temel bilgiler.....	31
Tablo 5.8. BMH'daki Seçilen İstasyonlar.....	32
Tablo 6.9. YSA ile Çıkan Model Akım Tahmin Sonuçları .....	35
Tablo 6.10. DSA ile Çıkan Model Akım Tahmin Sonuçları .....	35
Tablo 6.11. USBÇS ile Çıkan Model Akım Tahmin Sonuçları.....	35

## SİMGELER ve KISALTMALAR

### Simgeler

$B$	Regresyon Sabiti
$\beta$	Regresyon katsayısı
$dp$	Gerçek çıktı
$E$	Ağ Hatası
$I$	Tanımlama Matrisi
$J$	Jakobiyen Matrisi
$l$	Gizli katmandaki nöron sayısı
$m$	Çıktı katmandaki nöron sayısı
$n$	Girdi katmandaki nöron sayısı
$O$	İşlev
$\phi(t)$	Dalgacık Fonksiyonu
$r$	Korelasyon Katsayısı
$S$	Standart Sapma
$T$	Toplam
$u_i$	Marquardt Parametresi
$\mu_{Ai/Bi}$	Üyelik işlevi
$W_j$	Ağırlık
$\Delta w$	Ağırlık Değişimi
$\bar{X}$	Ortalama
$X_{(n)}$	Girdi
$yp$	İstenilen çıktı

## Kısaltmalar

ADD	Ayrık Dalgacık Dönüşümü
BÇS	Bulanık Çıkarım Sistemi
ÇKA	Çok Katmanlı Algılayıcı
DD	Dalgacık Dönüşümü
DK	Determinasyon Katsayısı
DSA	Dalgacık Sinir Ağları
DSİ	Devlet Su İşleri
EİEİ	Elektrik İşleri Etüt İdaresi
FD	Fourier Dönüşümü
İBSA	İleri Beslemeli Sinir Ağları
İBGY	İleri Beslemeli Geri Yayımlı
KOKH	Kök Ortalama Kare Hatası
MMİ	Muğla Meteorolojik İstasyonu
NS	Nush- Sutcliffe Katsayısı
OMH	Ortalama Mutlak Hata
$R^2$	Belirlelik Katsayısı
RSR	RMSE(KOKH)-gözlemleri standart sapma oranı
USBÇS	Uyarlama Sinir Bulanık Çıkarım Sistemi
YSA	Yapay Sinir Ağları

## 1. GİRİŞ

Su, hayatın başladığından itibaren günümüze kadar bütün yaşayanlar için en önemli veya hayati bir unsur olmuştur ve halen devam etmektedir. Su kaynakları canlıların varoluşundan beri tüketilmekte olup ve yaşamalarını devam edebilmesi için suya ihtiyaçları vardır. Tüm yeryüzünde yaklaşık olarak  $1.4 \times 10^9$  km<sup>3</sup> su bulunmaktadır. Bu miktardan %97,5'i okyanuslarda ve denizlerdeki tuzlu olan sudur. Yeryüzündeki var olan içilebilir yani tatlı su miktarı sadece %2,5'i ( $35 \times 10^6$  km<sup>3</sup>) kullanılabilir. İçilebilir (tatlı su) suların %70'i kutuplardaki buzulları içermekte olup geriye kalan kısmı ise Akifelerdeki yeraltı suyu ve yüzeysel akış şeklinde nehirlerden oluşmaktadır. Türkiye'deki akarsuların ortalama olarak yüzeysel akım su miktarı  $180,5 \times 10^9$  m<sup>3</sup> olarak belirtilmiştir (Karahan, vd. 2006).

İklim değişikliği ve nüfus artışından dolayı canlılar hep su kaynakları bulunan bölgelere yerleşmiş olup hayatlarını sürdürebilmek için sürekli göç etmekteydiler. İçilebilir su kaynakların yönetiminin önemi ve değeri zamanla artmakla birlikte, uzun sürdürebilmesi, daha iyi kullanılması ve zararlarından korunmak için gerekli çalışmaları başlatılmıştır (Price, 1985). Türkiye'deki var olan su kaynakları ve miktarları bakıldığında kullanılabilir su kaynakları yeterli olamayacağı için su miktarlarının dikkate alınarak depolanması, toplanması, kullanılması ve oluşan zararlarından en aza indirmek insan hayatı için büyük önem arz etmektedir. Buna göre, su kaynakların bilimsel biçimde incelenmesi, metodoloji geliştirmesi ve yönetilmesi ile insanların hayatlarını sürdürebilmesi için sunulması gerekmektedir. Böylelikle, su yapılarının yapılandırılması ve yönetilmesi, su kaynakları uzun yıllara taşınması ve insanların hayatlarını kurtarılması için büyük önem sürdürmektedir. Fakat su yapılarının ebatları, türü, yapılandırılması beklenen yerleri teşhis edilmesi için suyun davranışı, geçmiş dokümanları, miktarı, karakteristik yapısını ve diğer birçok parametrelerinin dikkate alınması gerekmektedir. Bu çalışmanın amacı, Büyük Menderes Havzasına bağlı olan BM nehri üzerinde yer alan dört istasyondan alınan, geçmiş yılların (1996-2011) akım verileri kullanılarak günlük akımların tahminini yapılabilmesidir. Günümüzde akım ölçümleri EİEİ ve DSİ tarafından kurulan akım gözlem istasyonları sayesinde yapılmaktadır. Anlaşılacağı üzere hidrolojinin en önemli konularından biri akım tahmini olmuştur. Günümüzde akım tahmini, çeşitli yöntemler ile yapılması mümkün hale gelmiştir.

Bu yöntemlerin sayesinde akım tahmini yapabilen modeller birçok alanda faydalanılmakta olup su kaynakların yönetilmesinde büyük rol oynamıştır. Havza yönetimi, baraj projelendirilmesi, taşkın koruma projeleri, doğal iklim afetleri, hidroelektrik enerji potansiyellerinin belirlenmesi ve bunlara benzer alanlar akımların tahmin edilmesinin önemini açıkça belirtilmektedir. Söz edilen alanların ana kaynağı olan akım tahmini ise doğru ve kaliteli bir şekilde hesaplanması ve analiz edilerek gerçeğe çok yakın tahminlerde bulunması şarttır. Yağış-akış ilişkisinin belirlenmesinde kullanılan hidrolik modeller, bir akarsu havzasına düşen yağışı ve akarsudan çıkan akışı esas almakta olup, tabanlı yayılı modeller (beyaz kutu modelleri), kavramsal modeller (gri kutu modelleri) ve kapalı (kara) kutu modelleri olmak üzere üç sınıfta değerlendirilmektedir. Bunlardan, kapalı kutu modelleri, yağış akış ilişkisinin belirlenmesinde fiziksel veya herhangi bir neden ya da etki gibi bir bilgiye ihtiyaç duyulmamaktadır (Gümüş vd. 2013). Hidroloji ve su kaynakları alanında son yıllarda kapalı kutu modelleme yöntemlerinden olan yapay sinir ağları (YSA) yağış akış ilişkisinin modellenmesi konusunda uygun bir alternatif olarak kullanılmaktadır (Dragan vd. 1999; Gümüş vd. 2011; Okkan ve Mollamahmutoğlu 2010; Tokar vd. 2000; Kişi vd. 2013). Akımların tahmin edilmesinde en yaygın ve köklü olan yöntem ise yapay sinir ağlarıdır. Yapay Sinir Ağları (YSA), beynimizin işlem sistemini benzeyen ve sinir hücrelerimizden ilham almış teknolojinin en iyi eseridir.

Geçmiş yıllarda, doğrusal olmayan ve karmaşık hidrolojik sistemlerin modellenmesinde etkili bir araç olarak YSA, DSA ve Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemleri (USBÇS) veriye dayalı modeller uygulanmıştır (Wu vd. 2009; Seo vd. 2013; Seo vd. 2013; Seo ve Kim 2016). Hidrolojik değişkenlerini tahmin etmek için YSA yönteminin genel olarak yararlanmasına rağmen, kararsız verilerin tahmininde doğru ve kesin neticeler vermeyebilir. Bu nedenle, linear olmayan bağlantılar içeren hidrolojik zaman serilerini tahmin etmek, ve YSA'nın verimliliğini yükseltmek için veri ön işleme yöntemleri kullanılması gerekmektedir (Okkan 2013). Mevcut yöntemlerden biri, bir sinyal işleme tekniği olan Dalgacık Dönüşümüdür (DD). Fourier Dönüşümünün (FD) aksine, dalgacık dönüşümü ile sinyalin hem düşük hem de yüksek frekanslı bileşenlerini her zaman aralığında hesaplanması mümkündür. Dalgacık analizi ve YSA kullanımını birleştirerek oluşturulan DSA modelleri ile kapsamlı tahminler yapılan çeşitli ve birçok çalışma vardır. (Coulibaly ve Burn 2004; Partal 2007; Kisi 2009;) Ege Nehrinin akımını tahmin etmek için önceki günlerin akım verilerini girdi parametresi olarak kullanıp

Dalgacık-YSA modelleri geliřtirdiler ve DSA modelleri, YSA modellerine gre biraz daha dřk hata deęerlerine sahiptir olarak vurgulamıřlardır.

USBS ilk olarak (Jang 1993) tarafından nerilmiřtir. USBS; yaęıř-akıřı tahmini, sel riski ynetimi, vb. gibi hidrolojik sreleri modellemek iin kullanılabilecek gl ve veriye odaklı bir tekniktir. USBS'in temel yapısında Eęer-İse kuralları vardır ve girdi-ıktı çiftleri oluřturabilmesi iin uygun yelik iřlevlerine sahiptir. Hindistan'daki Baitarani Nehrinin akımını modellemek amacıyla, zaman serilerini kullanarak USBS yntemi ile tahminde bulunmuřlar (Nayak vd. 2004). USBS ile alıřılan tahminde, asıl akım serisinin istatistiksel niteliklerinin korunduęu ve bařarılı bir tahminin ortaya ıktıęı gzlenmiřtir. Bu alıřmada kullanılan modeller geleneksel modelleme sistemlerine gre birok avantajı sahip olup, ok sayıda veriyi doęru tahmin edebilir ve doęrusal olmayan ve dinamik sistemlerden kaynaklanan grltleri temizleyebilmektedir. Sz geen modellerin performans kriterlerini ve gerek deęerlere yakınlıęını lmek iin en ok tavsiye edilen model deęerlendirme indisleri alıřmada yer verilmiřtir. Bu deęerlendirme indisleri; Kk Ortalama Kare Hatası (KOKH), Belirlelik Katsayısı (R2), Nash – Sutcliffe (NS) ve KOKH-gzlem standart sapma oranı (RSR)'dır. Bunların kullanılması ile sonular kolayca yorumlanabilir ve gvenilebilir bir sonu olarak gelecekteki alıřmalar iin katkısı olunabilir.

## 2. KAYNAK ÖZETLERİ

### 2.1. Akım Tahmini ile İlgili Çalışmalar (YSA, DSA, USBÇS)

Kim (2000), Nakdong Nehri havzasının Jindong istasyonunda günlük akım tahmin etmesi için sinir ağı modelleri kullanmıştır. Günlük akım tahmininde, Sinir Ağı modelleri ve Çoklu Regresyon Analiz Model (ÇRAM) sonuçları ile karşılaştırıldı. Sinir Ağı Modellerin sonuçları Çoklu Regresyon Analiz Modeli sonucundan daha iyi sonuç sergilenmiştir. Bu nedenle, Sinir Ağı Modelleri, daha sistematik bir yaklaşım sağlamak, model parametrelerini azaltmak ve model geliştirmede harcanan zamanı kısaltmak için birçok avantaja sahiptir.

Dawson ve Wilby (2001), akım tahmini için YSA yöntemi ile yağış-akış verileri kullanarak, İngiltere’de yer alan Thames ve Mole Nehir’i üzerinde modeller geliştirmişlerdir. Birleşmiş veya kompleks metotların yerine YSA yöntemi ile yapılan çalışmada, daha etkili ve başarılı sonuçlar elde edilebileceği görülmüştür.

Dibike ve Solomatine (2001), akım tahmini için YSA yönteminin işlevselliğini ve uygulanabilirliğini incelemişlerdir. Çalışma alanı Venezuela’da yer alan Apure Nehri üzerinde seçilmiştir. Çok Tabakalı Algılayıcı (ÇTA) ve Radyal Temeli Fonksiyon Ağlarını (RTFA) uygulamışlardır. Çalışmanın sonunda, seçilen ağların verimliliğini kavramsal akım yöntemi ile karşılaştırıp nehir akım tahmin problemi için gayet uygun bulmuşlardır.

Rajurkar vd. (2002), üç yöntemi ile günlük yağış-akış modeli üzerine çalışmışlardır. Çalışmada Lineer model, Lineer olmayan model ve YSA yöntemi ile Hindistan’ın Narma Bölgesinde günlük yağış-akış verileri Dünya Meteoroloji Kuruluşu'ndan alınan, bu üç modeli çalıştırıp baktıklarında YSA ile geliştirilen model daha iyi sonuç vermiştir. Çalışmalarında 1981-1990 yılları arasında Muson yağışları mevsiminde temin edilen günlük yağış akış bağıntısında, E' değeri doğrusal model için %75,5 Lineer Olmayan için %79,2 ve YSA modeli için %83,2 sonuçlara varmışlardır. Sonuç olarak, YSA için girdi veri sayısı fazla olan çalışmalarda doğruya yakın değer verdiğini varmışlardır.

Chiang vd. (2003), Tayvan'da yer alan Lan Yang Nehri üzerine YSA modelini kullanarak yağış akış ilişkisini inceleyerek tahminde bulunmuşlardır. 1632 yağış değerleri kullanarak dinamik ve statik geri besleme yöntemi ve bütünleşik yöntemiyle hesaplanmıştır. Dinamik olmayan ileri besleme yönteminde gerçeğe yakın neticeler temin edilebilmesi için yeteri kadar veri test edilmesi lazım olduğunu deęinmişlerdir. Dinamik YSA yönteminde ölçülen alandaki sabit biçimdeki akış tahminin statik olana göre çok hassas sonuç elde ettiklerini göstermişlerdir.

