

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

FFNN, ANFIS ve LSTM MODELLERİ KULLANARAK FIRAT
HAVZASI'NIN AYLIK AKIM TAHMİNİ

Nazim NAZİMİ

Danışman: Doç. Dr. Neşe ERTUGAY

İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI

ERZİNCAN
2021

Her Hakkı Saklıdır.

Bilimsel Etięe Uygunluk Sayfası

FFNN, ANFIS ve LSTM Modelleri Kullanarak Fırat Havzasının Aylık Akım Tahmini” isimli “Yüksek Lisans” tezim tarafımca 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 gerektirdiğı gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 21/01/2021



Nazim NAZİMİ

ÖZET

Yüksek Lisans Tezi

FFNN, ANFIS ve LSTM MODELLERİ KULLANARAK FIRAT HAVZASI'NIN AYLIK AKIM TAHMİNİ

Nazim NAZİMİ

Erzincan Binali Yıldırım Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Neşe ERTUGAY

Su kaynaklarının etkin bir şekilde kullanılabilmesi için kontrol ve yönetiminin doğru bir şekilde yapılması gerekir. Su kaynaklarının planlanması ve yönetimi içerisinde yer alan su yapıları ve çevresinin şehirleşme, nüfus artışı ve suya olan talebin de hızlı bir şekilde arttığını düşünürsek suyun akış tahminlerinin ayrıntılı olarak araştırılıp doğru verilerin elde edilmesi gerekir. Kısaca, suyu kontrol etmek için mevcut ve gelecekteki potansiyelinin bilinmesi gerekmektedir. Bu çalışmada, akarsu akımlarının tahminine yardımcı olabilecek modeller üzerine hesaplamalar yapılmıştır. Genel olarak su akışı tahmini için geleneksel ve Yapay Zekâ (AI) olmak üzere iki tür model kullanılır. Geleneksel yöntemlerin aksine AI modelleriyle doğrusal ve sabit olmayan su akım tahminlerinde bulunmak daha etkili sonuçlar vermektedir. Çalışmamızda Fırat Havzası'nın aylık su akımı tahmini için İleriye Beslemeli Yapay Sinir Ağları (FFNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Uzun Kısa Vadeli Hafıza Ağları (LSTM) olmak üzere üç farklı yapay sinir modeli kullanılmıştır. Hesaplamalarda Fırat Havzası'nın dört istasyonundaki 1981-2011 yılları arasındaki veriler kullanılmıştır. FFNN ve ANFIS modellerini çalıştırabilmek için Matlab programı, LSTM modeli için ise Payton programı uygulanmıştır. Sonuçlar karşılaştırıldığında ANFIS'in diğer modellere göre, LSTM modeli ise FFNN modeline göre daha iyi sonuçlar verdiği görülmüştür. Bu modellerin performans kriterlerini belirlemek için en çok tavsiye edilen model değerlendirme indislerinin üç tanesi kullanılmıştır. Bu değerlendirme indisleri; Ortalama Mutlak Hata (MAE), Korelasyon Katsayısı (R) ve Nash Sutcliffe Verimlilik (NSE)'dir.

2021, 68 Sayfa

Anahtar Kelimeler: Akım Tahmini, ANFIS, FFNN, LSTM

ABSTRACT

MSc Thesis

MONTHLY STREAMFLOW PREDICTION OF EUPHRATES BASIN BY USING FFNN, ANFIS AND LSTM MODELS

Nazim NAZİMİ

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

Supervisor: Assoc. Prof. Neşe ERTUGAY

In order to use water resources effectively, it must be controlled and managed accurately. If we think of the rapidly increasing urbanization, water structures and their surroundings, population growth and the demand for water, streamflow estimation must be investigated in detail and accurate data should be obtained. In short, to control the water, it is necessary to know the current and future potential of it. In this study, calculations had been done using past months streamflow as input. Generally, two types of models are used for streamflow prediction, conventional and artificial intelligence (AI). Unlike traditional methods, prediction of nonlinear and nonstationary streamflow with AI models can give more accurate results. In this study, for the monthly streamflow estimation of the Euphrates Basin three different AI models; Feed Forward Neural Networks (FFNN), Adaptive neuro fuzzy inference system (ANFIS) and Long Short Term Memory Networks (LSTM) had been used. For this purpose, data between 1981-2011 at four stations in the Euphrates Basin were used. To run FFNN and ANFIS models, Matlab program was used and to run LSTM model, Python program was used. In the end, the results were compared and it was found out that ANFIS was superior compared to LSTM and FFNN, Secondly, LSTM showed better performances than FFNN. To compare the performances of the models, Three of the most recommended model performance criteria; Mean Absolute Error (MAE), Correlation Coefficient (R) and Nash Sutcliffe Efficiency (NSE) were used.

2021, 68 Pages

Keywords: ANFIS, FFNN, LSTM, Streamflow Prediction

TEŐEKKÜR

Yüksek Lisans tez çalışmam boyunca bana yardımcı olan, pozitif sözler söyleyerek motivasyonumu artıran danışman hocam sayın Doç. Dr. Neőe ERTUGAY'a sonsuz teşekkürlerimi sunarım.

Çalışma hayatım boyunca yanımda olup beni teşvik eden değerli arkadaşlarım Rahimgül RAHİMİ, Abdüllatif ZAMANİ ve Nacem BARYAL'a da teşekkür ederim.

Son olarak da beni dualarında unutmayan akrabalarım ve maddi ve manevi destekte bulunan değerli babam ve kardeşlerime şükranlarımı sunarım.

Nazim NAZİMİ

01/2021

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
SİMGELER	viii
KISALTMALAR	ix
1. GİRİŞ	1
2. KURAMSAL TEMELLER	3
2.1. Su Kaynakları ve Döngüsü.....	3
2.2. Su Kaynakları Yönetimine Genel Bakış	5
2.3. Entegre Havza Yönetimi	6
2.4. Su Kaynaklarının Azalmasının Başlıca Nedenleri	8
2.4.1. Nüfus artışı	9
2.4.2. Su kirliliği	9
2.4.3. Enerji.....	9
2.4.4. Küresel ısınma.....	9
2.4.5. Kuraklık.....	9
2.5. Akım.....	12
2.6. Su Akımını Etkileyen Faktörleri	12
2.7. Akarsudan Elde Edilen Faydalar.....	13
2.8. Akım Tahmininin Önemi	13
2.9. Akım Tahmini İçin Kullanılan Yöntemler.....	13
2.9.1. Geleneksel yöntemleri	14
2.9.2. Ypay zekâ yöntemleri (AI)	14
2.9.2.1. Yapay sinir ağları,	14
2.9.2.2. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS),	20
2.9.2.3. Uzun kısa vadeli hafıza ağları (LSTM),.....	21

2.10. Yapay Zeka (Aİ) Yöntemleri ile Yapılan Bazı Çalışmalar.....	23
3. MATERYAL ve YÖNTEM.....	27
3.1. Materyal	27
3.2. Yöntem	31
3.2.1. İleriye beslemeli sinir ağları (FFNN)	31
3.2.2. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS)	35
3.2.3. Uzun kısa vadeli hafıza ağları (LSTM).....	38
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	42
4.1. İleriye Beslemeli Sinir Ağı (FFNN) Tasarımı	42
4.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) Tasarımı.....	44
4.3. Uzun Kısa Vadeli Hafıza Ağları (LSTM) Tasarımı	47
5. SONUÇLAR.....	52
KAYNAKLAR	55
EKLER.....	61
Ek-1. Tüm modeller ile eie_2102 istasyon için elde edilmiş sonuçlar.....	61
Ek-2. Tüm modeller ile eie_2122 istasyon için elde edilmiş sonuçlar.....	62
Ek-3. Tüm modeller ile eie_2124 istasyon için elde edilmiş sonuçlar.....	63
Ek-4. Tüm modeller ile eie_2131 istasyon için elde edilmiş sonuçlar.....	64
Ek-5. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2122).....	65
Ek-6. Gözlenen ve FFNN ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim).....	65
Ek-7. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2122).....	66
Ek-8. Gözlenen ve ANFIS ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim)	66
Ek-9. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2124).....	67
Ek-10. Gözlenen ve LSTM ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim)	67
Ek-11. Tez Çalışması Süresince Yapılan Akademik Çalışma	68
ÖZGEÇMİŞ	69