Alp ve Cıgızoęlu (2004) çalışmasında, YSA İleri Beslemeli Geriye Yayılım Yöntemi (İBGY) ve Genelleştirilmiş Regresyon Sinir Aęı (GRSA) yöntemi kullanarak Amerika'daki Juniata Nehrine ait günlük akım verileri ile üç meteoroloji yağış verileri kullanarak modeller geliştirmişlerdir. Modellerin biri ise, geçmişe ait akım verileri baz alarak ona izleyen gelecek akımın tahmini üzerinde çalışmışlardır. Öte yandan yağış ve geçmiş akım verilerini dikkate alınarak akım tahminini yapmışlardır. Yani kısacası iki farklı yapay sinir aęların algoritması ile akımdan akım tahmini ve yağış akış modellemesi geliştirmişlerdir. Adı geçen modellerden İleri Beslemeli Geriye Yayılımlı Yöntemi, Genelleştirilmiş Regresyon Sinir Aęı yöntemine kıyasla çok beęenilen sonuçlar verdięini belirtmişlerdir. Sonuç olarak İleri Beslemeli Geriye Yayılım modeli Genelleştirilmiş Regresyon Sinir Aęı ve klasik ARIMA modelinden daha iyi sonuç vermiştir.

Wu vd. (2005) yaptıkları çalışmada; YSA ile Havza Akış Tahmini (Watershed Runoff Prediction, WRP) ve Nehir Akış Tahmini (Streamflow Forecast, SFF) olmak üzere iki yöntem dikkate alınarak yağış akış arasında ki ilişkisinden meydana gelebilecek taşkın için önceden ihbar sistemi şekillendirmesini planlamışlardır. Şehirli bölgelerde hem esas akımı hem de taşkın akımı tahmininde ve nehirlerin akımında meteorolojik durumların etkisinin tahmininde YSA faydalı olabileceęi belirtmişlerdir.

Acı (2006), çalışmasında bir havzadaki akım, önceki akım ve yağış verileri model tahmini için ele alınmıştır. Tahminlerde geleneksel hale gelmiş olan YSA yöntemi seçilmiştir. Çalışma alanı ise Akarçay Havzası seçilmiştir. Havzadaki mevcut olan bazı parametreleri (yağış gözlem istasyonlarının yerleşimi, gözlem aralığı vb.) ilişkili olarak dört çeşit model tasarlanmıştır. Modeller 'den çıkan sonuçları ve çok deęişkenli regresyon analiz modelin sonucu ile kıyaslanmıştır. Sonucu, YSA yöntemi ile yağış gözlemlerinden, akım tahmin problemini başarılı şekilde uygulanabileceęi ve gerçeğe yakın tahminler verileceęi görülmüştür.



Partal vd. (2008), yapılan çalışmada günlük yağış tahmini için Yapay Sinir Ağları (YSA) ve Dalgacık Dönüşüm Yöntemleri (DDY) kullanarak modeller geliştirmişlerdir. Türkiye'ye ait olan üç istasyondan meteorolojik verileri kullanmışlardır. YSA'da en çok yaygın olan İleri Beslemeli Geri Yayılımlı Sinir Ağları (İBGYSA) ve Radyal Tabanlı Yapay Sinir Ağları (RTYSA) yöntemleri ele alınmıştır. Çeşitli girdi kombinasyonları deneme yanılma yoluyla her istasyon için deneyerek en uygun olanı seçmişlerdir. Sonuçlara bakıldığında İleri Beslemeli Geri Yayılımlı Sinir Ağları (İBGSA) yöntemi Radyal Tabanlı Yapay Sinir Ağları (RTYSA) yönteminden daha iyi performans sergilediği görülmüştür. Dalgacık Dönüşüm-YSA sonuçları Çoklu Lineer Regresyon Yöntemi ile de kıyaslandığında daha iyi sonuçlar verdiği bulunmuştur.

Okkan ve Mollamahmutoğlu (2010), çalışma alanı Gediz Havzasında bulunan, yığıtler çayına ait 1461 adet günlük akım verisi ve meteorolojik verileri çalışmada kullanmışlardır. İleri beslemeli ve geri yayılımlı yapay sinir ağları çalışmanın yöntemi olarak belirlenmiştir. Model'den çıkan sonuçları ile Çoklu Doğrusal Regresyon modelinden çıkan sonuçları birbirleriyle kıyaslanmıştır. Sonuçları bakıldığında, geçmiş üç ve iki gün öncesine ait olan yağış verilerini birleştirerek akım tahmini yapıldığında beklenen değerlere çok yakın değer verdiği ortaya çıkmıştır. YSA ve ÇDRA modellerinden çıkan sonuçlar sırasıyla  $R^2=0,88$  ve  $R^2=0,78$ 'dir. Böylelikle lineer olmayan yağış akış ilişkisinin YSA'la modellemek daha verimli olacağına varmışlardır.

Köse vd. (2011) yapılan çalışmada, Söğütluhan (1535) istasyonunun akımını tahmin etmek için Kızılırmak Nehri üzerindeki Yamula (1501) ve Bulakbaşı (1539) akım istasyonlarının akım verileri kullanılarak iki girdili çeşitli USBÇS modelleri geliştirilmiştir. Modellerde kullanılan veriler 1975-2005 yıllara aittir. Geliştirilen modellerin performansı, determinasyon katsayısı ve ortalama karekök hatasına göre değerlendirilmiştir. Geliştirilen modellerin performansı 0.896 ile belirleme katsayısına ve hibrid bir ağ yapısına sahip olan modelin uygun sonuçlar verdiği ve akış tahmininde kullanılabilir olduğu gösterilmiştir.

Okkan ve Dalkılıç (2012) yapılan çalışmada, Radyal Tabanlı Yapay Sinir Ağı modeli (RTYSA) geliştirilerek, Büyük Menderes Havzası'nda yer alan Kemer Baraj Havzası'na ait aylık akımlara uygulanmıştır. Gözlenmiş ve modellenmiş akımların uzun dönem ve mevsimsel istatistikleri karşılaştırıldığında; kurulan modelin Kemer Barajı aylık akımlarını başarıyla temsil ettiği; böylece geliştirilen modelin, bir baraj havzasının aylık akımlarının tahmininde başarıyla kullanılabileceği gösterilmiştir.

Terzi ve Barak (2014) çalışmasında, akarsu akımların tahmini için dalgacık dönüşüm tekniği ve yapay sinir ağları metodu kullanarak modeller geliştirmişler. Modelin akım verileri Kızılırmak nehrinde yer alan Söğütlühan İstasyonundan ve meteorolojik verileri ise Sivas Meteoroloji İstasyonundan elde edilmiştir. İlk başta, orijinal yağış verileri kullanarak Yapay Sinir Ağları (YSA) modelleri geliştirmişlerdir. Ardından, ölçülenmiş yağış verileri Dalgacık Dönüşümü (DD) tekniği ile alt serilere ayrıştırılmıştır. Alt serilere ayrıştırılan yağış verileri ile dalgacık-yapay sinir ağları modelleri geliştirmişlerdir. Geliştirilmiş verileri ölçülmüş veriler ile karşılaştırıldığında ve dalgacık dönüşümü uygulanmasından sonra edinen DSA modellerinin, orijinal veriler ile edinen YSA modellerinden çok başarılı sonuçlar ve performanslar meydana gelmiştir.

Anusree ve Varghese (2015), Thrissur bölgesinde bulunan KaruvYSAur nehir havzasının çıkışında günlük akımı tahmin etmek için yapay sinir ağları (YSA), Uyarlamalı Sinir Bulanık Çıkarım Sistemleri ve Çoklu Doğrusal Olmayan Regresyon kullanımı bu çalışmada ele alınmıştır. Modelleri geliştirmek için dokuz yağmur ölçer istasyonundan yağış verileri kullanılmıştır. Simülasyon için girdi vektörleri ve farklı zaman gecikmeleri ile, farklı yağış ve akım kombinasyonları içermektedir. Modellerin performansları KOKH ve Nash-Sutcliffe model verimlilik değerleri ile değerlendirilmiştir. Sonuçlar USBÇS modelinin günlük akımı için YSA ve MNLR modellerine göre daha doğru tahminler elde edilmiştir.

Altunkaynak ve Nigussie (2016) çalışmasında, günlük akımların doğru ve uzun süreli tahmin edebilen modelleri geliştirmek için modelde Ayrık Dalgacık Dönüşümü (ADD) yöntemini kullanarak orijinal verileri bileşenlerine ayırarak bir model geliştirmişlerdir. Çalışmada on iki yıllık günlük akım verileri kullanılmıştır. Bunlardan, yedi yıllık verileri eğitime amaçlı ve son beş yıllık verileri de test amaçlı tahmin verisi olarak kullanışlardır. Ayrıştırılan veriler, yedi günlük akımları tahmin edebilmek için Çok Tabakalı Algılayıcı (CTA) modelini veri girişi olarak dikkate alınmıştır. Araştırmalarında D-ÇTA ve ÇTA olan modellerin tahmin sonuçları; ortalama karekök hatası (OKH), verim katsayısı (VK), ve beceri puanı (BP) parametreleri kullanılmışlardır. Sonuç olarak, D-ÇTA modellerinin ÇTA modelinden daha başarılı sonuçlar verildiği görülmüştür.

Tayyap vd. (2017) yapılan çalışmada, ayrıştırılmış zaman serileri ve YSA modelleri birlikte kullanarak akım tahmini için modeller geliştirmişlerdir. Çin'in Yangtze Nehri'nin üst kısımlarındaki Jinsha Nehri havzasında, İleri Beslemeli Geri Yayılımlı Sinir Ağı içeren YSA ve Radyal Temelli Yapay Sinir Ağları (RTYSA) modelleri Ayrık Dalgacık

Dönüşümü (ADD) ile entegre edilmiştir. Veriler, simülasyon çıktıları korelasyon katsayısı (R) ortalama karekök hataları, ortalama mutlak hatalar, ortalama mutlak yüzde hatası ve Nash – Sutcliffe Verimliliği olan modeller ile karşılaştırılarak analiz edilmiştir. Sonuçlar, zaman serisi ayrıştırma tekniği (ADD), tek olan YSA modeli ile kıyaslandığında akım tahmini için daha başarılı olduğu görülmüştür. ADD ile entegre edilmiş olan RTYSA diğer gelişmiş modeller ile kıyaslandığında daha iyi tahmin yetenekleri sahip olduğunu görülmüştür.

Altunkaynak ve Başakın (2017), çalışma alanı Amerika’da Columbia Nehri’nde yer alan günlük akım tahmini için 1950-1960 yılları arasındaki ölçülen verileri kullanarak modeller geliştirmişlerdir. Modellerde kullanılan yöntemler ise; Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi (USBÇS), Yapay Sinir Ağları (YSA) ile Doğrusal olmayan Otoregresif Model (NAR) ve Otoregresif Hareketli Ortalama Modeller (ARIMA). Modellerin sonuçları istatistiksel kurallara göre hesaplanmıştır. Sonuçlara bakıldığında USBÇS tahmin modeli NAR ve ARIMA tahmin modellerinden daha iyi performans sergilediği görülmüştür.

Taylan (2018) çalışmasında, akım tahmini için Ayrık Dalgacık Dönüşümü (ADD) ve Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi (USBÇS) yöntemleri kullanarak model geliştirmiştir. Bu amaçla, Dalgacık-USBÇS modelleri, Oto-Regresif süreç (AR) ile entegre edilmiş olan USBÇS modellerinin performansını artırmak için dalgacık analizi ile oluşturulan alt serileri kullanılarak dikkate alınmıştır. Dalgacık analizi ile üretilen girdi veri setlerinin model performansını artırdığı görülmüştür. Sonuç olarak, Dalgacık-USBÇS hibrid modellerinin AR-USBÇS modellerinden daha iyi tahmin gücüne sahip olduğu ve Dalgacık-USBÇS hibrid modelinin akış tahmininde başarılı bir şekilde kullanılabileceği görülmüştür.

Dalkılıç ve Hashimi (2020) çalışmasında, YSA, DSA ve USBÇS modelleri kullanarak günlük akım tahmini için modeller geliştirmişlerdir. Çalışma alanı Büyük Menderes Havzası olup, dört farklı akım istasyonların yanı sıra meteorolojik verileri yağış, sıcaklık ve bağıl nem model girdileri olarak hesaplamışlardır. Çalışmanın sonucunda, DSA ile geliştirilen model YSA ve USBÇS modellerinden daha başarılı sonuçlar verdiği görülmüştür.


### **3. MATERYAL ve YÖNTEM**

#### **3.1. Yapay Sinir Ağları (YSA)**

Yapay Sinir Ağları veya YSA, beyin işlem bilgisi gibi biyolojik sinir sistemi tarafından ilham alan ve paralel dağıtılmış bir bilgi işlem sistemidir. Belirli bir sorunu çözmek için birlikte çalışan çok sayıda birbirine bağlı işlem elemanından (nöronlar) oluşur (Tsoukala ve Uhrig, 1996). Sinir ağları, potansiyelini sadece yüzeyi çizilen yeni bir kavramdır. Çeşitli farklı kavramlar ve fikirler için kullanılabilen ve test aşamasında belirli bir geri yayılım ve hata düzeltme mekanizması yoluyla öğrenilmektedir. Hatayı düzgün bir şekilde en aza indirgeyerek, bu çok katmanlı sistemler bir gün insan düzeltmesi olmadan fikirleri öğrenebilir ve kavramsallaştırabilir olacaktır.

##### **3.1.1. Yapay Sinir Hücresi ve Biyoloji Sinir Hücresi**

Biyolojik Nöronlar (ayrıca sinir hücreleri olarak da adlandırılır) veya basitçe nöronlar, beyin ve sinir sisteminin temel birimleridir. Dış dünyadan duyuşsal girdilerin (dendritler) aracılığıyla alınmasından sorumlu olan hücreler, işlemde geçirir ve Aksonlar aracılığıyla çıktı verir. Hücre gövdesi (Soma); nöron hücresinin gövde çekirdeği içerir ve nöronların yaşamı için gerekli olan biyokimyasal dönüşümü gerçekleştirir. Dendritler; her nöronun çevresinde ince, saç benzeri boru şeklindeki yapılar (uzantılar) vardır. Hücre gövdesi etrafındaki bir ağaca ayrılırlar ve gelen sinyalleri kabul ederler. Akson; bir iletim hattı gibi çalışan uzun, ince, boru şeklinde bir yapıyı sahiptir. Sinaps; nöronlar karmaşık bir uzaysal düzenlemede birbirine bağlanır. Aksonun sonunda sinapslar olarak adlandırılan oldukça karmaşık ve özel yapılardır. İki nöron arasındaki bağlantı bu sinapslarda gerçekleşir. Dendritler diğer nöronların sinapslarından girdi alır. Soma bu gelen sinyalleri zamanla işler ve işlenen değeri akson ve sinapslar yoluyla diğer nöronlara gönderilen bir çıktıya dönüştürür. Aşağıdaki şema biyolojik bir nöronu esinlenen genel YSA modelini temsil etmektedir. Tek katmanlı sinir ağına Perseptron denir ve tek bir çıktı verir.




Şekil 3.1. Perseptronun (Algilayıcı) Şeması

Yukarıdaki şekilde 3.1’de, tek bir gözlem için,  $x_1, x_2, x_3, x_4 \dots x(n)$  ağa çeşitli girdileri (bağımsız değişkenler) temsil eder. Bu girişlerin her biri bir bağlantı ağırlığı veya sinaps ile çarpılır. Ağırlıklar  $w_{1j}, w_{2j}, w_{3j}, w_{4j} \dots w_{nj}$  olarak temsil edilir. Ağırlık, belirli bir düğümün gücünü göstermektedir.  $b_j$  bir önyargı değeridir. Önyargı değeri, etkinleştirme işlevini yukarı veya aşağı kaydırmanıza olanak tanır. En basit şekli, bu ürünler toplanır, bir sonuç üretmek için bir transfer fonksiyonuna (aktivasyon fonksiyonu) beslenir ve bu sonuç çıktı olarak gönderilir.

Matematiksel olarak,  $x_1 * w_1 + x_2 * w_2 + x_3 * w_3 + x_4 * w_4 + \dots + x_n * w_n = \sum x_i * w_i$

Aktivasyon fonksiyonu da bu şekilde uygulanır,  $\varphi(\sum x_i * w_i)$

Aslında, bütün yapay sinir ağları belli bir strükture sahiptir. Yani birkaç nöronlar, girdileri edinmek için ve birkaç diğer nöronlar ise çıktıları geçirmek için dış alan ile ilişkili bir şekilde hallederler ama, arkada kalan nöronlar ise gizli tabakalarda ağ içinde ilişkileri vardır(Anderson, D. ve McNeill, G., 2006).



Şekil 3.2. Biyolojik ve Yapay Sinir Hücreleri

### 3.1.2. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, bir YSA'nın gerçekten karmaşık bir şeyi öğrenmesi ve anlamlandırması için önemlidir. Ana amacı, bir YSA'daki bir düğümün bir giriş sinyalini bir çıkış sinyaline dönüştürmektir ve bu çıkış sinyali, yığındaki bir sonraki katmana giriş olarak kullanılmaktadır. Aktivasyon fonksiyonu, ağırlıklı toplamını hesaplayarak ve buna önyargı (bias) ekleyerek bir nöronun etkinleştirilip etkinleştirilmeyeceğine karar verir. Hedef, bir nöronun çıkışına doğrusallık getirmektir.

Aktivasyon fonksiyonunu uygulanmazsa, çıkış sinyali basitçe doğrusal fonksiyonu olacaktır (bir derece polinom). Şimdi, doğrusal bir fonksiyonu çözmek kolaydır yani onların karmaşıklığı sınırlıdır, daha az güce sahiptirler. Aktivasyon fonksiyonu olmadan, modelimiz görüntüler, videolar, ses, konuşma vb. gibi karmaşık verileri öğrenemez ve modelleyemez. Peki neden doğrusal olmayanlığı (Non-Linearity) ihtiyaç duyulur sorusuna şu şekilde yanıtlanabilir, doğrusal olmayan fonksiyonlar, derecesi birden fazla olan ve eğriliğe sahip olan fonksiyonlardır. Şimdi, bir girdiyi çıktı ile eşleştiren herhangi bir keyfi karmaşık işlevi öğrenmek ve temsil etmek için bir sinir ağına ihtiyaç gerekir. Yapay sinir ağları evrensel fonksiyon yaklaşımcıları olarak kabul edilir. Bu, herhangi bir işlevi hiç hesaplayabilecekleri ve öğrenebilecekleri anlamına gelmektedir. Düşünebileceğimiz adeta her süreç, yapay sinir ağlarında fonksiyonel bir hesaplama olarak temsil edilebilir.

**Tablo 3.1** Aktivasyon Fonksiyonlarının Türleri

AKTİVASYON FONKSİYON	DENKLEM	ARALIK
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ 1 & \text{için } x \geq 0 \end{cases}$	$\{0, 1\}$
Sigmoid Fonksiyon	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$(-1, 1)$
ReLU	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$[0, \infty)$
Leaky (Sızıntı) ReLU	$f(x) = \begin{cases} 0.01 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Swish Fonksiyonu	$f(x) = 2x\sigma(\beta x) = \begin{cases} \beta = 0 & \text{için } f(x) = x \\ \beta \rightarrow \infty & \text{için } f(x) = 2\max(0, x) \end{cases}$	$(-\infty, \infty)$

### 3.1.3. İleri Beslemeli ve Geri Yayılımlı Sinir Ağları

Yapay sinir ağlarında en çok kullanılan yöntem, ileri beslemeli ve geri yayılımlı olarak bilinmektedir. Bu yöntem üç katmandan girdi, gizli ve çıktı olarak oluşmaktadır. İleri beslemeli ağlarda, sinyaller girdi katmandan çıktı katmanına doğru bağlantılı şekilde iletilir. Geri yayılımlı da çıkan hataları çıktı katmanından giriş katmanına doğru azaltma mantığından yaydırır. Dış ortamda olan bilgiler giriş katmanında alınıp herhangi bir değişikliği uğratmadan gizli katmana yani hücrelerine gönderir ve orta katmandaki olan bilgiler, çıkış katmanında işlenip ağ çıkışı belirlenir. İleri hesaplama ve geriye doğru hesaplama arasındaki ilişki eğitim prosedürleri ile elde edilir. İleri beslemeli sinir ağı modellerini eğitme teknikleri ile ilgili olarak geliştirilen çeşitli geri yayılım algoritmaları vardır. Geri yayımlı eğitim sürecinin amacı, ağın hatalarını azaltmak için sistemin ağırlıklarını düzenlemektir.

$$E(W) = \frac{1}{2} \sum_{p=1}^P (d_p - y_p)^2 = \frac{1}{2} \sum_{p=1}^P (e_p)^2, P = mT \quad (3.1)$$

Burada, T eğitim örneklerinin toplamıdır, m çıktı katmaların sayısı, W ağıdaki ağırlıkları temsil eder,  $d_p$  ve  $y_p$  sırasıyla ağın gerçek ve istenilen çıktılarıdır. Ağırlıkların değişikliği  $\Delta W$ , model Levenberg-Marquardt algoritması ile eğitim aldığında aşağıdaki gibi hesaplanabilir.

$$\Delta W_k = -[J_k^T J_k + \mu_k I]^{-1} J_k^T e_k \quad (3.2)$$

Daha sonra, ağırlıkların iyileştirilmesi aşağıdaki gibi değiştirilebilir:

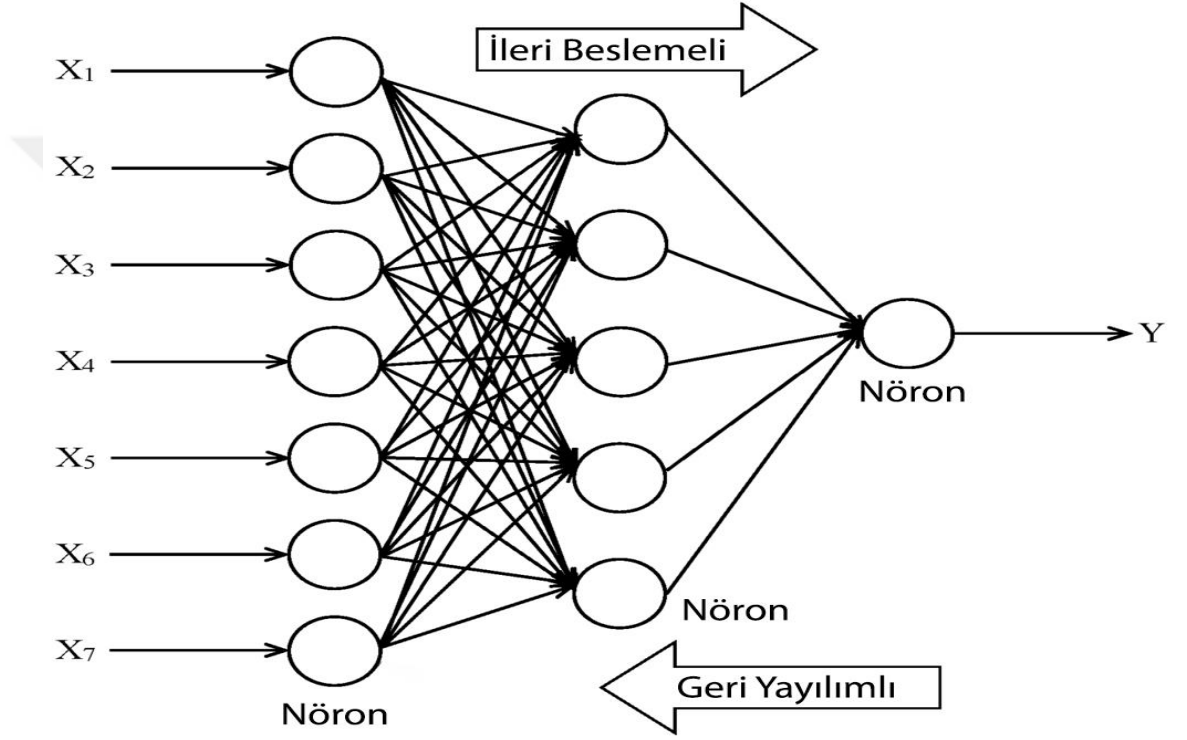
$$\Delta W_{k+1} = W_k + \Delta W_k \quad (3.3)$$

Burada,  $J$ ,  $I$ ,  $e$ ,  $u$  sırasıyla Jacobian matrisi, tanımlama matrisi, ağ hatası ve Marquardt parametresidir. Ayrıca,  $u$  azalan oran yani  $\beta$  ( $0 < \beta < 1$ ) ile çarpılır,  $E(W)$  ne zaman azaldığında  $E(W)$  yeni bir adıma yükselecektir (Coulibaly vd. 2000).

Bu çalışma alanında, ileri beslemeli sinir ağı eğitiminde Levenberg-Marquardt geri yayılımlı algoritması kullanılmıştır. LMGY algoritması genellikle diğer geri yayılımlı tekniklerinden daha hızlı ve daha güvenilirdir ve ikinci dereceden doğrusal olmayan bir optimizasyon tekniğidir (Coulibaly vd. 2000; Kişi 2004; BÇStik oğlu ve Okkan, 2011).

LM optimizasyon algoritması, ileri beslemeli sinir ağının eğitim aşamasına uygulanan Newton yönteminin kısaltılmış bir versiyonunu gösterir.

Şekil 3.3'de gösterildiği gibi, hata yayma prosedürü ağı farklı katmanlarında iki hareketi içermektedir.. Öndeki harekette, algoritmanın giriş vektörü ağı nöronlarına uygulanır ve geri hareketteki, tüm ağırlıklar hata düzeltme kuralına göre değiştirilir. Daha sonra hata sinyali ağ üzerinden geriye doğru yayılır ve ağı gerçek yanıtını  $y_p$  istenen yanıt  $d_p$  göre daha fazla bağıl yapmak için ağırlıklar değiştirilir.




Şekil 3.3. Tipik bir İleri Beslemeli, Geri Yayılımlı Şeması



### 3.2. Dalgacık Sinir Ağları (DSA)

Dalgacık Sinir Ağı (DSA) modeli, Ayrık Dalgacık Dönüşümü (ADD) ve YSA yönteminin uygulanmasıyla meydana gelmekte ve dalgacık teorisi temelinde duran bir sinir ağı tahmin algoritmasıdır. DSA fonksiyonlarının arasında en önemlilerinden biri tahmin fonksiyonudur. Nöronlar, daha fazla alana sahip olmak için sinir ağının gizli katmanında ölçekleme fonksiyonu ile yer değiştirilir ve bu nedenle daha güçlü bir fonksiyon yaklaşımı yeteneğine sahiptir (Khodadadi vd. 2012). Bir dalgacık ağı, gözlemlenen bir veri fonksiyonunun bileşimini öğrenmek ve belirli bir değer için beklenen bir değeri hesaplamak üzere eğitilebilir. Aynı zamanda kendi kendine öğrenme, uyarlanabilirlik ve bir sistemin doğrusal olmayan parametrelerini hesaplama yeteneğine de sahiptir (Hou vd. 2013). Geleneksel GY sinir ağı ile karşılaştırıldığında, dalgacık ağı, dalgacık fonksiyonunun zaman-frekans geleneksel kabiliyeti nedeniyle yerleştirme sinir ağının eksik bilgi çıkarılmasındaki eksiklikleri telafi edebilir (Justin ve Oliver 2016). İlk olarak DSA modelini elde etmek için, orijinal zaman serileri bir ADD kullanılarak alt gruplara ayrılır, daha sonra elde edilen her alt seri, orijinal seri üzerinde değişik davranır. Takiben, elde edilmiş alt seriyle model çıktısı arasında korelasyon katsayıları hesaplanır. DSA girdileri korelasyon katsayısı verilerine göre kullanışlı alt serilerle belirlenir. Dalgacık analizinde kullanılan ana dalgacıklar Haar (db1), Morlet (morl), Meksika şapkası (mexh), Daubechies (dbN), Meyer (meyr), Symlet (symN) dalgacıklarıdır ve Şekil 3.4'te gösterilmiştir.