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Dünyadaki Suyun Dağılımı	3
Şekil 2.2. Türkiye’de Bulunan 25 Nehir Havzası	8
Şekil 2.3. Telrarlayan Sinir Ağı Modeli.....	22
Şekil 3.1. Türkiyedeki Büyük Akarsu Havzaları	27
Şekil 3.2. Aşığa Fırat Havzası 2124, 2131 İstasyonları	28
Şekil 3.3. Orta Fırat Havzası 2102, 2122 İstasyonları	28
Şekil 3.4. Orta fırat havzası eie_2102 nolu istasyonun eğilim çizgisi	29
Şekil 3.5. Orta fırat havzası eie_2122 nolu istasyonun eğilim çizgisi	30
Şekil 3.6. Aşağı Fırat Havzası eie_2124 nolu istasyonun eğilim çizgisi	30
Şekil 3.7. Aşağı Fırat Havzası eie_2131 nolu istasyonun eğilim çizgisi	30
Şekil 3.8. Biyolojik Sinir Ağı Yapısı	31
Şekil 3.9. Yapay Sinir Ağı	32
Şekil 3.10. Temel yapay hücresi	32
Şekil 3.11. Çok Katmanlı Yapay Sinir Ağları.....	33
Şekil 3.12. Tüm katmanları gösterilen ANFIS yapısı.....	35
Şekil 3.13. Bir Uzun-Kısa Vadeli beledi Hücresi	39
Şekil 4.1. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2122)	43
Şekil 4.2. Gözlenen ve FFNN ile Tahmin Edilmiş Veri Arasındaki İlişki	44
Şekil 4.3. Tahmin Edilmiş ve Gözlenen Verinin Dağılım Diyagramı (İstasyon eie_2122)	46
Şekil 4.4. Gözlenen ve ANFIS ile Tahmin Edilmiş Veri Arasındaki İlişki.....	46
Şekil 4.5. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2124)	49
Şekil 4.6. Gözlenen ve LSTM ile Tahmin Edilmiş Veri Arasındaki İlişki	49
Şekil 5.1. Tahmin Edilmiş ve Gözlenen Veri Arasında İlişki (Test)	53
Şekil 5.2. Tahmin Edilmiş ve Gözlenen Veri Arasında İlişki (Test)	53
Şekil 5.3. Tahmin Edilmiş ve Gözlenen Veri Arasında İlişki (Test)	54
Şekil 5.4. Tahmin Edilmiş ve Gözlenen Veri Arasında İlişki (Test)	54

TABLULAR LİSTESİ

Sayfa

Tablo 2.1. Su Kaynaklarının Yeryüzündeki Dağılımı (BM verilerine göre)	4
Tablo 3.1. eie_2102 ve eie_2122 istasyonlara ait yağış alan ve kotlar	29
Tablo 3.2. eie_2124 ve eie_2131 istasyonlara ait yağış alanı ve kotlar	29
Tablo 3.3. Çalışmada kullanılmış olan modeller için seçilen; duğrusal, sigmoid, relu softmax ve tanh aktivasyon fonksiyonların denklem ve aralıkları.....	34
Tablo 3.4. ANFIS İçin iki geçişli hibrit öğrenme algoritması	38
Tablo 4.1. Kullanılan 4 istasyon için FFNN yöntem ile elde edilen en yüksek istatistiksel kriterlerin değerleri.....	42
Tablo 4.2. FFNN ile Elde Edilen Akım Tahmin Sonuçları /İstasyon eie_2122)	43
Tablo 4.3. Kullanılan 4 istasyon için ANFIS yöntemi kullanarak elde edilen en yüksek olan istatistiksel kriterlerin değerleri	44
Tablo 4.4. ANFIS ile Elde Edilen Akım Tahmin Sonuçları (İstasyon eie_2122).....	45
Tablo 4.5. ANN ve ANFIS yöntemleri için kullanılan kombinasyonlar	46
Tablo 4.6. LSTM yöntem kullanarak 4 istasyon için elde edilen en yüksek istatistiksel kriterlerin değerleri.....	47
Tablo 4.7. LSTM ile Elde Edilen eie_2124 İstasyonun Akım Tahmin Sonuçları	48
Tablo 4.8. LSTM yöntem için kullnılan kombinasyonlar.....	50
Tablo 4.9. eie_2131 İstasyon İçin FFNN ve LSTM Akım Tahmin Sonuçları.....	51

SİMGELER

Simgeler

$\mu A_i/\mu B_i$	Üyelik Fonksiyonları
$a^{<t>}$	Karar Verilen Bilgiler
b	Bias
c, σ	Öğrenme Sürecinden Eğitilmiş, Bilinen Parametreleri
$c^{<t>}$	Var Olan Hücre Durumu
$\tilde{c}^{<t>}$	Önceki Hücre Durumun
F	Aktivasyon Fonksiyonudur
$f^{<t>}$	t Anındaki Unutma Kapı
$i^{<t>}$	t Anındaki Güncelleme Kapı
n	Toplam Veri Noktaları Sayısı
$o^{<t>}$	t Anındaki Çıkış Kapı
P_i, q_i, r_i	Bulanık Kuralları Sonuç Bölümün Parametreleri
W	Ağırlıklar
\bar{X}	Ortalama
X	Girdiler
X_i	Gerçek Verilerin Toplamı
\bar{Y}	Gerçek Verilerin Ortalaması
Y_i	Tahmin Edilmiş Verilerin Toplamı

Kısaltmalar

ANN	Yapay Sinir Ađı (Artificial Neural Network)
AR	Otoregresif
ANFIS	Uyarlamalı ađ tabanlı bulanık ıkarım sistemi (Adaptive Neuro Fuzzy Inference System)
ARMA	Otoregresif Hareketli Ortalama
ARIMA	Otoregresif Entegre Hareketli Ortalama
ARMAX	Otoregresif Eksojen ile Hareketli Ortalama Giriřler
AGİ	Akım gözlem istasyonu
ABD	Amerika Birleřik Devletleri
BA	Yarasa Algoritması (Bat Algorith)
BBO	Biyografi Tabanlı Optimizasyon (Biography Based Optimization)
DSİ	Devlet Su İřleri Genel Müdürlüğü
DPT	Devlet Planlama Teřkilatı
EMD	Ampirik Mod Ayrıştırması (Empirical Mode Decomposition)
En-De-LSTM	Kodlayıcı-Kod Çözücü Uzun Kısa Vadeli Hafıza Ađları
FFNN	İleri Besleme Sinir Ađı (Feed Forward Neural Network)
FİS	Bulanık ıkarım Sistemi (Fuzzy Inference System)
FL	Bulanık Mantık (Fuzzy Logic)
GD	Dereceli Alçalma (Graduated Descent)
GRNN	Genel regresyon sinir ađı (General regression neural network)
GPR	Gauss Süreci Regresyon (Gauss Process Regression)
HKAP	Havza Koruma Eylem Planları
KGE	Kling–Gupta verimliliđi (Kling – Gupta efficiency)
LSE	En Küçük Kareler Tahmincisi (Least Squares Estimator)
MLP	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MF	Üyelik Fonksiyonu (Membership Function)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
NSE	Nash Sutcliffe Verimlilik (Nash Sutcliffe Efficiency)

NARX	Doğrusal Olmayan Oto regresif Dışsal (Nonlinear Autoregressive External)
NHYP	Nehir Havzası Yönetim Planları
R	Korelasyon Katsayısı (Correlation Coefficient)
R ²	Belirtme Katsayısı (Coefficient of Determination)
RMSE	Kök Ortalama Kare Hatası (Root Mean Square Error)
SVR	Destek Vektör Regresyonu (Support Vector Regression)
SAC-SMA	Sacramento Toprak Nemi (Sacramento Soil Moisture)



1. GİRİŞ

Su yeryüzünde yaşayan tüm canlıların hayatlarını sürdürebilmesi için en önemli maddelerin başında yer alır. Yeryüzündeki su miktarı sabit olup suya olan ihtiyaç nüfus artıkça arttığı için su kaynaklarının olabildiği kadar doğru bir şekilde planlanarak yönetilmesi son zamanlarda hidrolojinin en önemli konulardan biri olmuştur. Dolayısıyla su yapılarının doğru ve kesin bir şekilde tasarlanarak amacına uygun şekilde kullanılabilmesi için kullanılacak olan veriler sağlıklı, doğru ve uzun akım verileri olmalıdır. Suyun planlanıp ve yönetilmesi son zamanlarda geniş bir şekilde araştırılması büyük önem arz etmektedir.