Şekil 3.4. Dalgacık Türleri

Dalgacık kullanmanın temel avantajı, uzayda lokalize (yerelleştirilme) olmalarıdır. Genellikle uygulamaları veri işleme, veri sıkıştırma ve diferansiyel denklemlerin çözümüdür. Bu çalışmada, Haar dalgacı, DSA modeli için kullanılmıştır ve dalgacık ailesinin en basiti, en kolay hayal edilebilir ve en erkencisidir. Haar dalgacığının dalgacık fonksiyonu aşağıdaki gibidir.

$$\psi(x) = \begin{cases} 1 & 0 \leq x < 1/2, \\ -1 & 1/2 \leq x < 1, \\ 0 & \text{Aksi takdirde} \end{cases} \quad (3.4)$$

Haar dalgacığının ölçeklendirme fonksiyonu,

$$\varphi(x) = \begin{cases} 1 & 0 \leq x < 1 \\ 0 & \text{Aksi takdirde} \end{cases} \quad (3.5)$$

### 3.2.1. Dalgacık

Sinyalleri analiz etmek için, ham sinyallerden kolayca erişilemeyen bilgileri elde etmek için matematiksel dönüştürücüler kullanılır. Dalgacık dönüşümü sinyal işlemede en verimli matematiksel dönüştürücülerden biridir. Dalgacıklar, zaman serilerinin zaman ölçeği formunu sağlayan, değişkenleri ve değişken olmayanları içeren zaman serilerinin analizi ile ilişkisi olan matematiksel fonksiyonlardır. Dalgacık analizi, kullanılan düşük frekanslı bilgi için uzun zaman aralıklarını ve yüksek frekanslı bilgi için daha kısa zaman aralıklarını sağlamaktadır. Dalgacık analizi, diğer sinyal analizi yöntemlerinin gösteremeyeceği farklı verilerin, kesme noktalarının ve süreksizliklerin farklı yönlerini gösterebilir. Bir dalgacık, küçük bir dalga anlamına gelir ve sınırlı sayıda salınımın üç özelliğine, genliğinde hem pozitif hem de negatif yönde hızlı sıfıra ve ortalama sıfır değerine sahip olup (bu üç özellik, bir işlevin dalgacık dönüşümü olarak işlev görmesi için gereklidir) ve kabul koşulu olarak adlandırılır ve aşağıdaki gibi ifade edilir:

$$\int \varphi(t)dt = 0 \quad (3.6)$$

Burada,  $\varphi(t)$  dalgacık fonksiyonudur.

İki tür dalgacık dönüşümü vardır: 1- Sürekli dalgacık dönüşümü 2- Ayrık dalgacık dönüşümü.

### 3.2.2. Ayrık Dalgacık Dönüşümü

Dalgacık dönüşümünün kullanımı uygulamalı matematik alanında 1980'lerde başlanmıştır. Grossman ve Morlet (1984), uygun biçimlerini birleştirerek çeşitli zamanlara dayanan sınırlı bir zaman ve titreşimli bir sinyal modellemeye çalıştılar ve sürekli dalgacık dönüşümünü literatüre dahil ettiler. Bununla birlikte, sürekli dalgacık dönüşümündeki ölçek değerlerindeki dalgacık katsayılarının hesaplanması çok sayıda katsayıya ve işlem yüküne neden olmuştur. Bu katsayılar yalnızca seçilen ölçeklerde ve zaman periyotlarında hesaplama mantığını kullanan ayrı dalgacık dönüşümleri kavramı ortaya çıkmış ve Daubechies'e (1988) dayanarak, bu yöntem sürekli dalgacık dönüşümüne göre birçok avantaj sağlamaktadır. Ayrık Dalgacık Dönüşümü, ön işleme ve zaman serilerini analiz etmek için Sürekli Dalgacık Dönüşümüne göre daha uygundur çünkü ADD ile dönüştürülen verilerin ek bileşenleri yoktur ve bu nedenle herhangi bir frekans bandı verisi için ters dönüşüm kullanılabilir. Sınır ağı kullanmadan önce, DSA'daki nöron sayısının belirlenmesi esastır. Gizli nöronların sayısını belirledikten sonra nöronların sayısı çok fazla olursa eğitim hassasiyeti azalır ve çok az olursa, aşırı uyumlu bir olgu olacaktır.

$$l < \sqrt{(m + n)} + a \quad (3.7)$$

Denklem 3.7'de  $l$  gizli katmandaki nöronların sayısı ve  $a \in (0,10)$ ,  $m$  çıktı katmandaki nöron sayısını ve  $n$  girdi katmandaki nöron sayısını belirler. Bu çalışmada  $l = 10$  olarak atanmıştır.

Genellikle, dalgacık analizinde dalgacık türlerinden en çok ana dalgacıklar (Haar, Meksika Şapka, Daubechies) kullanılmıştır. Şekil 3.4'de bazı dalgacık türleri mevcuttur.

### 3.3. Uyarlamalı Sinir Bulanık Çıkarım Sistemi (USBÇS)

Uyarlamalı sinir-bulanık çıkarım sistemi (USBÇS), Tagaki-Sugeno-Kang (TSK) bulanık çıkarım sistemine dayanan bir bulanık harita algoritmasıdır (Jang vd. 1997). Birçok değişkenler arasındaki ilişkiyi düzenlemek için çeşitli yöntemler kullanılmıştır. Bu yöntemler şunlardır: YSA'lar, doğrusal regresyon (DR), bulanık çıkarım sistemleri (BÇS). Uyarlanabilir sinir-bulanık sistemler (USBÇS) olarak bilinen sinir ağları ve BÇS'in bir kombinasyonudur. Hem BÇS hem de YSA yöntemlerinin verileri eğitilmesi ve istenen bir sonuç varmak için kendi zayıf yönleri vardır. Bu nedenle USBÇS, Jang (1993) tarafından tanıtılmıştır. USBÇS, BÇS modellerinin bulanık kurallarını üretme kabiliyeti ile bu modellerin her birinin dezavantajlarının üstesinden gelebilecek YSA ağ modelini eğitme yeteneğinin bir kombinasyonunu yaratmıştır. Böylece, hidrolik parametrelerin tahmininde olduğu gibi yeraltı suyu çalışmaları da dahil olmak üzere çeşitli alanlarda YSA ve BÇS modellerinden daha az kısıtlama ile daha iyi sonuçlar sağlayabilmiştir. USBÇS yapısı beş katmandan oluşmaktadır. İlk Katman, Girdi Düğümleri: Bu katmanın her düğümü, üyelik işlevini kullanarak uygun bulanık kümelerin her birine bağlı olan üyelik değerleri oluşturur.

$$O_{1,i} = \mu A(x) \text{ için } i = 1,2 \quad (3.8)$$

$$O_{1,i} = \mu B(y) \text{ için } i = 3,4 \quad (3.9)$$

A ve B düğümlerine bulanık-olmayan x ve y girdileri, sırasıyla  $\mu A_i$  ve  $\mu B_i$  üyelik işlevleri tarafından belirtilen dilbilimsel etiketlerdir. Bu işlevler O simgesi olarak sembolize edilir. İkinci katman, temel düğümler: Her bir nöron bu katmana sabitlenir VE, VEYA operatörü, bu kural için öncülün (önceki) sonucunu temsil eden bir çıktı elde etmek için uygulanır, yani – sağlamlık gücü. Bu katman, denklemini aşağıdaki gibi olan  $O_{2k}$  çıktıların ilk katmanının derecelerinin ürünüdür.

$$O_{2,i} = w_i = \mu A_i(x) \mu B_i(y), \quad i = 1,2 \quad (3.10)$$

Üçüncü katman, orta düğümler: Üçüncü katmanın temel amacı, her bir tutuşma faktörü, İ'nin tüm tutuşma yasalarının toplamına, oranını belirlemektir. Sonuç olarak standart bir tutuşma kaynağı olarak w elde edilir.

$$O_{3,i} = \dot{w}_i = \frac{w_i}{w_1 + w_2} \quad (3.11)$$


Dördüncü katman düğümlere neden olur: her katmanın çıktısı şuna eşittir:

$$O_{4,i} = \bar{w}_i f_i = w_i(p_i x + q_i y + r_i) \quad (3.12)$$

Bu bağlamda  $w_i$ , öncü tabakanın çıktısıdır ve  $p_i$ ,  $r_i$ ,  $q_i$ , kombinasyonun lineer katsayılarıdır ayrıca, uç bölümünün toplam parametreleri Takagi-Sugeno bulanık modelleridir. Beşinci katman, çıktı düğümleri: Bu katman, tüm girdi sinyallerini toplayarak toplam çıktının sinyal düğümünü hesaplamaktadır. Bu nedenle, bu hareketsizlik tabakasında, her bulanık kuralın sonuçları bulanık olmayan çıktıya dönüştürülmektedir.

$$O_{5,i} = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i} \quad (3.13)$$

Ağ, gözetim altında öğrenmeye dayalı olarak eğitilir. Bu nedenle hedef, USBÇS'e öğretim bilgilerinden elde edilen belirsiz fonksiyonları tahmin etmeyi ve bilinmeyen parametreleri doğru bir şekilde tahmin etmeyi öğretmektir. Bir USBÇS modeli belirli bir hedef için tasarlaması daha iyi bir bulanık çıkarım sistemin seçmesi kolay olmamıştır. Literatürde farklı tipte BÇS belirtilmiştir (Takagi ve Sugeno 1985). Uyarlamalı sinir bulanıklığı sistemi genellikle Sugeno bulanık sistemi ile Şekil 3.5'te gösterildiği gibi aşamalı bir ağ yapısı olarak kullanılır.



Şekil 3.5. USBÇS'in Ağ Yapısı

### 3.3.1. Bulanık Mantık Kavramı

Bulanık Mantık Kavramı ilk olarak Lutfi Aliasker Zadeh tarafından 1960'de tanıtıldı. İnsanlar her zaman sayısal olarak ölçülemeyen doğal dil terimleri veya ifadeleri, duyguları, yeteneği vb. günlük hayatta sürekli kullanılmaları motive vericidir (Zadeh 1965). Tipik olarak kullanılan ifadeler ise; çok uzun, çok çok güzel, birkaç ülke, aşırı zeki ve diğer benzer ifadeler insanların duygularını doğru şekilde ifade etse de ancak bu ifadeler tam anlamıyla sayısal dönüşürülemez ifadelerdir. Buna göre, insanların sayısal rakamlara gerek duymadan kendi aralarında net bir şekilde duygularını paylaşabilmektedir. Diğer taraftan, eğer bir sistemin daha karmaşık hale dönüşüyorsa onun davranışı ile ilgili değerler ile yorumlamak daha da zor hale gelir veya açıklaması hatta imkansız olabilir ve buna belirsizlik denilir. Bu nedenle, bulanık kümelerin belirsizliklere ve belirsizliğe karşı çözüm getiren sistemlerin en yaygın ve sağlam aracı olarak bilinmektedir.

Geleneksel hesaplama mantığı ve küme teorisi tamamen aşağıdakilerden ibarettir.

- Doğru veya Yanlış
- Sıfır veya Bir (0-1)
- İçeri veya Dışarı
- Siyah veya Beyaz

Bulanık Mantık temel kavramları;

- Yaklaşım (granülasyon)
  - Bir renk tam olarak kırmızı yeşil mavi değerleri kullanarak tanımlanabilir veya yaklaşıkça mavi veya kırmızı vb. olarak ifade edilebilir.
- Derece (derecelendirme)
  - Mesela, iki farklı rengin her ikisi de kırmızı olarak tanımlanabilir, ancak biri daha kırmızı olarak kabul edilebilir.
- Bulanık mantık, insanın düşünme biçimini yansıtmaya çalışır.

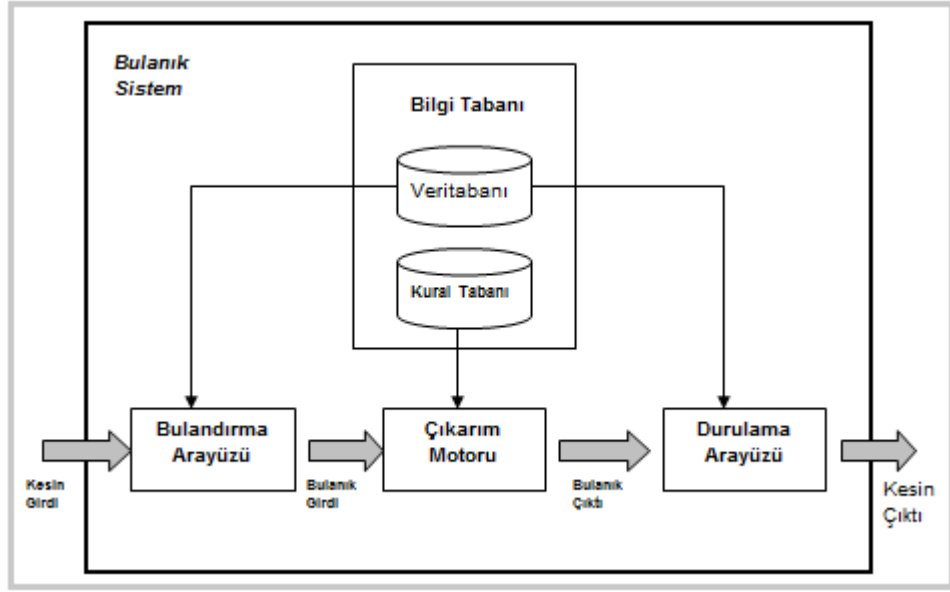
Bulanık mantık teorisi, yağış tahmini, akım tahmini ve rezervuar çalışması gibi hidrolojik modellemelerde de incelenmiştir (Yu 2000; Chang 2001 ve Russel 1996). Bu modeller; bulanık optimizasyon teknikleri, kural temelli bulanık sistemler ve hibrid bulanık sistemleri içermektedir.

### 3.3.1.1. Bulanık Mantık Terminolojisi

- Bulanık kümesi
  - Her bir  $Y$  elemanının 0 ile 1 aralığında  $\mu_X(y)$  üyelik derecesine sahip olduğu bir  $X$  kümesi, mesela, üyelik kümesi kısmi de olabilir.  
Örn. soğuk bulanık küme ise, kesin sıcaklı değerleri bulanık kümeye aşağıdaki şekilde eşlenebilir.
    - 15 derece  $\longrightarrow$  0,2 (çok az soğuk)
    - 10 derece  $\longrightarrow$  0,1 (oldukça soğuk)
    - 0 derece  $\longrightarrow$  1 (tamamen soğuk)
- Bulanık İlişkisi
  - İlişkiler 0 ile 1 ölçeğinde de ifade edilebilir. Örneğin, iki kişi arasındaki benzerlik derecesi
- Bulanık Değişkeni
  - Bulanık kümelerle (etiketleri) değişken olarak değerleri
- Dilsel Değişkeni
  - Dildeki kelimeler veya cümlelerin değerlere sahip olan bulanık değişken.  
Örn. değişken renk değerleri kırmızı, mavi, yeşil, ...
- Dilsel Çiti
  - Dilsel değerlerde temel terimler için niteleyici olarak kullanılan terim.  
Örn. Çok, biraz, birazcık vb. gibi kelimeler

### 3.3.1.2. Bulanık Çıkarım Sistemi

Bulanık çıkarım sistemi verilerin belirsizlikleri veya belirsizliğini uygun kural tabanlarına göre niteleyerek ve modelleyerek, ölçmek için kullanılan sistemlerdir. Genel olarak, bir Bulanık Çıkarım Sistemi, sistem davranışını belirlemek için kural tabanında yerleşik bir takım bulanık kuralları kullanarak kesin girdi veri vektörlerinin kesin çıktılara doğrusal olmayan bir eşlemesini uygulamaktadır. Buna göre, BÇS'in kesin girdileri bulanık benzerliklerine dönüştürülmesi gerekmektedir. Bunun nedeni, doğrusal olmayan eşleme işlemine katılan girdilerin ve üretilen çıktılarının karakteristik üyelik işlevleri, uygulanan bulanık operatörler ve alttaki bulanık eğer-ise kuralları tarafından yönlendirilmesidir. Eğer birden çok girdi mevcut ise o zaman ve-veya işlemcileri bulanık çıkarım kurallında kullanılır.