Şiddetli ve uzun süreli yağmur yağdığına toprak suyu doymun hale gelir ve su hareket etmeye başlar. Herekete geçen su fazla ise sele sebep olabilir. Aynı şekilde, hızlı bir şekilde kar erimesi akan su miktarında artış meydana getirir. Bunun tersine, yağışın az olduğu durumlar kuraklığa neden olur. Sel, kuraklık veya su miktarında artış meydana geldiğinde birçok ekonomik, sosyal ve çevresel sorunların yanında insan ve diğer canlıların hayatlarını tehlikeye atar.

Her yıl dünyanın birçok ülkesinde meydana gelen taşkın ve kuraklık gibi doğal afetler, ekonomik zararların yanında, canlıların hayatını tehlikeye attığı birçok olay yaşanmıştır. 2005 ile 2008 yılları arasında Tayland'da meydana gelen kuraklık özellikle tarıma verdiği zararlar 11 milyon insanı doğrudan etkilemiştir. Tersine 2011'de aynı ülkede meydana gelen sel neticesinde 65 ilde 20.000 km² tarım toprağı yanında başka yapıları tahrib ederek 13,6 milyon insanı etkilemiş ve 45,6 milyar dolar maddi zarar olmuştur (Garbero vd, 2013).

Bu olayların tam olarak yok edilmesi imkânsızdır ama alınacak önlemlerle etkisini en aza indirmek mümkündür. Yani afeti felakete çevirmemek mümkündür. Su kaynaklarının planlanması ve yönetimi, su talebinin hızlı bir şekilde artış göstermesi neticesinde çok önemli bir duruma gelerek su yapılarının geliştirilmesinde daha detaylı araştırmaların yapılmasını zorunlu kılmıştır. Alınacak önlemler arasında en çok uygulanan yöntem su yapılarının inşaa edilmesidir. Bu yapıların birçoğu aynı zamanda su temini, su dağıtımı, tarım, sanayi, balıkçılık, hayvancılık, vb gibi birçok amaç için de kullanılmaktadır. Su yapılarının doğru bir şekilde projelendirilebilmesi için akış tahmini olabildiği kadar doğru yapılması gerekmektedir. Bu tahminler için de farklı modeller kullanılmaktadır. Doğada

suyu etkileyen faktörler belirsiz olup bunları etkileyecek olan parametreler arasında doğrusal olmayan bir ilişki olmasından dolayı modelleme ve kontrolü sırasında bazı zorluklar yaşanmaktadır.

Akım modellemesi için geçmiş yıllarda geleneksel yöntemler kullanılmıştır. Geleneksel yöntemler doğrusal ve durgun olmayan veriyi Yapay Zeka (AI) yöntemler gibi doğru bir şekilde modelleyemez. Dolayısıyla son zamanlarda geleneksel yöntemlerin yerine AI yöntemleri kullanılmaya başlanmıştır. AI yöntemleri, geleneksel yöntemlere göre doğruluk oranı yüksek olduğu için oldukça yaygın bir şekilde kullanılmaktadır.

Bu çalışma, su yapılarının geliştirilmesinde önemli bir faktör olan akarsu akımlarının tahminine yardımcı olabilecek önceki-akış ilişkisinin modellenmesi konusu ele alınmaya çalışılmıştır. Farklı AI yöntemleri kullanılarak içerisinde verimli tarım arazilerini barındıran Fırat Havzası'nın aylık akım tahminleri yapılarak elde edilen sonuçlar birbirleri ile karşılaştırılıp performansları değerlendirilmiştir. Bunun için üç tür AI modeli kullanılmıştır. Bunlar; İlereye Beslenmeli Yapay Sinir Ağları (FFNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Uzun Kısa Vadeli Hafıza Ağları (LSTM)'dir. Modellerin tahmin performansları istatistiksel kriterlere göre değerlendirilmiştir.


Sözü geçen modellerin performans kriterlerini ve gerçek değerlere yakınlığını ölçmek için en çok tavsiye edilen model değerlendirme indisleri çalışmada yer verilmiştir. Bu değerlendirme indisleri; Ortalama Mutlak Hata (MAE), Korelasyon Katsayısı (R) ve Nash Sutcliffe Verimlilik (NSE) 'dır.

2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

2.1. Su Kaynakları ve Döngüsü

Su, tüm canlıların hayatlarını devam ettirebilmeleri için vazgeçilmez bir kaynaktır ve suyun dünyadaki mevcudiyeti dünyayı diğer gezegenlerden ayıran en önemli özelliktir. Su, dünyada değişmeyen miktar ve belirli bir döngü içinde kendini yeniler ve tükenmeden var olmayı devam ettirir. Ancak, sürekli bir çevrim içinde olmasına rağmen nüfus artışı, çevre kirliliği, maliyet, bilinçsiz su tüketimi, iklim şartlarındaki değişim gibi sebeplerden ötürü çevrimini tamamlamadan tüketilir (Ekinci, 2015).

Dünyada var olan su hacmi yaklaşık olarak 1,4 milyar km³'tür. Bunun %97,5'i okyanus ve denizlerde tuzlu su olarak; %2,5'i ise tatlı su olarak bulunmaktadır. %2,5 'luk kısmın %69,5'u buzullarda, %30,1'ü yeraltı suyu, %0,4'ü yüzeysel su ve nem olarak bulunmaktadır. Şekil 2.1'de görüldüğü gibi yüzeysel suyunun %67,4'ü göller, %1,6'si nehirlerde ve %31'i bataklık ve diğer yerlerde bulunur. Bu miktar içerisinde dünyadaki tatlı suyun %70'i tarım, %22'si sanayi ve %8'i içme ve kullanma suyu olarak kullanılmaktadır. Bu durum yeryüzünde bulunan suyun acı gerçeğini göstermesi yanında kullanılabilir suyun zaman içinde kirlenmesi ve gerekli önlemler alınmaksızın entegre bir şekilde yönetilmemesi geleceğimiz açısından oldukça düşündürücüdür (Kara vd, 2013).



Şekil 2.1. Dünyadaki suyun dağılımı (Ekinci, 2015, s. 3)

Dünya genelindeki dağılımı adil olmayan bu miktar su kirliliği, iklim değişikliği ve su havzalarındaki yapılaşmalarla daha da düşmektedir. Buna karşın, hızlı nüfus artışına ve tüketim alışkanlıklarının değişimine bağlı olarak talebin sürekli artması, dünyamızı giderek büyüyen su sorunlarıyla karşı karşıya bırakmaktadır. Bu da "su yönetimi ve güvenliği" konularının ne kadar önem arz ettiğini göstermektedir (T.C. Kalkınma Bakanlığı, 2014)

Tablo 2.1'de görüldüğü üzere tatlı su miktarı kıtalar arasında su potansiyeli ve yaşayan nüfus oranına göre çok farklı ve dengesiz bir dağılım göstermektedir.

Tablo 2.1. Su kaynaklarının yeryüzündeki dağılımı (BM verilerine göre)

Kıtalar	Nüfus (%)	Su Kaynağı (%)
Kuzey Amerika	8	15
Güney Amerika	6	26
Avrupa	13	8
Afrika	13	11
Asya	60	36
Avustralya ve Adalar	1	5

Su varlığına göre ülkeler sınıflandırıldığında; yılda kişi başına düşen ortalama kullanılabilir su miktarı 1000 m³'ten az olan ülkeler "su fakiri", 1000-2000 m³ olan ülkeler "su sıkıntısı çeken ülke", 2000-8000 m³ olan ülkeler suyun yeterli olduğu ülkeler, 8000 m³'ten fazla olan ülkeler ise "su zengini" olarak kabul edilmektedir (DSİ, 2014).

Ülkemizde kişi başına düşen kullanılabilir su miktarı 1500 m³ civarında olup, ülkemiz su kısıtı bulunan ülkeler arasında yer almaktadır. 2030 yılında nüfusun yaklaşık olarak 100 milyona ulaşacak olan Türkiye, kişi başına düşen 1100 m³ kullanılabilir su miktarıyla, su sıkıntısı çeken bir ülke durumuna gelecektir.

Su sıkıntısına karşı geliştirilebilecek çözümlerin temelinde kısıtı oluşturan bileşenlerin iyi irdelenerek etkisinin azaltılmasına yönelik önlemlerin alınması gelir. Bu bağlamda Su Yönetimi; suyun etkin kullanımı, korunması ve kontrolü hususunda önemli bir üst kavram olarak ortaya çıkar. Bu doğrultuda, su kaynaklarının her tür kullanım amacıyla

korunması ve iyileştirilmesi maksadıyla uzun vadeli koruma program ve tedbirlerini içeren havza koruma eylem planlarının hazırlanması gerekir (T.C. Kalkınma Bakanlığı, 2014).

2.2. Su Kaynakları Yönetimine Genel Bakış

Bugünlerde su kaynakları yönetiminde en büyük sorun, sınırlı su kaynakları ile çoğulan su talebini karşılamaktır. Suya olan talebin giderek artması, mevcut kaynakların günden güne azalması, su kaynaklarından verimli bir şekilde yararlanmak için suyun etkin yönetimini zorunlu kılmıştır. 1992’de ifade edilen Dublin ilkelerine göre sürdürülebilir bir şekilde suyu kontrol etmek için su kalitesi, su arzı ve talebi birlikte değerlendirilmelidir.

Genellikle su kaynaklarının kullanımında bütün ülkeler tarafından kabul edilmiş öncelik, yaşamın sürdürülebilmesi için zorunlu gereksinimlerin karşılanması, daha sonra başka gereksinimler için su tahsis edilmesidir. Sekizinci beş yıllık kalkınma planında bu önceliklendirme; içme ve kullanma, doğal hayatın devam etmesi için su ihtiyacı, tarım sürdürebilmek için su ihtiyacı, sanayi ve enerji için su ihtiyacı, turizm, ticaret, balıkçılık vb. su ihtiyacı şeklinde belirtilmiştir (DPT, 2001). Suya olan istek belirlenen önceliklere uygun bir şekilde karşılanabilmesi, su kaynaklarının etkin şekilde yönetilebilmesiyle mümkün olabilmektedir.

Su kaynakları yönetimi; ekonomik, sosyal ve çevresel gereksinimleri karşılayarak suyun insanlara ucuz fiyatta, olabildiği kadar yüksek kalitede, ihtiyacın olduğu yer ve zamanda sunumudur. Su; tarım, sanayi, enerji, ormancılık, ulaşım, bölgesel ve kentsel gelişme ile çevre koruma gibi birçok alanda oluşturulan politikalar ile bağlantılıdır. Aslında yukarıda bahsedilen konuların yönetimi su kaynakları yönetimine girer. Sorunlar çok yönlü ve birbirlerine bağımlı olmasına rağmen, bu konu ile ilgili çalışan kurumlar birbirinden bağımsızdır. Dolayısıyla, mevcut yönetsel ve yasal düzenlemeler, su yönetimi ile diğer hükümet politikaları aralarında gerekli olan uyumu ve iş birliğini sağlayacak kadar gelişmemiştir.

19. yüzyılın sonlarından beri dünya çapında gelişmekte olan ve gelişmiş ülkeler suyun verimli kullanımı ve ihtiyaçları karşılanması için bazı su politikalarını benimsemiştir. Özellikle endüstri devrimi ile suyun kullanım hedefleri yükselmiş, temel ihtiyaçları

karşılamanın yanında endüstriyel ve enerji üretimi amaçlı kullanımlar, suyun önemini daha da artırmıştır. Bu durumda; gelişmiş ülkeler gıda, enerji, içme ve kullanma suyu amaçlı istekleri karşılamaya yönelik birçok baraj ve sulama kanallarını içeren su kaynakları tasarımı anlayışı benimsenmiştir (T.C. Kalkınma Bakanlığı, 2014).

Suya olan talebin artması ve kaynakların kısıtlı olması ile su kaynakları yönetimi daha büyük önem kazanarak yönetimin havza bazında yapılması gerekliliğini ortaya çıkarmıştır. Çünkü kaynağın azalmasına etki eden faktörler birden fazla ve birbiri ile etkileşim içindedir.

Özellikle iklim değişikliği, enerjiye olan talebin artması sonucu barajların yapılması akım halinde bulunan su miktarında büyük değişikliğe neden olmuştur. Bunun yanında nüfus artışı, hava ve su kirliliği, tarım için suya olan ihtiyaç gibi faktörleride göz önüne alacak ve bu faktörlerinde birbirlerini etkileyeceğini düşünecek olursak su kaynaklarının entegre şekilde yönetilmesi gerekliliği büyük önem arz etmektedir.

2.3. Entegre Havza Yönetimi

1970'li yılların ortalarına kadar, su kaynaklarının planlanmasında temel hedef, belli bir su ihtiyacının karşılanması için suyun temin edilmesi ve bu amaçla kaynak geliştirilmesi ve suyun neden olduğu zararların önlenmesine yönelik sistem tasarımı şeklinde. Bunun için ise en önemli kriter mevcut su potansiyeli veya suyun miktarı olmuştur. Zaman içerisinde, ihtiyaçların değişmesi ile kısıtlı hale gelmeye başlayan su kaynaklarının daha etkili biçimde kullanılabilmesi amacıyla, tek maksatlı planlamalardan çok maksatlı projelere bir geçiş yaşanmıştır. Bu çerçevede de su kaynaklarının geliştirilmesinde optimizasyon yaklaşımları geçerlilik kazanmıştır (Harmanoğlu vd., 2002).

Geliştirilmesi istenen su kaynakları havza temelli bütüncül bir yaklaşımla planlanması, projelendirilmesi ve işletilmesi gerekmektedir. Havza bazlı su kaynakları ile ilgili projelerin geliştirilmesi ve etkili bir şekilde işletilebilmesi için su kaynaklarının istenilen zaman ve doğrulukta ölçülmesi oldukça önemlidir. Aksi takdirde enerji, içme suyu, sulama ve ekoloji gibi yeni projelere doğru verilerin sağlanması ve devam eden projeler için tahsis edilen su miktarlarının entegre havza su planına göre kullanılıp, kullanılmadığının belirlenebilmesi, hazırlanan havza su planlarının uygulamayla ne derece örtüştüğünün hesaplamasına imkân yoktur. Bu sorunun tek çözümü, gelişmiş yöntemler kullanılarak, bu konuyla ilgili taslak çalışma, plan ve önerilerin hazırlanması

ve hızla uygulamaya geçirilmesi entegre havza yönetiminin en önemli unsurudur (Koç, 2018).

Entegre havza yönetiminin esas hedefi, havzanın su miktarı yanında bu su miktarını etkileyecek hava, toprak, nüfus yoğunluğu, enerji potansiyeli, kirlilik durumu, topografik yapısı, iklim koşulları gibi tüm yönleri ele alınmak sureti ile etkin bir şekilde yönetilmesidir. Su kaynaklarının planlama ve yönetiminde entegre havza yönetiminin benimsenmesinin en önemli üç nedeni;

a) Çevre, su, hava, toprak gibi kaynaklardan oluşan bir bütündür. Bu kaynaklar, birbirleriyle sürekli etkileşim içinde olmalarından dolayı kaynaklardan birine yapılan müdahale diğerlerini de etkilemektedir. Bu kapsamda, su kaynaklarını etkin biçimde geliştirilmesi ve yönetimi için, diğer kaynaklarla olan ilişkileri de dikkate alınmalıdır. Dolayısıyla su kaynaklarının havza bazında ve diğer çevresel kaynaklarla birlikte yönetilmesi gerekmektedir.

b) Hızlı ekonomik gelişim sonucu çevrede geriye dönüşü olmayan hasarlar meydana gelmektedir. Temel politika haline gelen çevresel sürdürülebilir kalkınma açısından havza gelişiminin, sosyal, ekonomik, politik, yasal, idari unsurlarla birlikte veya entegre biçimde ele alınması gerekmektedir.

c) En önemli sorunlardan birisi olan küresel iklim değişikliği, tüm çevresel kaynakları etkilemekte ve bu etkileşimler bir kaynaktan diğerine yansımaktadır. Bu durum da entegre kaynak yönetimini zorunlu hale getirmektedir (T.C. Kalkınma Bakanlığı, 2014).

Ülkemizde akarsu havzalarında karşılaşılan sorunlar karmaşık hale geldiği ve bunun sonucunda yönetimi zorlaştığı için havza planlama ve yönetim çalışmalarında yeni uygulamalara ihtiyaç duyulmuştur. Bunun için, diğer ülkelerde olduğu gibi entegre yönetim esasına dayandırılarak havza bazında yönetilmesi gerekli görülmüştür. Bu açıdan akarsuları olabildiği kadar verimli bir şekilde kullanmak ve yönetmek için Türkiye 25 havzaya ayrılmıştır. Havza Koruma Eylem Planları (HKEP) hazırlanmakta olup, daha sonra Nehir Havzası Yönetim Planları (NHYP) hazırlanıp uygulanması sağlanacaktır. Bu sayede tüm havzalar, havza bazında daha etkin yönetilmiş olacaktır. Şekil 2.2'de Türkiye'de yer alan 25 nehir havzası gösterilmiştir.