**Şekil 3.6.** Bulanık Çıkarım Sistemi

Bulandırma (Bulanıklaştırma) işlemi bulanık mantık sisteminde ilk modelleme aşamasıdır. Bu aşamada daha önce belirlenmiş modelin girdi ve çıktı değerleri üyelik fonksiyonundan (0,1) belirtilen bir değere çevrilerek bulanıklaştırılır. Bu aşamada, EĞER-İSE terimleri kavramsal ifadeler ile ilişkilendirilir. Örneğin “Eğer talep yüksek ise fiyatlar düşüktür”. Bu örnekte talep ve fiyat dilsel değişkenlerdir ve yüksek ve düşük değerlere karşılık gelen değerlerdir (Yücel, 2010).

Belirlenen kuralların değerlendirilmesinde çıkan sonuç değerlere “çıkarım” olarak tanımlanır. Pek yaygın olan çıkarım metotları Mamdani Yöntemi ve Takagi-Sugeno Kang Yöntemleri bulanık mantık sisteminde kullanılmaktadır. Bulanık modelinde en son adım Durulama değerlerin tekrar kesin değerlere dönüştürülmesi adımıdır. Durulama veya berraklaştırma 'da en yaygın olan metotlar; En Büyüklerin Ortalaması Metodu, En Büyük Üyelik Metodu, Ağırlık Merkezi Metodu ve Ortalama Ağırlık Metodu olarak söylenebilir.

### 3.4. Modellerin Performansının Değerlendirilmesi

Bu modellerin başarılı tahminler verip vermediğini ölçmek için günlük gözlenen akım verileri ile tahmin edilen günlük akımların arasındaki farklar aşağıda özet şeklinde tanımlanan yöntemler ile değerlendirilmiştir. Bu çalışmada, Kök Ortalama Kare Hatası (KOKH) birçok alanda tahmin yönteminin seçiminde en yaygın olarak kullanılan hata istatistiğidir, Nash-Sutcliffe etkinlik katsayısı (NS) Nash ve Sutcliffe tarafından teklif edilmiş ve birçok hidrolojik tahminin doğruluğunu ölçmek için kullanılan bir istatistiktir,



Belirlelik Katsayısı  $R^2$  regresyon denkleminin verilere olan uyumunun sağlanıp sağlanmadığının göstergesi olup açıklanabilen değişimin toplam değişime olan oranıdır., ve KOKH-gözlemleri standart sapma oranı (RSR) tahmin yöntemlerinin belirlenmesinde kullanılmıştır. Bu kriterlere göre, hangi tahmin yönteminin daha başarılı olduğuna karar verilmektedir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\text{Predicted}'i - \text{Actual}'i)^2}{N}} \quad (14)$$

$$R^2 = \frac{\sum (y - y')^2 - \sum (y - \bar{y})^2}{\sum (y - y')^2} \quad (15)$$

$$NS = 1 - \frac{\sum_{i=1}^N (y - y')^2}{\sqrt{\sum_{i=1}^N (y - \bar{y})^2}} \quad (16)$$

$$RSR = \frac{RMSE}{STDEV} \left[ \frac{\sum_{i=1}^N (y - y')^2}{\sqrt{\sum_{i=1}^N (y - \bar{y})^2}} \right] \quad (17)$$

## 4. ARAŞTIRMA BULGULARI


### 4.1. Yapay Sinir Ağı Modelinin Tasarımı

Bu çalışmada, Büyük Menderes Nehir'indeki 4 istasyonun 15 yıllık (1996-2011) günlük yağış verilerini kullanarak bir sinir ağını eğitmeye ve gelecekteki akımı tahmin etmeye çalışmıştır. Tahmin sürecinin hassasiyetini arttırmak amacıyla verilerin %70'i eğitim ve geri kalan verilerin yani %30'u modelde test amaçlı kullanılmıştır. Modelde kullanılan parametreler (her zaman sürekli değişim gösterdikleri ve sayılarda sabit olmayan) toplam yağış, ortalama sıcaklık, rüzgar ve bağıl nemdir. Sürekli değişim gösteren parametreler matematik modellerde tanımlanması zordur. Bu nedenle, burada doğrusal olmayan problemlerin çözümünde YSA yöntemi kullanılmıştır. İleri beslemeli sinir ağı olarak tasarlanan YSA modeli farklı girdi kombinasyonlardan ( $Q_{t-3}$ ,  $Q_{t-2}$ ,  $Q_{t-1}$ ,  $P_t$ ,  $T_{avg}$ ,  $R_h$ ) ve bir çıktıdan ( $Q_t$ ) oluşmaktadır. Tasarlanan YSA modelinde, gizli katmanlarında 3 katman ve 10 nörondan oluşmaktadır. YSA modelin geliştirilmesinde deneme ve yanılma bölümünde en etkili ve minimum hata oranı gösteren sonuçlar 10 nöron sayısı ve 3 katman ile elde edilmiştir. Ağ, geriye doğru yayılarak ağıdaki hatayı düzelten geri yayılma modelini temel alır. Modelin eğitim algoritması olarak Levenberg-Marguardt optimizasyonu dikkate alınmıştır. Bu yöntemleri birlikte kullanarak, devirlerde (epochs) YSA'nın ağırlık değerleri hesaplanmıştır. Eğitim sürecinde, çıktılardan sağlanan sonuçlar ile devirlerin her yinelemesinde gereken değerler arasındaki farkı (hatayı) minimuma indirecek şekilde ağırlıkların tekrar olarak belirlenmesidir.

Burada, Kök ortalama kare hatası (KOKH) fonksiyonu hata azaltma fonksiyonu olarak kullanılmıştır. En iyi performansı gösteren günlük akımı tahmin etmek için geliştirilen YSA modellerinden ( $Q_{t-3}$ ,  $Q_{t-2}$ ,  $Q_{t-1}$ ,  $P_t$ ,  $T_{avg}$ ,  $R_h$ ) girdileri modelde kullanılmıştır. Burada, YSA (2,9,1) model yapısı için, girdi katmanında iki, gizli katmanda dokuz ve çıktı katmanında bir hücre olduğunu işaret etmektedir. Geliştirilen modelleri bakıldığında YSA (1,2,3) modelleri sıkı korelasyon değerleri verdiği gözlemlenmiştir. YSA ( $Q_{t-1}$ ,  $Q_{t-2}$ ,  $Q_{t-1}$ ) modeli yüksek korelasyon değerlere elde etmiştir. YSA modellerinin sonuçları Tablo 4.2'de verilmiştir.

**Tablo 4.2.** Orijinal akım serisi ile kullanılan YSA modellerin değişkenleri (İstasyon E07A0037)

Model Gidileri	Model Yapısı	Eğitim Seti				Test Seti			
		KOKH	OKH	R	R <sup>2</sup>	KOKH	OKH	R	R <sup>2</sup>
Q <sub>t-1</sub>	(1,10,1)	3,09	9,58	0,77	0,60	1,87	3,50	0,96	0,91
Q <sub>t-2</sub> , Q <sub>t-1</sub>	(2,9,1)	2,98	8,90	0,90	0,81	2,60	6,75	0,89	0,79
Q <sub>t-3</sub> , Q <sub>t-2</sub> , Q <sub>t-1</sub>	(3,10,1)	3,62	13,10	0,77	0,59	4,66	21,74	0,75	0,57
Q <sub>t-1</sub> , P <sub>t</sub>	(2,9,1)	2,98	8,86	0,79	0,63	2,24	5,03	0,86	0,75
Q <sub>t-1</sub> , P <sub>t</sub> , T <sub>avg</sub> , R <sub>h</sub>	(4,10,1)	2,92	8,52	0,82	0,67	2,21	4,91	0,85	0,72



**Şekil 4.7.** (Q<sub>t-3</sub>, Q<sub>t-2</sub>, Q<sub>t-1</sub>) Girdiler arasındaki en büyük hata değeri grafiği

#### 4.2. Dalgacık sinir ağının (DSA) çalışma prensibi

İlk olarak, günlük meteorolojik veriler (ortalama sıcaklık, bağıl nem, buharlaşma, rüzgar, toplam yağış) Ayrık Dalgacık Dönüşümü (ADD) kullanılarak beş ayrıntıya (2-4-8-16-32 günlük periyodik bileşenler) ve bir yaklaşım bileşenine ayrılmıştır. Mallat (1989) tarafından verilen algoritmanın yardımıyla, orijinal veriler, (sinyal) yaklaşık ve detay (YD) bileşenleri olarak adlandırılan birkaç seriye bölünmüştür ve orijinal veriler bu serilerin üst üste toplanmasıyla tekrar geri kazanılmaktadır. İlk düzey ayrıntı bileşeni YD1 olarak adlandırılır ve 2 günlük ölçek bileşenini belirtir. Bu bize yüksek frekans varyasyonları verir. YD5 düşük frekanslı detay bileşenidir ve 32 günlük ölçeğe sahiptir. YSA ile akım tahmininde istenen başarılı sonuçları elde etmek için hangi YD bileşenlerinin seçileceğini belirlemek gerekmektedir. Bu amaçla, YD bileşenleri ile orijinal akış arasındaki korelasyonlar hesaplanmıştır. Tablo 4.3'te E07A0037 İstasyonu için elde edilen sonucu göstermektedir.

Bu korelasyon değerleri, akış değerleri üzerinde etkili olan alt bileşenlerin belirlenmesinde önemlidir. Etkili alt bileşenlerin seçiminde sınır değerler olarak farklı korelasyon değerleri kullanılmıştır. (Partal 2007) korelasyon değeri 0.2'den büyük alt bileşenler, (Tiwari ve Chatterjee 2011) 0.1'den büyük, (Partal ve Cıgızoğlu 2008) yaklaşık 0.3'ten büyük ve (Shiri ve Kişi 2010) 0.1'den büyük bir alt bileşen seçti. Bu katsayılar incelendiğinde, D3, D5 ve A5 bileşenlerinin seçilen aralıkların arasında iyi kaldığı görülmüştür. D1 ve D2 bileşenleri genellikle diğerlerine göre en düşük korelasyon değerlerine sahiptir. D3, D5 ve A5 bileşenleri, en yüksek korelasyon katsayılarına sahip olduğu için akım tahmininde DSA modelinin girdi parametreleri olarak seçilmiştir. Korelasyon tabloları kullanılarak 4 farklı istasyonda uygun bileşenler belirlenmiştir. Daha sonra ölçülen veriler, YSA yöntemlerinde girdi olarak bu belirlenen bileşenler kullanılarak tahmin edilmiştir. İBGYSA modelini eğitmek için 01.01.1996'dan 31.12.2007'ye kadar toplam 4383 veri noktası kullanılmış ve modeli test etmek için 01.01.2008'den 31.12.2011'e kadar son 4 yıllık toplam 1461 verisi kullanılmıştır.

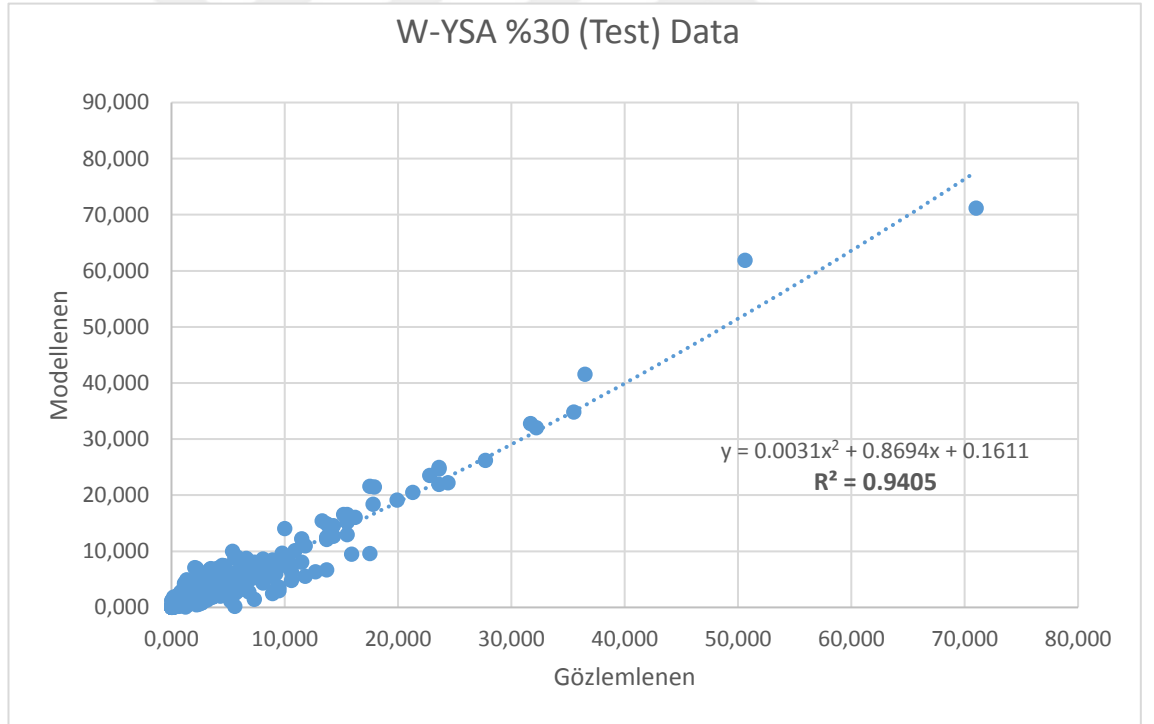
**Tablo 4.3.** Ölçülen akım veri korelasyon katsayılarına sahip (E07A0037) istasyonu için Yaklaşım ve Detay (YD) bileşenleri