Şekil 2.2 Türkiye’de bulunan 25 nehir havzası

HKEP’nın hazırlanması esnasında, havzadaki var olan yüzeysel su kaynaklarının (göl, nehir, dere, rezervuar, geçiş ve kıyı suları) ve yeraltı sularının özelliklerinin, miktarlarının ve kirlilik durumunun ve havzadaki endüstriyel, kentsel, ekonomik, tarımsal vb. faaliyetler neticesinde oluşan baskı ve etkilerinin tespit edilmesi, havzadaki su kaynaklarının miktarı ve kullanma potansiyeli ile havza bazında tespit edilen kirlilik kaynakları ve yüklerinin detaylı bir şekilde incelenmesi söz konusu olmaktadır. Ek olarak, su kalitesi haritalarının oluşturulması, havzanın korunması, çevresel altyapı durumunun tespit edilmesi, iyileştirilmesi ve kirliliğin azaltılması için havzadaki bütün paydaşların katılımı ile uzun, orta ve kısa vadede tedbirlere yönelik çalışmaların program, plan ve önceliklendirilmeleri yapılmaktadır. Hazırlanan HKEP’lar, sonradan Nehir Havza Yönetim Planlarına dönüştürülecektir.

2.4. Su Kaynaklarının Azalmasının Başlıca Nedenleri

Dünya yüzeyin dörtte üçü sularla kaplı olmasına rağmen, insan kullanımına elverişli tatlı su miktarı oldukça kısıtlıdır. Kısıtlı olan bu miktara olan talep ise dünya genelinde çeşitli sebeplerden dolayı gün geçtikçe hızla artmakla birlikte aynı zamanda kullanılmadan farklı şekillerde yok edilmektedir. Bu sebepler; nüfus artışı, kirlilik, enerji, endüstrinin

gelişmesi, yaşam standartının artması, küresel ısınma ve buna bağlı olarak meydana gelen kuraklıktır.

2.4.1. Nüfus artışı

Nüfus artışı, miktarı sınırlı olan su kaynaklarını daha hızlı tüketerek suyun zamanında döngüsünü tamamlamasına engel olmaktadır. Ayrıca nüfusu yüksek olan yerlerde sanayinin, yaşam standartının ve buna bağlı olarak da enerji ihtiyacında arttığı düşünülecek olursa suya olan talep nüfus yoğunluğunun olduğu bölgelerde daha çok olacaktır.

2.4.2. Su kirliliği

Su kirliliği suyun kullanım özelliğini kaybettirdiği için su kaynakları miktarının azalmasına neden olmaktadır. Su aynı zamanda alıcı ortam olarak kullanıldığından kirli suların yüzeysel sulara deşarj edilmesi suyu kullanmadan kirletmektedir.

2.4.3. Enerji

Özellikle elektrik enerjisi üretmek için yapılan barajların suyu tutması neticesinde su kaynaklarını özellikle akışa geçen su miktarını fazlasıyla etkilemektedir.

2.4.4. Küresel ısınma

Dünyayı tehdit edip en önemli sorunların başında yer alan küresel ısınmanın en önemli etkilerinden biri olan su kaynaklarının düşürmesi, sürdürülebilir yaşamı engelleyecek boyutlara ulaşmaktadır. Küresel ısınması sonucunda dünyanın pek çok bölgeleri çölleşme riski ile karşı karşıya geleceğinden suyun önemi daha da yükselmiştir. Ekolojik dengenin korunması ve insan topluluklarının sürdürülebilir gelişiminin sağlanması için, su kaynaklarının bugün ve gelecekteki ihtiyaçları karşılayabilecek şekilde kullanılmalı.

2.4.5. Kuraklık

Kuraklık normal ve tekrarlayan bir iklim olayıdır ve küresel iklim değişikliğinin sonucu dünyanın çeşitli bölgelerinde yükselen sıcaklıklar azalan yağışlar nedenleriyle meydana

gelmektedir. Kuraklık çok yavaş başlayıp aylar ve hatta yıllar sonra etkileri farkedilmeye başlar. Kuraklık bütün iklim kuşaklarında görülür ama, alanın kuraklığa karşı etkileri ve hassasiyetin derecesi bölgeden bölgeye oldukça büyük farklılıklar gösterebilir.

Diğer doğal afetlerle karşılaştırıldığında, kuraklıktan insan ve diğer canlılar daha fazla etkilenmektedir. Kuraklık aynı zamanda tarım üzerinde önemli etkileri olan en maliyetli afetlerdendir. 2016'da doğal afetlerden etkilenen insan sayısı 411 milyon iken bunun %94'ü kuraklıktan olduğu belirtilmiştir. Bu felaket sadece Amerika Birleşik Devletleri (ABD)'nde 6-8 milyar/yıl ABD doları değerinde tarıma zarar verir. Aynı şekilde, son yirmi yılda Çin'de 27 milyon tonu aşan yıllık tahıl üretimi kaybına neden olmuştur. 1950'lerden yirmi birinci yüzyılın başına kadar kuraklıktan zarar gören yıllık ortalama mahsul alanında %116 artış ile 11,6 milyon hektardan 25,1 milyon hektara yükselmiştir (Guppy vd., 2017).

Türkiye'nin değişik iklim bölgelerinde gözlenen kuraklık süreleri genellikle birbirinden farklılık gösterir. Bunun en önemli sebebi Karadeniz dağlarının ve Akdeniz Torosları'nın kıyıya paralel uzanması ve Ege Bölgesi'nde ise kıyıya dik uzanması olarak gösterilebilir. Güneydoğu Anadolu, Akdeniz, Ege kıyıları ve İç Anadolu bölgesinde kurak dönem Türkiye ortalamasının üzerinde olup yaklaşık 6-7 ay olarak tespit edilmiştir. Marmara Bölgesi ve Doğu Anadolu'nun güney kısımlarında ise bu süre 5-6 ay arasında değişirken, Doğu Anadolu'nun kuzeyi ve Karadeniz Bölgesinde bu süre 2-4 aya kadar gerilemektedir (Sırdaş, 2002).

Literatürde birçok tanımı olan kuraklığın üç belirgin tipi vardır (Wilhite ve Glantz, 1987).

Bunlar:

- Meteorolojik Kuraklık
- Tarımsal Kuraklık
- Hidrolojik Kuraklık'tır

-Meteorolojik Kuraklık: Bölgenin normal durumuna kıyasla daha az yağış alması ve kurak evrenin süresine bağlı olarak gerçekleşir ve ilk görülen kuraklık türüdür. Öncelikle tarımsal kuraklığı daha sonra da hidrolojik kuraklığı tetikler (Doğan, 2013)

-Tarımsal Kuraklık: Belirli bir zaman içerisinde bir bitkinin ihtiyacı olan toprak neminin yetersiz kalmasıdır. Tarımsal kuraklığın saptanmasında yalnızca normalin altındaki yağışlardan yararlanılması belirleyici olmayabilir. Kuraklığın şiddeti, süresi ve zamanlaması yanında, bölgedeki toprak yapısının, bitki türünün ve hayvan ırkının kuraklığa karşı direnci de çok önemlidir. Tarımsal kuraklık hidrolojik kuraklıktan önce ve meteorolojik kuraklıktan sonra görünen tipik bir durumdur. (Doğan, 2013).

-Hidrolojik kuraklık: Meteorolojik kuraklığın kümülatif etkisi ile hem yüzeysel hem de yeraltı sularındaki olumsuz değişimi ifade eder. Meteorolojik kuraklık bittikten uzun süre sonra dahi hidrolojik kuraklık varlığını devam ettirebilir. Hidrolojik kuraklık, uzun zaman devam eden yağışların eksikliğinde meydana gelmektedir. Genellikle havza bazında incelenir. Nehir akış ölçümleri, göl, yeraltı su seviyesi ölçümleri ile takip edilse de arazi kullanım değişikliği, ağaç kesimi, arazi kaybı veya verimsizleşmesi ve baraj inşaatı gibi faktörlere de bağlıdır.

Hidrolojik kuraklık olduğunda; kanal, akarsu ve derelerin debileri azalır. Göl, gölet ve barajlardaki sular çekilerek, yeraltı sularında olduğu gibi su seviyeleri düşer. Meydana gelen bir meteorolojik kuraklıkla yani yağış miktarının azalması ile hidrolojik kuraklık arasında gecikme vardır, çünkü yağıştaki azalmanın hidrolojik sistemdeki bileşenlere etkisi daha uzun bir zaman alır. Hidrolojik kuraklığın etkilerini belirleyebilmek ve izleyebilmek için akarsu debilerinin, göller ve barajlar gibi su rezervuarları ile akiferlerdeki yeraltı suyu seviyelerinin ölçülmesi gereklidir. (Sırdaş, 2002; Doğan, 2013).

Kuraklık akımı etkileyen en önemlil faktörlerdendir. Kuraklığın yaşandığı mevsimlerde akımda azalış meydana gelir. Akımda azalma meydana gelmesi aynı zamanda yeraltı sularının da azalmasına neden olmaktadır.

Havza üzerinde değişik su projelerinin tasarımlarının yapılması ve bölgenin su potansiyelinin belirlenmesi için su akımlarının olabildiği kadar doğru tahmin edilmesi gerekmektedir. Havza akımını doğru bir şekilde tahmin edebilmek için geçmişe ait;

akım, buharlaşma, sıcaklık, yağış, rüzgâr, nem, zemin özellikleri vb gibi meteorolojik verilerin bilinmesi gerekmektedir. Bu verilerden en önemli olanı geçmişe ait akım verileridir. İnsan nüfusu günden güne arttığı için değişik sektörlerde daha fazla akan suya ihtiyaç duyulmaktadır.

2.5. Akım

Yağış neticisinde yeryüzü duygun bir hale gelip su bir araya toplanır ve toplanan su herkete geçer, harekete geçen akarsuya suyun akımı denir. Başka bir deyişle akarsu akımı, nehirin belli bir noktadan geçen su miktarıdır ve hacimi m^3/s olarak ölçülendirilir. Akımın başladığı yere akarsu kaynağı, döküldüğü yere ise akarsu ağızı denir. Su akımı yüksek yüzeyden düşük yeze, küçükten büyüğe doğru çay, ırmak, nehir şekillerinde akmaktadır. Hidrologlar nehir akımlarını, ölçüm istasyonlarında ölçer. Amerika Birleşik Devletleri gibi birçok ülkede akım ölçümleri online olarak yayınlanır. Havza, bir nehir ya da göl havzası, nehrin kaynağı ile sonlandığı yer arasında kalan, nehre su veren tüm alanı kapsamaktadır. Akarsuyun bir noktaya göre, akışına katkıda bulunan yukarı akış alanı ilgili havzayı tanımlar. Bir havzanın alanı aynı zamanda onu çevreleyen topoğrafya ile eşdeğerdir. Bir nehir boyunca ne kadar yukarı akış belirleme istasyonu belirlensek, ilgili havza o kadar küçülür. Eğer belirli bir havza çıkışında gerçek akımın zaman serisinin bir ölçüm istasyon varsa, bu havzaya ölçülü havza denir yok ise havzaya ölçülmeyen havza denir. Ölçülmeyen havza için akım tahmini yapmak zordur. (Gauch, 2020).

2.6. Su Akımını Etkileyen Faktörleri

Su akımı belirsiz olup farklı mevsimlerde miktarında sürekli değişiklik meydana gelmektedir. Su miktarındaki azalış veya artış nedenleri tam olarak belirgin olmayıp çeşitli parametrelerden etkilenmektedir. Genellikle bir bölgenin su akımı; hava sıcaklığı, buharlaşma, yağış mektarı, yer yüzündeki bitki veya ağaç oranı, toprak türü, konaklama, vb gibi parametrelerden etkilenmektedir. Örneğin kış mevsiminde özellikle sıcaklığı düşük olan bölgelerde yağın kar olarak erimediği için bu dönemde akarsuyu besleyemez. Dolayısıyla akım seviyesi düşük olur. Aynı kar hava ısındığı zaman, erimeye başlar ve akımda ani artış meydana getirir. Benzer olarak yağmur da akarsuyu besleyen esas kaynaktır. Sonuç olarak yağış fazla ise akarsu akımının fazla olacağını

söylenirken adı geçen parametreler de akım miktarında büyük miktarda azalış veya artış meydana getirebilir.

2.6. Akarsudan Elde Edilen Faydalar

Kutuplarda don halinde, yeraltında, göllerde, denizlerde, buhar halinde vb gibi yerlerdeki tatlı suya göre, akarsu insan hayatını sürdürebilmesi ve yeryüzünün gerekli ihtiyacını taşıyan damarlar olarak düşünülürse daha fazla hayati önem taşımaktadır. Akarsudan içme ve kullanma, elektrik üretimi, sulama, hayvancılık, balıkçılık, sanayi vb gibi birçok amaç için faydalanılmaktadır. Algburi (2016) yaptığı bir çalışmaya göre 150'den daha fazla ülkede akarsudan faydalanarak elektrik üretildiğini ve dünyanın yenilenebilir enerjisinin en büyük kaynaklarından birinin akarsu olduğunu söylemiştir. Aynı çalışmada 63 ülkenin elektrik enerji ihtiyacının %50'sinin akarsulardan elde edildiğini belirtmiştir.

2.7. Akım Tahminin Önemi

Akım miktarının belirlenmesi, mevcut su kaynakları potansiyeli, tasarlanacak olan veya işletmede bulunan su yapılarının davranışlarının belirlenmesi açısından büyük önem taşır. Dolayısıyla, su yapıları ve su kaynaklarının etkin yönetimi açısından uzun süreli debi değerlerine gerek duyulmaktadır. Su akımını etkileyen birçok nedenin olmasından dolayı var olan belirsizlikler çoğu zaman istenilen istatistiksel çalışmalara gerekecek veri dizilerini elde etmek mümkün olamamaktadır. Gerekli veriyi elde etmek için genellikle uzun süreli mevcut olan yağış değerleri ile mevcut kısıtlı akım veri arasında ilişki kurulmaya çalışılır. Bu noktadan hareketle suyun asıl kaynağı olan yağışın belli periyottaki miktarının doğru bir şekilde bilinmemesi, yağış-akış gibi hidrolojik işlemlerin çeşitli parametreye (jeolojik, iklim, topoğrafik, zaman v.s) bağlı olması suyun zaman ve konum içindeki yayılımının bilinmesini zorlaştırmaktadır. Su akımını belirlemek için çeşitli modeller geliştirilmiştir.

2.9. Akım Tahmini İçin Kullanılan Yöntemler

Akımı tahmin etmek için hidrologlar iki tip girdi kullanmaktadır. Birincisi; yağış, sıcaklık, rüzgâr hızı gibi meteorolojik zaman serileri verisi. İkincisi; eğim, yükseklik veya

arazi örtüsü gibi statik havza özelliklerini içeren verilerdir. Bu girdilere göre akım tahmini yapmak için genellikle Geleneksel ve Yapay Zekâ (AI) yöntemleri kullanılmaktadır. Geleneksel yöntemleri yapay zekâ yöntemleri gibi doğru ve kesin sonuçlar vermediği için, son yıllarda AI yöntemleri daha yoğun bir şekilde kullanılmaktadır.

2.9.1. Geleneksel yöntemler

AI yöntemlerinin gelişiminden önce geleneksel yöntemler su akımı, yağış, su seviyesi gibi birçok durgun ve doğrusal olmayan hidrolojik süreçlerin tahminlerinde geniş bir şekilde kullanılmıştır. Literatürde; Box ve Jenkins (1970) Otoregresif (AR), Otoregresif Hareketli Ortalama (ARMA), Otoregresif Entegre Hareketli Ortalama (ARIMA), Otoregresif Eksojen ile Hareketli Ortalama Girişler (ARMAX); Thomas ve Fiering (1962) ve Yevjevich (1963) eski birçok geleneksel yöntemlerden bahis etmişlerdir. Bu yöntemleri uygulamak için daha fazla veri ve zamana ihtiyaç duyulmaktadır. Ayrıca daha önce belirtildiği gibi AI yöntemleri gibi daha kesin sonuçlar vermezler. Dolayısıyla geleneksel yöntemler yerini AI yöntemlerine bırakmıştır (Firat, 2007).