YD Bileşenleri	$Q_{t-3}$	$Q_{t-2}$	$Q_{t-1}$	$P_t$	$T_{avg}$	$R_h$
D1	-0,018	-0,097	0,325	0,190	0,023	0,007
D2	-0,023	-0,019	0,326	0,176	0,022	-0,015
D3	<b>0,144</b>	<b>0,260</b>	<b>0,408</b>	<b>0,289</b>	<b>-0,033</b>	<b>-0,003</b>
D4	0,044	0,165	0,361	0,231	-0,059	0,013
D5	<b>0,253</b>	<b>0,271</b>	<b>0,301</b>	<b>0,197</b>	<b>-0,073</b>	<b>-0,022</b>
Y5	<b>0,597</b>	<b>0,610</b>	<b>0,634</b>	<b>0,516</b>	<b>-0,310</b>	<b>-0,270</b>

Akım tahmin modellerini geliştirmek için, akımın önceki dönemlerine ilişkili olan üç değişik giriş kombinasyonu ele alınmıştır. Mevcut giriş kombinasyonları aşağıdaki gibidir: 1-  $Q_{t-3}$ ,  $Q_{t-2}$ ,  $Q_{t-1}$  2-  $Q_{t-2}$ ,  $Q_{t-1}$  3-  $Q_{t-1}$ . YSA ve D-YSA modellerinin performansını değerlendirmek için ölçülen verilerle model sonuçları arasında Kök ortalama kare hatası (KOKH), ortalama mutlak hata (OMH), korelasyon katsayısı (R) ve belirlilik katsayısı ( $R^2$ ) değerleri kullanılmıştır. Burada, öğrenme algoritması olarak Levenberg-Marquardt yöntemi seçilmiştir. DSA modeli, YSA modelinden Haar dalgacık ile elde edilen bir girdi parametresi olarak alt serilerle geliştirilmiştir. Literatür incelendiğinde (Adamowski ve Chan 2011; Kişi ve Partal 2011; Tiwari ve Chatterjee 2011) çalışmasında ADD'den elde edilen alt serileri bir araya getirerek YSA yönteminde girdi olarak kullanılmıştır. Burada sadece Tablo 4.4'teki E07A0037 istasyonu için geliştirilen DSA modellerinin eğitim ve test setlerinin istatistiksel parametreleri verilmiştir.

**Tablo 4.4.** Akım alt serilerinin toplamını kullanan DSA (Haar) modelleri için değişkenler (İstasyon E07A0037)

Model	Model	Eğitim Seti				Test Seti			
		KOKH	OKH	R	R <sup>2</sup>	KOKH	OKH	R	R <sup>2</sup>
Girdileri	Yapısı								
Q <sub>t-1</sub> (D1+D2+D3+D4+A5)	(1,10,1)	2,57	6,63	0,94	0,89	1,09	1,18	0,97	0,93
Q <sub>t-2</sub> , Q <sub>t-1</sub> (D3+D5+A5)	(2,9,1)	2,54	6,45	0,84	0,71	1,14	1,30	0,96	0,93
Q <sub>t-3</sub> , Q <sub>t-2</sub> , Q <sub>t-1</sub> (D5+A5)	(3,10,1)	2,58	6,68	0,84	0,70	0,70	0,49	0,98	0,97
Q <sub>t-1</sub> , P <sub>t</sub> (D1+D2+D3+D4+A5)	(2,8,1)	2,40	5,74	0,86	0,75	1,06	1,13	0,97	0,94
Q <sub>t-1</sub> , P <sub>t</sub> , T <sub>avg</sub> , R <sub>h</sub> (D1+D2+D3+D4+A5)	(4,10,1)	2,29	5,27	0,87	0,76	1,04	1,08	0,97	<b>0,94</b>



**Şekil 4.8.** Gözlemlenen ve model çıktısı (Tahmin edilen) arasındaki korelasyon ilişkisi (İstasyon E07A0037)

### 4.3. Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi Çalışma Prensipleri

Temel olarak bir bulanık çıkarım sistemi beş fonksiyonel bloktan oluşur (Jang 1993).

1. Girdi üyelik işlevlerine girdi özellikleri
2. Kurallara üyelik girdi işlevi
3. Bir takım çıktı özellikleri kuralları
4. Çıktı üyelik fonksiyonlarına çıktı karakteristikleri, ve
5. Tek değerli bir çıktıya çıktı üyelik işlevi veya çıktıyla ilişkili bir karar

Burada, bulanık çıkarım sistemi (BÇS) oluşturmak için çeşitli üyelik fonksiyonu türleri değerlendirilmiş ve girdi verileri ve çıktı verileri (doğrusal) için en etkili üyelik fonksiyonu tipi (trimf) dört farklı istasyonun tümü için en iyi sonuçları göstermiştir. BÇS eğitimi için, geri yayılma (GY) yöntemi, uyarlanabilir bir ağı temel kuralı olan BÇS'de parametre tanıma sorunu ile başa çıkmak için kullanılır ve parametreleri tahmin etmeyi başarabilecek iyi bir kurala dayanır. USBÇS modelinin sonuçları ve model performans kriterlerinin özellikleri Tablo 4.5'te gösterilmiştir.


**Tablo 4.5.** Orijinal akım serisinin' de kullanılan USBÇS modeli için değişkenler (İstasyon E07A0037)

Model	Eğitim Seti				Test Seti			
	KOKH	OKH	R	R <sup>2</sup>	KOKH	OKH	R	R <sup>2</sup>
Q <sub>t-1</sub>	2,97	8,80	0,81	0,80	2,45	6,02	0,84	0,87
Q <sub>t-2</sub> , Q <sub>t-1</sub>	2,93	8,80	0,80	0,81	2,45	6,01	0,84	0,88
Q <sub>t-3</sub> , Q <sub>t-2</sub> , Q <sub>t-1</sub>	2,86	8,15	0,81	0,65	2,44	5,97	0,84	0,89
Q <sub>t-1</sub> , P <sub>t</sub>	2,93	8,59	0,80	0,80	2,33	5,44	0,84	0,86
Q <sub>t-1</sub> , P <sub>t</sub> , T <sub>avg</sub> , R <sub>h</sub>	2,92	8,54	0,80	0,80	2,45	6,02	0,83	0,69

**Tablo 4.6.** YSA, DSA ve USBÇS Modelleri için Geçerlilik Yöntemlerinin Özellikleri

Metodlar	Aralıklar	Yetirli	Yetirsiz	Model Sonuçları
KOKH	0 to $+\infty$	$x \leq 0,5$	$x \geq 0,5$	√
$R^2$	0 to +1	$x \geq 0,5$	$x \leq 0,5$	√
NS	$-\infty$ to +1	$x \geq 0,5$	$x \leq 0,5$	√
RSR	0 to $+\infty$	$x \leq 0,5$	$x \geq 0,5$	√

Mevcut veriler (5845) iki gruba ayrılır: eğitim seti (kalibrasyon), test seti (doğrulama). Eğitim ve test düzenleri için veriler sırasıyla 4382 ve 1463 girdi düzenlerine göre rastgele olarak seçilmiştir.




**Şekil 4.9.** USBÇS modelinin yapısı (Üç girdi-Qt-3, Qt-2, Qt-1 ve bir çıktı-Qt)




#### 4.4. Çalışma Alanı

Bu çalışmada, esas alınan Büyük Menderes Havzası Türkiye'nin güney batısında yani batı Anadolu'da, 37° 12' - 38° 40' kuzey enlemleri ile 27° 15' - 30° 15' doğu boylamları arasında yer almaktadır. Büyük Menderes Havzasının güneyinde Muğla, doğusunda Afyon ve Bordur, batısında Ege Denizi ve kuzeyinde ise İzmir, Manisa ve Uşak yer almaktadır. Türkiye'nin %3,2 yüzey alanını oluşturmakta olup, toplam yağış alanı 24 873 KM<sup>2</sup>'dir. Büyük Menderes Havzası Türkiye haritası üzerinde aşağıdaki şekilde gösterilmiştir.



Şekil 5.10. Türkiye'deki Büyük Menderes Havzası'nın Konumu



Şekil 5.11. Büyük Menderes Havzası'nın Haritası

Büyük Menderes nehri, Batı Anadolu'nun en büyük nehri ve Menderes Havzası'nın ana sulama kaynağıdır. Havzadaki suyun%79'u tarım sektöründe ve tarımsal sulamada kullanılmaktadır (Büyük Menderes Havza Atlası 2012). DSİ (1975) ve EİE (1993) kayıtlarına göre Büyük Menderes nehrinin uzunluğu 584 km ve 24300 km<sup>2</sup> alana sahiptir. Afyonkarahisar ilinin Dinar ilçesinde (38 ° 4 ' 15 " N, 30 ° 10 ' 37 " E) doğar ve diğer kolları ile beraber Büyük Menderes Nehrini oluşturmaktadır. Aşağıdaki Tablo 5.7'da BMH ile ilgili bazı temel bilgiler yer verilmiştir.


**Tablo 5.7.** Büyük Menderes Havzası ile ilgili Bazı temel bilgiler

Koordinatlar	37° 10' - 38° 49' Kuzey ve 27° 11' - 30° 53' Dogu
Alan	24873 km <sup>2</sup>
Ana nehir uzunluğu	584 km
Ülke yüzdesi	%3,2
Yıllık ort. Yağış	635 mm (350 ve 999 mm arasında)
Delta alanı	98 km <sup>2</sup> (16.7 km <sup>2</sup> si Milli Park)
Havzadaki top. Baraj sayısı	13
Havzadaki arazi kullanımı	%40 tarım %45 orman %10 çayır ve mera %3 boş %1 yerleşim %1 yüzey suyu
Havzadaki ana tarım sal ürünle	Pamuk, incir, zeytin
Kapladığı iller	Aydın, Denizli, Muğla, Usak ve Afyon

Büyük Menderes Havzası'nın Ege kıyılarında tipik Akdeniz iklimi hüküm sürerken, iç kısımda karasal iklim hakimdir. Havzanın batı kesiminde, aylık maksimum yağış 79 mm ile 132.3 mm arasında değişirken, doğu kesimde bu değer 14.0 mm ile 80.2 mm arasında değişmektedir. Toplam yıllık yağış ortalamasının havzanın doğu kesimine doğru 999,1 mm'den 350,4 mm'ye düştüğü ve yıllık ortalama yağış miktarının 635 mm olduğu görülmektedir. Yıllık ortalama buharlaşma 2122 mm'dir. Sonuç olarak, yıllara göre sıcaklıklarda artış ve havzada yağış miktarı azalmaktadır. Büyük Menderes havzasından dört farklı yerlerinden akım istasyonları seçilmiştir. Bu dört farklı akım istasyonların (E07A0040, E07A0032, E07A0033, ve E07A0037) yanında Muğla Meteorolojik İstasyona bağlı olan ortalama sıcaklık, bağıl nem, rüzgar ve yağış verileri çalışmanın girdileri olarak kullanılmıştır. Çalışmada, EİEİ'a ait olan dört akım istasyonların verileri ve MMİ'a ait olan meteorolojik veriler 1996-2011'a kadar günlük olan verilerdir.

**Tablo 5.8.** BMH'daki Seçilen İstasyonlar

<b>Büyük Menderes Havzası</b>			
<b>Kod</b>	<b>İstasyon'un adı</b>	<b>Yeri</b>	<b>Yağış Alanı</b>
E07A0040	Akçay-Amasya	(28° 28' 49" D - 37° 36' 27" K)	3138 KM2
E07A0032	Akçay-Değirmenalanı	(28° 43' 28" D - 37° 20' 08" K)	854,4 KM2
E07A0033	Sarhoş Çayı-Göktepe	(28° 33' 39" D - 37° 25' 50" K)	236 KM2
E07A0037	Mortuma Çayı-Yemişendere	(28° 36' 56" D - 37° 15' 43" K)	169,7 KM2



**Şekil 5.12.** Çalışma 'da yer alan akım istasyonları ve meteorolojik istasyonu

## 5. SONUÇLAR

Büyük Menderes Havzası Türkiye'nin en büyük ve hayati havzalarından biri olmuştur ve devam edecektir. Orta ve batı Anadolu'yu besleyen bu havza yıllardır araştırmacıların dikkatini çekip üzerinde ulusal ve uluslararası çalışmalar yürütülmüştür. Literatürde yapılan araştırmaları incelendiğinde farklı yöntemler, deneyler ve farklı amaçlar olmak üzere günümüze kadar devam edilmiştir. Konumuza ilgilenen çalışmaları taratıldığında birçok araştırmacı veya bilim adamlar çeşitli yöntemler, deneyler veya gözlemler ile hem havza için ve hem de bilime önemli adımlar ve büyük katkılar sağlamıştır. Bu çalışmada diğer çalışmalardan farklı olarak en etkili ve yaygın olan üç farklı yöntemi kullanıp modelleri geliştirilmiş olup geleceğe dair günlük akım tahmini yapılmıştır. Bu üç model (Yapay Sinir Ağları, Dalgacık Sinir Ağları ve Uyarlamalı Sinir Bulanık Mantık Çıkarım Sistemi) kendilerine ait yöntemler ile günlük akım tahmini için ayrı ayrı çalıştırılıp, hem modeller arasında performans güçleri ve hem de çalışmanın hassasiyetini fark yaratılmıştır.

Büyük Menderes Nehri'nde yer alan dört farklı akım istasyonları ve Muğla iline yakınlığından dolayı Muğla Meteorolojik İstasyondan sağlanan veriler (yağış, bağıl nem, ortalama sıcaklık, buharlaşma ve rüzgâr) ile modellerin girdileri olarak kullanılmıştır. Çalışmada kullanılan veriler günlük olup 1996-2011(15Yıl)'a aittir. Kullanılan verilerin %70'i modeli eğitmek için ve geri kalan %30'u ise modeli test etmek amacıyla dikkate alınmıştır. Modellerin girdileri tek ve kombinasyon şeklinde seçilip ve bir çıktıyı sahiptirler. İlerideki paragraflarda modelden çıkan tahminler sonucu ve gözlemlenmiş sonuçların arasındaki fark aralıkları ve modellerin performans hassasiyetleri tablolar ve şekiller üzerinde sayılarla gösterilmiştir. Modellerin hassasiyetleri ve performans güçleri ölçmek için aşağıdaki model verimlilik katsayıları sırasıyla Kök Ortalama Kare Hatası KOKH, Belirlelik Katsayısı  $R^2$ , KOKH'in gözlemleri standart sapma oranı RSR ve Nash-Sutcliffe NS Katsayısı verilmiştir.