2.9.2. Yapay zekâ yöntemler (AI)

AI yöntemleri durgun ve sabit olmayan veri tahmininde yüksek performans göstermesinden dolayı son yıllarda hidroloji alanında su akımını belirlenmek için yoğun bir şekilde kullanılmaktadır. AI yöntemleri hidrolojide kullanılan değişkenlerin durgun ve lineer olmadığına rağmen etkili olduğunu görülmüştür (Altunkaynak ve Başakın, 2018). Bu çalışmada kullanılan AI yöntemlerinin ortak amacı, geçmiş yıllara ait aylık akım verilerini girdi olarak kullanıp geleceğe yönelik tahminlerde bulunmaktır. Bu çalışmada, yaygın olarak da kullanılan AI yöntemlerinden; Yapay Sinir Ağları (ANN)'ndan olan İleriye Beslenmeli Sinir Ağları (FFNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Uzun Kısa Vadeli Hafıza Ağları (LSTM) isimli yöntemler kullanılmıştır.

2.9.2.1. Yapay sinir ağları (ANN)

Yapay Sinir Ağları (ANN), paralel bir şekilde çalışıp sade elementlerden oluşan uyarlanabilir ağlardır. Bu elementler biyolojik sinir sisteminden ilham alarak meydana gelmektedir. Doğada olduğu gibi, ağ fonksiyonu büyük ölçüde elementler arasındaki oluşan bağlantılarla belirlenir. Genellikle ANN'ler belirli girdilerinin belli çıktılara yol

açacak bir şekilde ayarlanmış veya eğitilmişlerdir. Farklı çalışmalarda uygulanan AI yöntemleri ile doğrusal ve doğrusal olmayan veri kolay bir şekilde tahmin edilmiştir. ANN ile belirsiz verileri için dahi tatmin edici sonuçlar verdiği görülmüştür. Farklı alanlarda gerçek değerlere yakın tahminler elde edildiğinden ANN; örüntü tanıma, tanımlama, sınıflandırılma, konuşma, görme, kontrol sistemleri satış tahmini, robotik, endüstri işlem kontrolü, risk yönetimi, veri tahmini gibi amaçların yanında mühendislik, tıp, bilgisayar, çeviri, ekonomi, ticaret, psikoloji ve diğer birçok alanda yoğun bir şekilde kullanılmaktadır (Acar, 2019).

ANN'lerin yapısı basit işlemci elemanlardan oluşmaktadır ve ANN'yi oluşturulan elemanlar farklı biçimlerde ifade edilebilen sayısal verileri taşıyan ağırlıklar ve bağlantılar ile kendi aralarında bağlıdırlar. ANN'lerin ilerlemesine sebep olan insan beyninin mekanikleşmiş olarak gerçekleştiği anlaşılması zor olan hesaplamaları yapabilen yapay sistemlerin yapabileceği özelliklere sahiptir (Yarar 2010).

Literatürdeki ANN'lerin tanımlarına bakıldığında herkesin kabul ettiği bir tanım görülmemektedir ama genel bir şekilde kabul edilen bazı tanımlar şunlardır.

Haykin (1999) ANN'yı detaylı bir şekilde araştırıp (Neural Networks: A Comprehensive Foundation) adına bir kitap yazmış ve kendi kitabında ANN'yı "Bir sinir ağı, bilgiyi depo etmek için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemcidir." diye tanımlamıştır.

Kang vd. (1992) ANN insan beynin biyolojik sinir sistemden ilham alan bir bilgi süreç paradigması olup bu paradigmanın anahtar unsuru ise bilgi süreç sistemin bünyesi olarak tanımlanmıştır.

Bugünlerde çeşitli alanlardaki çalışmalara bakıldığında ANN'nin yaygın bir şekilde kullanıldığı görülmektedir. Bunlardan en yaygın olarak; örtü tanıma, çevirme, sistem tanımlama, işaretleme ve doğrusal olmayan denetim alanlardır. Burada bütün sorunlar için, ANN ile tahmin edilecek çözümler, tasarımcıya birtakım seçenekler tanıtır ve bazıları seçenek olmaktan zorunlu hale gelebilir. Dolayısıyla, bu seçenekleri tasarımcılar tarafından doğru değerlendirmesi, diğer yaklaşımlarda olduğu gibi ANN'da da zorunluluk söz konusudur (Firat, 2007).

Bir problemi ele alıp ANN kullanarak çözüldüğü zaman tasarımcı çeşitli seçenekler ile karşılaşır bunlardan ilk olanı öğrenme mekanizmasıdır. Literatüre bakıldığında öğreticili (denetimli) ve öğreticisiz (denetimsiz) diye iki tür öğrenme stratejilerden bahs edildiğini görülmektedir. Denetimli ve denetimsiz öğretileri arasındaki farkı istenecek olan çıkış verilerinin mevcut olup olmamasıdır. Eğer bir eğiticinin sistem çıkışları istenen değerleri temin ederse bu tür öğrenmeye eğitici öğrenme adı verilir. Tasarım koşulları, istenen değeri temin edemezse, bu tür öğretilme öğreticisiz öğrenme gubuna girer. Öğreticisiz öğrenme algoritmalar çoğunlukla geçmişte sistemin karşılaştığı veri kümesi içindeki istatistiksel bilgileri ortaya çıkarır. Bundan dolayı, çok ögeli veri kümeleri içinde deneyim vasıtasıyla bilgi genelleştirilmesi yapılabilir. ANN'lerde tasarımcının ikinci seçeneği mimari ile ilgilidir. Eğer ağ üstündeki veriyi sürekli ileriye doğru besliyor ise, ileriye beslenmeli, geriye doğru besliyor ise geriye beslenmeli yapay sinir ağları mimarisi oluşturmaktadır. Tasarımcının tarafından sunulan üçüncü seçenek ise öğrenme algoritmalarıdır. Literatürde büyük sayıda ANN algoritmalarından bahsedilmektedir ve bunlar öğrenme diye adlandırılan olguyu, matematik koşulları ile ölçülebilen büyüklüklere dönüştürerek, bir başarıml ölçütü oluşturulmasına, ölçütün zaman içinde fazlalaştırılmasına veya bir maliyet ölçütün meydana getirilmesi ve ölçütün zaman içinde azaltılmasını sağlayacak parametrenin değişim hesaplamasına dayanır. Burada parametre işleme türetilen bilginin hangi metod oluşturduğu, planlama esnekliğin ana temasıdır (Yaşar, 2004).

ANN genel olarak; bir girdi, bir veya daha fazla gizli ve bir çıktı katmanlardan oluşmaktadır. Girdi verisi ile bağlantısı olup veriyi gizli tabakaya transfer eden nöronlardan oluşan tabakaya girdi tabakası denir. Girdi tabakasından veriyi alıp işlem yapıldıktan sonra çıktı tabakasına gönderen nöronlardan oluşan tabakaya gizli tabakası denir ve gizli tabakanın dış ortam ile hiçbir bağlantısı yoktur. Son olarak işletmiş veriyi teslim alan nöronlardan oluşan tabakaya da çıktı tabakası denir (Dölling, 2002).

Eğer ANN sadece girdi ile çıktı katmanlardan oluşuyorsa, tek katmanlı, girdi, gizli ve çıktı tabakalarından oluştuysa çok katmanlı yapay sinir ağları diye adlandırılır.

ANN yönteminin; doğrusal olmama, öğrenme, genelleme yapma, uyarılma, veri işleme, gürültüye karşı hoşgörü ve duyarlılık, ve donanım gibi üstünlükleri vardır (Bayır, 2006).

Bunlar:

Doğrusal olmama

Yapay nöronlar doğrusal olmama özelliğine sahiptir ve ANN'lerin çevredeki tüm problemlere uygulanmasını sağlamaktadır.

Öğrenme

ANN yöntemi diğer yöntemlerden ayıran temel özelliği öğrenmedir. Bir problemi bu yöntem ile öğrenmek için problemin girdilere karşılık gelen çıktılarının veya sadece girdilerinin sağlanması gerekir. Girdi ve çıktı verileri ile belirlenen öğrenme kümesi yeterli miktarda örnek içermelidir.

Genelleme yapma

Eğitim sürecinden sonra ANN eğitim kümesinden başka veriler için de çıktılar üretebilir. Üretilen çıktılarının kabul edebilir seviyede olup olmadığı, test datasının bilinen sistem çıkışı ile ANN'in çıktıları karşılaştırılarak anlaşılabilir ve bu uygulamaya genellemenin testi denir.

Uyarlama

ANN'lerin parametreleri tekrar tekrar değişir veya olabildiği kadar doğru çözümleri bulmak için sürekli eğitebilir. Bu özellik ANN'lerin uyarlamalı örnek tanıma, hedef tanıma, işaret işleme, sınıflandırma, sistem kimliklendirme ile modelleme ve otomatik kontrol gibi alanlarda kullanımını sağlamaktadır.