Tablo 6.9'da gösterildiği gibi, YSA için en iyi sonuç, 3 girdi katmanı, 10 gizli katman ve 1 çıktı katmanı içeren KOKH = 4.466 ve  $R^2 = 0.932$ 'dir. YSA modelinde, gizli katmanın belirlenmesi ve en arzu edilen sonucu bulmak için bir deneme-yanılma testi uygulanmak düşünülen kritik bir konu olarak görülmüştür. Tablo 6.10'de gösterildiği gibi, DSA modeli KOKH = 0.700 ve  $R^2 = 0.971$  tahmin değerleri ile gözlemlenen değerlerle çok yakın olduğu ortaya koymuştur. Tablo 6.11'de gösterildiği gibi USBÇS model sonuçları

da bu çalışmada en iyi ikinci sonucu gösterdiğini  $KOKH = 5.068$  ve  $R2 = 0.947$  ile belirtmiştir.

Son olarak da bu çalışmanın temel amacı literatürde en çok bireysel olarak kullanılan üç modeli birlikte kullanmak ve tahmin sonuçlarını karşılaştırmaktır. Çalışmanın sonucunda, ortaya çıkan sayıları bakılarak dalgacık sinir ağı yöntemi ile çalıştırıldığı modelde en iyi tahmin sonuca vermiştir. Bu da orijinal verilerin alt kümelere ayrıştırılması ve görülülerini çıkartılması, gözlemlenen verileri doğru tahmin etmenin en etkili yolu olacağı anlamına gelir. Gözlemlenen ve tahmin edilen zaman serileri ve her bir modelin tahmin performans sonucu, Şekil 6.19'de gösterilmektedir.



**Tablo 6.9.** YSA ile Çıkan Model Akım Tahmin Sonuçları


İstasyonlar(m <sup>3</sup> /s)	Şebeke Mimarisi	KOKH (m <sup>3</sup> /sec)		R <sup>2</sup>		NS		RSR	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
E07A004	3-10-1	14,015	4,466	0,864	<b>0,932</b>	0,623	0,931	0,614	0,262
E07A0032	1-10-1	16,093	10,423	0,919	0,785	0,391	0,538	0,780	0,680
E07A0033	2-10-1	2,134	2,238	0,593	0,856	0,418	0,548	0,763	0,672
E07A0037	1-10-1	3,096	1,870	0,599	0,915	0,516	0,785	0,695	0,464

**Tablo 6.10.** DSA ile Çıkan Model Akım Tahmin Sonuçları

İstasyonlar (m <sup>3</sup> /s)	Şebeke Mimarisi	KOKH (m <sup>3</sup> /sec)		R <sup>2</sup>		NS		RSR	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
E07A004	2-10-1	7,642	6,072	0,918	0,884	0,888	0,873	0,335	0,356
E07A0032	1-10-1	14,655	9,359	0,566	0,949	0,555	0,852	0,667	0,385
E07A0033	4-10-1	1,587	1,047	0,688	0,854	0,682	0,852	0,564	0,385
E07A0037	1-10-1	0,585	0,700	0,705	<b>0,971</b>	0,665	0,927	0,579	0,270

**Tablo 6.11.** USBÇS ile Çıkan Model Akım Tahmin Sonuçları


İstasyonlar (m <sup>3</sup> /s)	Şebeke Mimarisi	KOKH (m <sup>3</sup> /sec)		R <sup>2</sup>		NS		RSR	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
E07A004	3-10-1	7,159	5,068	0,939	0,914	0,902	0,912	0,313	0,297
E07A0032	2-10-1	16,049	10,119	0,918	<b>0,947</b>	0,394	0,564	0,778	0,660
E07A0033	1-10-1	2,160	1,947	0,906	0,888	0,411	0,487	0,767	0,716
E07A0037	3-10-1	2,856	2,444	0,654	0,886	0,585	0,632	0,644	0,606



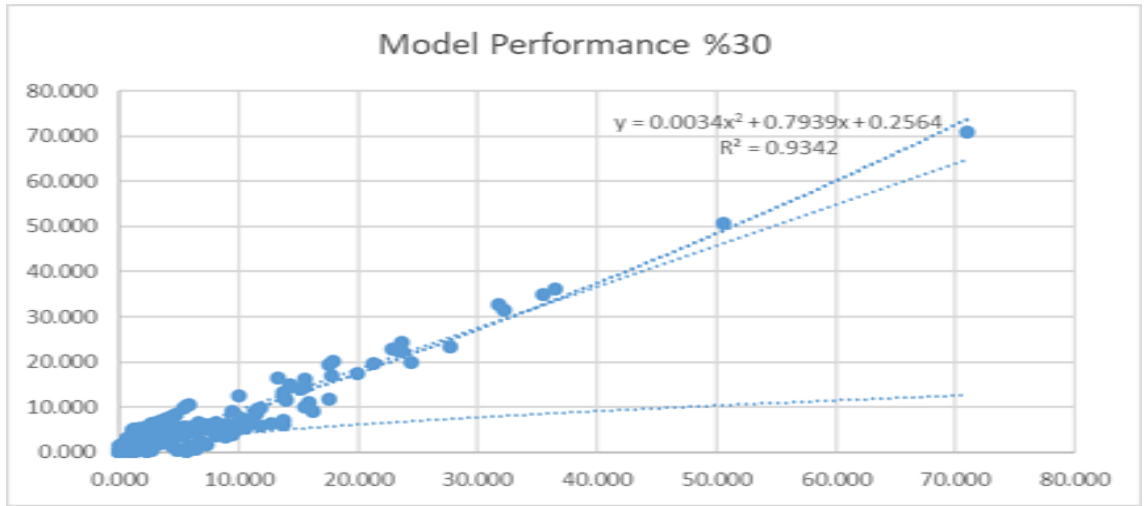
Şekil 6.13. YSA için Zaman Serisi (E07A004).



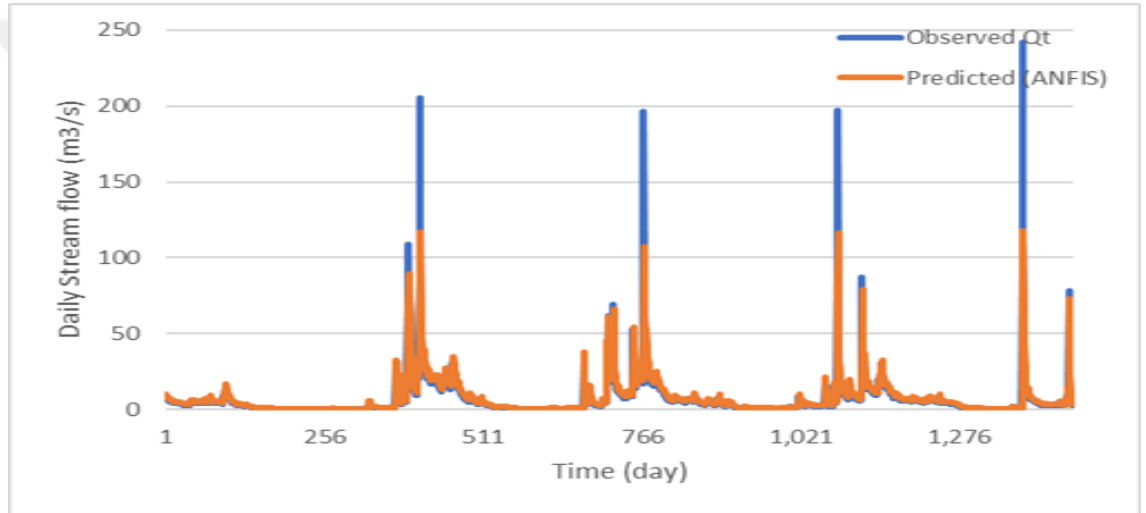
Şekil 6.14. YSA için Dağılım Diyagramı (E07A004)




Şekil 6.15. DSA için Zaman Serisi (E07A0037)



Şekil 6.16. DSA için Dağılım Diyagramı




Şekil 6.17. USBÇS için Zaman Serisi



Şekil 6.18. USBÇS için Dağılım Diyagramı





Şekil 6.19. Kullanılan Üç Modelin Zaman Serisi ve Sonuçları (E07A0032)

## KAYNAKLAR

- Acı, M. (2006) “Yapay Sinir Ağları ile Hidrolik Modelleme”, Celal Bayar Üniversitesi, *Fen Bilimleri Enstitüsü*, 1-69s, Manisa.
- Adamowski, J. and Chan, H.F. (2011) “A Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting”, *Journal of Hydrology*, 407, 28-40. <https://doi.org/10.1016/j.jhydrol.2011.06.013>.
- Alp, M., ve Cıgızoğlu, K. (2004) “Farklı Yapay Sinir Ağı Metotları ile Yağış- Akış İlişkisinin Modellenmesi”, *İTÜ Dergisi Mühendislik*, Cilt:3, Sayı:1.
- Altunkaynak, A. ve Nigussie, T. (2016), “Günlük akımların tahmini açısından çok tabakalı perseptron ve dalgacık-çok tabakalı perseptron modellerinin performans karşılaştırması”, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 7(2), 291-308. Retrieved from <https://dergipark.org.tr/en/pub/dumf/issue/29220/312768>.
- Altunkaynak, A. ve Başakın, E. E. (2017) “Zaman Serileri Kullanılarak Nehir Akım Tahmini ve Farklı Yöntemlerle Karşılaştırılması”, *Erzincan Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 2018, (11), 1. ISSN: 1307-9085, e-ISSN: 2149-4584.
- Anderson, D. and McNeill, G. (2006) “Artificial Neural Networks Technology”, (<https://www.thedacs.com/techs/neural/neural.title.php>).
- Anusree. K. ve Vargheseb, K.O. (2016) “Streamflow Prediction of KaruvYSAur River Basin Using USBÇS, YSA and MNLR Models”, *Procedia Technology*, 24 ( 2016 ) 101 – 108.
- Chang, F.J. and Chen, Y.C. (2001) “A counter propagation fuzzy-neural network modeling approach to real time streamflow prediction”, *Journal of Hydrology*, 245:153–164.
- Chiang, Y. M., Chang, L. C. and Chang, F. J. (2003) “Comparison of static-feed forward and dynamic-feedback neural Networks for rainfall–runoff modeling”, *Journal of Hydrologic*, 290.
- Coulibaly P. and Burn D. H. (2004) “Wavelet analysis of variability in YSAual Canadian Streamflow”, *Water Resources Research*, 47: 1-14.
- Coulibaly, P., Anctil, F., and Bobee, B. (2000) “Daily Reservoir Inflow Forecasting Using Artificial Neural Network with Stopped”, Training Approach. *Journal of Hydrology*, 230, (3-4), 244-257. [https://doi.org/10.1016/S0022-1694\(00\)00214-6](https://doi.org/10.1016/S0022-1694(00)00214-6).
- Daubechies, I. (1988) “Orthonormal Bases of Compactly Supported Wavelets”, *Communications on Pure and Applied Mathematics*, 41: 909–996.
- Dawson C. W., Harpham C., Wilby, R. L. and Chen Y. (2001) “Evaluation of Artificial Neural Network Techniques for Flow Forecasting in The River Yangtze”, China.

- Dibike, Y.B. and Solomatine, D.P. (2001) "River Flow Forecasting Using Artificial Neural Networks", *Physics Chemical Earth* (B), 26(1), 1-7.
- DSİ, (1975) "Aşağı Büyük Menderes Havzası Hidrojeoloji incelemesi" (An Hydrogeological Investigation of Büyük Menderes Basin), *Devlet Su İşleri Raporu, State Hydraulic Works Report*, 207s. Ankara.
- Dragan, A., SAVIC, Godfrey, A. W., JAMES, W. D. (1999). "A Genetic Programming Approach to Rainfall-Runoff Modelling Water Resources Management." 13: 219–231, 1999.
- EİE, (1993) "Türkiye Akarsularında Sediment Gözlemleri ve Sediment Taşınım Miktarları" (Sediment Transport Amount And Sediment Observations In Rivers Of Turkey), *Elektrik İşleri Etüt İdaresi Genel Müdürlüğü (General Directorate of Electrical Works Survey Administration)*, Yayın no: 93-59, Ankara.
- Fistikoglu, O., ve Okkan, U. (2011) "Statistical Downscaling of Monthly Precipitation Using NCEP/NCAR Reanalysis Data for Tahtali River Basin in Turkey", *Journal of Hydrologic Engineering*, 16, (2), 157-164. Retrieved from [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000300](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000300). DOI: 10.1061/(ASCE)HE.1943-5584.0000300.
- Grossman, A. and Morlet, J., (1984) "Decomposition of Hardy functions into square integrable wavelets of constant shape", *SIAM Journal on Mathematical Analysis*, 15, 723– 736. doi:10.1137/0515056.
- Gümüş V., Soydan N. G., Şimşek O., Aköz M. S., ve Kırkgöz M. S. (2013) "Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması", Cukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 28(1), ss.37-49.
- Gümüş, V., Kavrut, M. E., Yenigün, K. (2011). "Yağış-Akış İlişkisinin Modellenmesinde YSA Kullanımının Değerlendirilmesi: Orta Fırat Havzası Uygulaması." *New World Sciences Academy*, 6(1), 1A0160.
- Hou, Z., Lu, W., and Chen, S. (2013) "Research on Precipitation Prediction Based on DSA", *Water Saving Irrigation*, (03),31-34.
- Jang, J. (1993) "USBÇS: adaptive-network-based fuzzy inference system". *IEEE Transactions on Systems Man and Cybernetics*. 23, 665-685.
- Jang, J., Sun C., Mizutani E. (1997) "Neuro-Fuzzy and Soft Computing, A Computational Approach to Learning and Machine Intelligence". *Prentice Hall*, NJ, USA
- Justin H. and Oliver K. (2016) "Machine Learning Ensembles for Wind Power Prediction", *Renewable Energy*.
- Karahan, H., İlhan, M.H. ve Ayvaz, M.T. (2007) "Günlük eksik akımların yapay sinir ağları ve genetik algoritma kullanarak tamamlanması", *V.Ulusal Hidroloji Kongresi ODTÜ*, Ankara 5-7 Eylül.

- Khodadadi, H. and Razavi, A. (2012) “Comparison Between Neural Networks and Wavelet Networks in Nonlinear System Identification”, *Research Journal of Applied Sciences, Engineering and Technology*, 4, (9),1021-1026.
- Kim, S. (2000) “A study on the Forecasting of Daily Streamflow using the Multilayer Neural Networks Model”, *Journal of Korea Water Resources Association* (한국수자원학회논문집), Pages.537-550.
- Kisi, O. (2004) “Multi-Layer Perceptron with Levenberg-Marquardt Training Algorithm for Suspended Sediment Concentration Prediction and Estimation”, *Hydrological Science Journal*, 1025-1040.  
<https://doi.org/10.1623/hysj.49.6.1025.55720>.
- Kisi, O. (2009) “Neural network and wavelet conjunction model for intermittent streamflow forecasting”, *Journal of Hydrologic Engineering*, 14, (8), 773-782.  
DOI: [https://10.1061/\(ASCE\)HE.1943-5584.0000053](https://10.1061/(ASCE)HE.1943-5584.0000053).
- Kisi, O. and Partal, T. (2011) “Wavelet and Neuro-Fuzzy Conjunction Model for Streamflow”, *Forecasting. Hydrology Research*, 42,(6), 447-456.  
<https://doi.org/10.2166/nh.2011.048>.
- Kisi, Ö., Shiri, J., and Tombul, M. (2013). “Modeling Rainfall-Runoff Process Using Soft Computing Techniques.” *Computers & Geosciences*, 51, 108-117.
- Köse, M., Terzi, Ö., İlker, A. ve Ergin, G. (2011), “Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi ile Kızılırmak Nehri'nin Akım Tahmini”, *6th International Advanced Technologies Symposium (IATS'11)*, 16-18 May 2011, Elâzığ, Turkey.
- McAdams, W. H. (1942) “Heat Transmission 2<sup>nd</sup> ed.”, *Mc Graw Hill*, New York, 278-292.
- Mallat, S. G. (1989) “A Theory for Multiresolution Signal Decomposition: The wavelet Representation”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11, (7), 674-693.
- Nayak, P.C., Sudheer, K.P., Rangan, D.M., and Ramasastri, K.S. (2004) “A neuro-fuzzy computing technique for modeling hydrological time series”, *Journal of Hydrology*, 291, (1), 52-66. <https://doi.org/10.1016/j.jhydrol.2003.12.010>.
- Okkan, U. (2013) “Wavelet neural network model for reservoir inflow prediction”, *Scientia Iranica*, 19, (6), 1445-1455.  
<https://doi.org/10.1016/j.scient.2012.10.009>.
- Okkan, U. ve Mollamahmutoğlu, (2010) “Yiğitler Çayı Günlük Akımlarının YSA ve Regresyon Analizi ile Modellenmesi”, DPÜ, *Fen Bilimleri Enstitüsü*, Sayı 23.
- Özkaya, M., Seçkin, İ.U. ve Yıldız, M., (2006) “EİE’de Göl Gözlemleri”, *II ulusal Limnoloji Çalıştayı*, Sinop, 6-8 Eylül.

- Partal, T. (2007) “Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini”, Doktora tezi, *İTÜ Fen Bilimleri Enstitüsü*, İstanbul.
- Partal, T., Kahya, E. ve Cıgızoğlu, K. (2008) “Yağış Verilerinin Yapay Sinir Ağları ve Dalgacık Dönüşümü Yöntemleri ile Tahmini”, *İtü Dergisi/d mühendislik* Cilt:7, Sayı:3, 73-85.
- Partal, T. and Cıgızoğlu, H.K. (2008) “Estimation and Forecasting of Daily Suspended Sediment Data Using Wavelet-Neural Networks”, *Journal of Hydrology*, 358:317-331.
- Price M. (1985), “Introducing Groundwater”, *George Allen &Unwin*, London, The United Kingdom, 195 pp.
- Rajurkar P. R., Kothiyari, U. C. and Chaube (2002) “Artificial neural Networks for daily rainfall-runoff Modelling”, *Hydrological Sciences-Journal-des Sciences Hydrologiques*.
- Russell, S.O. and Campbell, P.F. (1996) “Reservoir operating rules with fuzzy programming”, *J. Water Resour. Plng. Mgmt*, 122(3):165–170
- Seo, Y., Kim, S. and Singh, V.P. (2013) “Flood forecasting and uncertainty assessment using bootstrapped USBÇS”, *Proceedings of 6th Conference of Asia Pacific Association of Hydrology and Water Resources*, Seoul, South Korea, 1-8.
- Seo, Y. and Kim, S. (2016) “River Stage Forecasting Using Wavelet Packet Decomposition and Data-driven Models”, *Procedia Engineering*, 154,1225 – 1230. <https://doi.org/10.1016/j.proeng.2016.07.439>.
- Shiri, J. and Kisi, O. (2010) “Short-Term and Long-Term Streamflow Forecasting Using a Wavelet and Neuro-Fuzzy Conjunction Model”, *Journal of Hydrology*, 394(3-4):486-493, DOI: 10.1016/j.jhydrol.2010.10.008.
- Takagi, T., and Sugeno, M. (1985) “Fuzzy Identification of Systems and Its Application to Modeling and Control”, *IEEE Transactions on Systems, Man and Cybernetics*, 15 ,(1), 116–132.
- Taylan, D. E. (2018) “Estimation of Dalaman Stream Flow by Using Wavelet-USBÇS”, *Journal of Engineering Sciences and Design* DOI: 10.21923/jesd.380158.
- Tayyap, M., Zhou, J., Dong, X., and Ahmad, I. (2017) “Rainfall-Runoff Modeling at Jinsha River Basin By Integrated Neural Network with Discrete Wavelet Transform”, *Springer-Verlag GmbH Austria 2017*, Meteorol Atmos Phys (2019) 131:115–125 <https://doi.org/10.1007/s00703-017-0546-5>.
- Terzi, Ö. ve Barak, M. (2014) “Dalgacık-Sinir Ağı Yaklaşımı ile Yağış-Akış Tahmini: Kızılırmak Nehri Örneği”, *Tarım Bilimleri Dergisi Tar. Bil. Der.* Dergi web sayfası: [www.agri.ankara.edu.tr/dergi](http://www.agri.ankara.edu.tr/dergi).
- Tiwari, M. K. and Chatterjee, C. (2011) “A New Wavelet Bootstrap- YSA Hybrid Model for Daily Discharge Forecasting”, *Journal of Hydro informatics* ,13,(3), 500-519.

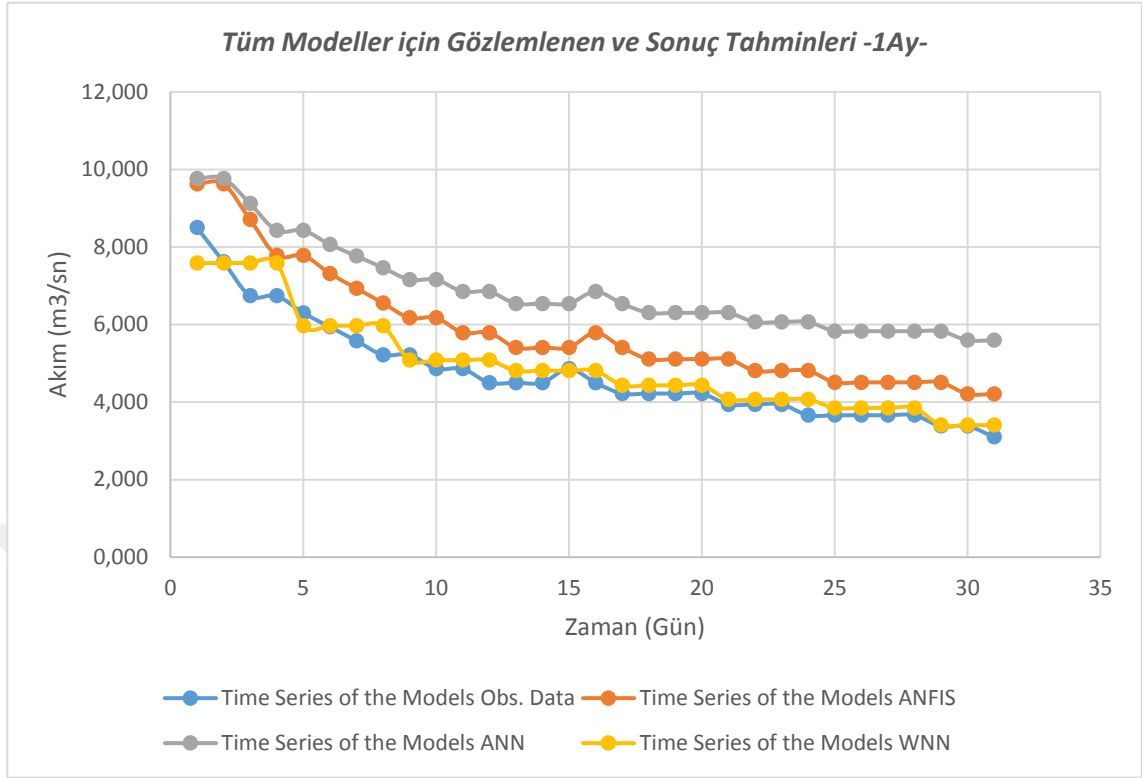
- Tsoukalas, L. H., and Uhrig, R. E. (1996) "Fuzzy and Neural Approaches in Engineering". *Wiley*, NY, 587.
- Tokar, A. S., Markus, M. (2000). "Precipitation-Runoff Modeling Using Artificial Neural Networks and Conceptual Models." *J. Hydrology. Eng.*, 5:156-161.
- Wu, C. L., Chau, K.W. and Li, Y.S. (2009) "Predicting monthly streamflow using data-driven models coupled with data-preprocessing techniques", *Water Resource Res.* 45,(8) ,W08432. <https://doi.org/10.1029/2007WR006737>.
- Wujy, S., Asce, P.E.M., YSAambhotla, S. and Bryant, S. (2005) "Artificial Neural Networks for Forecasting Watershed Runoff and Stream Flows", *Journal of Hydrologic Engineering*.
- Yu, P. S. and Chen, C. J. (2000) "Application of gray and fuzzy methods for rainfall forecasting", *J Hydrol Eng* 4(5):339–345.
- Yücel, A. (2010) "Tedarikçi Seçimi Probleminde Bütünleşik Sinirsel Bulanık Mantık Yaklaşımı", *İstanbul Üniversitesi Endüstri Mühendisliği Bölümü*, Doktora Tezi, İstanbul.
- Zadeh, L. A. (1965). "Fuzzy sets. Information and Control", 8, 338–353. doi:10.1016/S0019-9958(65)90241-X.

## EKLER

### Ek-1. Modellerdeki Zaman Serisi ve Gözlemlenen ve Tahmin Sonuçları (E07A0032)

Tüm Modellerin için Zaman Serileri				
NUMBER	Obs. Data	USBÇS	YSA	DSA
1	8.500	9.628	9.766	7.586
2	7.620	9.628	9.766	7.586
3	6.740	8.706	9.118	7.586
4	6.740	7.781	8.427	7.586
5	6.300	7.781	8.427	5.969
6	5.940	7.317	8.067	5.969
7	5.580	6.936	7.768	5.969
8	5.220	6.555	7.464	5.969
9	5.220	6.173	7.158	5.080
10	4.860	6.173	7.158	5.080
11	4.860	5.790	6.850	5.080
12	4.500	5.790	6.850	5.080
13	4.500	5.406	6.541	4.809
14	4.500	5.406	6.541	4.809
15	4.860	5.406	6.541	4.809
16	4.500	5.790	6.850	4.809
17	4.220	5.406	6.541	4.432
18	4.220	5.107	6.302	4.432
19	4.220	5.107	6.302	4.432
20	4.220	5.107	6.302	4.432
21	3.940	5.107	6.302	4.070
22	3.940	4.808	6.064	4.070
23	3.940	4.808	6.064	4.070
24	3.660	4.808	6.064	4.070
25	3.660	4.508	5.828	3.850
26	3.660	4.508	5.828	3.850
27	3.660	4.508	5.828	3.850
28	3.660	4.508	5.828	3.850
29	3.380	4.508	5.828	3.404
30	3.380	4.208	5.595	3.404
31	3.100	4.208	5.595	3.404

**Ek-1. (Devamı).** Tüm Modellerin Gözlemlenen ve Tahminleri arasındaki İlişkisi.<sup>1</sup>



<sup>1</sup> Görüldüğü üzere, DSA model sonucu (tahmini), YSA ve USBÇS model sonuçlarından, gözlemlenen veri setine daha yakın ilişkiyi sahip olduğu görülmektedir.



## **Ek-2. Tez Çalışması Süresince Yapılan Akademik Çalışma**

Dalkılıç H. Y., Hashimi S. A. (2020) “Prediction of Daily Streamflow using ANN, WNN and ANFIS models”, *Watery Supply, IWA*, 20 (4): 1396–1408.  
<https://doi.org/10.2166/ws.2020.062>



## ÖZGEÇMİŞ

Said Ali HASHİMİ, 1994 yılında Bamyan ilinde, Afganistan’da doğdu. İlk, orta ve lise öğrenimini Afganistan’da tamamladı. Afganistan Devlet Burslusu olarak 2013 yılında Türkiye’ye gönderilip, Türkçe Dil Hazırlığını TÖMER, Trabzon’da başladı.

Erzincan Binali Yıldırım Üniversitesinde 2014-2018 İnşaat Mühendisliği Bölümü lisans derecesinden mezun oldu. Yüksek lisans eğitimini yine EBYÜ, Fen Bilimler Enstitüsü, İnşaat Mühendisliği Bölümünde 2018-2020 arası tamamladı. Yüksek lisans eğitimi sürecince danışmanı ile birlikte bir akademik makalesi uluslararası dergide (<https://doi.org/10.2166/ws.2020.062>) yayınlanmıştır.

Mail: [sayedalihashemi2@gmail.com](mailto:sayedalihashemi2@gmail.com)

Tel: +90 539 249 3735