Veri işleme

Biyolojik sistemlerdeki veri dağılmış yapıdayken ANN'lerde ise ağırlıklar üstüne paralel bir şekilde dağılmakta, işlenmekte ve korunmaktadır. Ağırlıklar her anda ANN'nin problemle alakalı olan bilgiyi ifade eder. ANN'lerde verinin kullanılan hafıza yapısı birleşik dağılmış olup çeşitli formlara dönüşerek işlenebilir.

Gürültüye karşı hoşgörü ve duyarlık

ANN’larda büyük sayıda bulunan işlemci kümeleri paralel bir şekilde dağılmış bir yapıya sahiptir ve ağın bilgileri bütün bağlantılara dağılmıştır. Girdi veri kümesinde bulunan her görültü, tüm ağırlıklar üzerine dağıtıldığından, görültü tesiri tolere edebilir. ANN’lerin hatayı tolere etme gücü daha fazladır.

Donanım

ANN donanımları bugünlerde kolay bir şekilde elde edilmesi ve yaygın bir şekilde değişik çalışmalarda kullanılabilmesi, ilgi çekici özelliklerin başında yer almakta ve asıl zamanlı uygulamalarda oldukça önemlidir.

Yapay sinir ağları birbirleriyle bağlı bir şekilde gelen işlemcilerin birleşmesinden meydana gelmekte, diğer bir deyişle nöronların bağlantısından oluşur. Ağın yapısı nöronlar arasındaki bağlantıdan belli olur. İstenilen hesaplamalar yapmak için bağlantıda yapılan değişimler öğrenme algoritması ile belirlenir. ANN’ler öğrenme algoritmalarına ve yapılarına göre sınıflandırılırlar.

ANN’ler yapılarına göre İleriye Beslenmeli ve Geriye Yayılmalı diye iki yapıda incelenir (Partal vb, 2008; Bayır, 2006). Bunlar:

-İleri Beslenmeli Ağlar

ANN’lerin bu çeşitinde nöronlar katmanlara ayrılmaktadır. Veri, giriş katmanından çıkış tabakasına doğru tek yönlü bağlantılarla ileriye doğru iletilir. Nöronlar bir katmandan diğerine bağlantı kurarlar ama aynı tabaka içerisinde bağlantılar kurulmaz. İleriye beslenmeli ağları doğrusal olmayan verinin tüm yapısı yakalama yeteneklerine sahip olduğundan diğer ANN yöntemlere göre daha geniş bir şekilde kullanılmaktadır.

-Geri Beslenmeli Ağlar

Geri beslenmeli sinir ağları, çıkış ve orta tabaka çıkışları, önceki ara katman veya giriş birimine doğru geri beslenen ağdır. Bu nedenle veriyi hem ileri hemde geriye doğru aktırır.

Yapay bir ađın ana öđeleri ađın; giriř, gizli ve ıkıř katmanlarından birinde kullanılmakta geerlidir. Bu öđeler Ađarlıklandırma Faktörleri, Transfer veya Aktivasyon Fonksiyonu, Toplam Fonksiyonu, ıkıř Fonksiyonu, Öđrenme Fonksiyonu, Hata Fonksiyonu ve Geriye Yayma Deđeri diye adlandırılır (Bayır, 2006).

Ađarlıklandırma Faktörleri, bir sinir hücresi, çođu zaman giriřleri eřzamanlı olarak kabul eder. Yapay bir nöron ile listelenmiř ađrılıklar giriřlerin sinyallerinin řiddetini ölçmek için ađdaki uyarlayıcı katsayılardır. Ađarlıklandırma faktörleri giriřlerin bađlantı kuvvetlerini ölçer. Bunlar çođu zaman, rastgele seilip yakınsama durumuna göre kesinleřir.

Transfer veya Aktivasyon Fonksiyonu, bu öđe ađrılıklandırılmıř toplam sonucu aktarma diye adlandırılan bir iřlem algoritması içinde bir ıkıř iřlem diye geer. Transfer fonksiyon içerisinde sinir ıkıřına eriřmek için, toplam deđer bařka bir eřik deđer ile karřılařtırılır, bu deđer eřik deđerden büyük ise iřlem elemanı sinyal oluřturur. Giriř ađrılık ile arpılıp toplam eřik deđerinde küçük olduđuunda sinyal oluřmaz.

Toplam Fonksiyonu, tüm girdilerin ađrılıklandırılmıř toplamını hesap etme iřlemin ilk adımıdır. Girdiler ve ađrılıkların matematiksel gösterisi sırasıyla $(I_1, I_2 \dots)$ ve $(w_1, w_2 \dots)$ řekindedir. Toplam fonksiyonu her giriř elemana ters gelen ađrılık bileřen yoluyla oluřup $(giriř1 = I_1 * w_1, giriř2 = I_2 * w_2 \text{ vb. toplam} = giriř1 + giriř2)$ řekilinde gösterilir.

Bu iřlem tüm katamanlarda birbirlerine benzer. Her önceki nöronun ıkıřı bir sonraki nöronun giriři olmaktadır.

ıkıř Fonksiyonu, her iřlem elemanı tek ıkıř sinyali verir. Biyolojik nöronlarda olduđu gibi, çok girdilerin olduđu yerde sadece tek ıkıř sinyali olabilir. Normal olarak ıkıř sinyali, aktırma fonksiyonun direk sonucudur.

Öđrenme Fonksiyonu, bu Fonksiyonun hedefi, nöron tabanlı algoritmaya nazaran her iřlem elemanın giriřleri üstündeki deđiřebilen bađlantı ađrılıklarını deđiřtirmektir ve öđreticili ile öđreticisiz diye iki tür öđrenme vardır.

Hata Fonksiyonu ve Geriye Yayma Deęeri, Büyük bir miktarda öğrenme aęlarında, istenen çıkış ve aęın elde ettięi deęerler arasındaki fark hesaplanır. Bu ham hata deęeri, mimarisi içinde kıyaslamak için hata fonksiyonu yoluyla deęiştirilir. Bu hata önceki katmana geriye doęru yayılır. Yayılan deęer geçerli hata ölçümü veya tipi üstüne baęlı istenen deęer olabilir.

2.9.2.2.Uyarlamalı aę tabanlı bulanık çıkarım sistemi (ANFIS)

ANFIS bulanık mantığı ve sinir aęı düşünce kombinasyonu olup; Son yıllarda ANN ve Bulanık Çıkarım Sistemi (FL) ikisinin özelliklerine sahipler olan ANFIS, hidroloji alanında geniş bir şekilde kullanılmaktadır (Keskin vd., 2010). ANN ile modellenen sistemin girdi ve çıktısı arasında bağlantı kurar ve istenen çıktıyı oluşturmak için eğitilmelidir (Changchun vd., 2006). Bulanık mantığı ve bulanık küme teorileri ilk kez 1965 yılında Zadeh tarafından bulunmuş ve bir dizi mantıksal kural aracılığıyla karar verme özellikleri tanımlamak için kullanılır. Nitel bir modellemeye bulanık esas olan yaklaşımı ilk kez Sugeno ve Yasukawa tarafından 1993 yılında geliştirilmiş, bu modelin yapı tanımlanması için bir bulanık kümeleme yöntemin kullanılmasını önermişlerdir. (Changchun vd., 2006). ANN'nin eğitim yeteneęi, bulanık mantığın eęer-ozaman kural oluşturma ve parametre optimizasyon özellięi bir araya gelip çok güçlü bir hibrid modeli (ANFIS) oluşturma özellięi sahiplerdir. ANFIS ve prensipleri ilk kez Jang tarafından 1992 yılda ortaya çıkarıldı ve şimdiye kadar çeşitli alanlarda birçok problem çözümünde yoğun bir şekilde kullanılmaktadır. Bu model geriye yayılım gradyanının iniş ve küçük kareler yöntemi birleştiren hibrid öğrenme kural kullanarak bir set parametreleri tanıtır. ANFIS önceden öngörülen girdi-çıkıtı oluşturmak için Üyelik Fonksiyonu (MF) sahip bir set bulanık, eęer-o halde kuralları oluşturmak için kullanılır. Bazı araştırmacılar ANFIS'i hidrolojik modellemede uygulamışlardır. Chang vd., (2001), gerçek zamanlı rezervuar operasyonu modeli üzerine çalışıp bulanık kuralları oluşturmak için yeterli bilgi verildiğinde, ANFIS'in rezervuar için klasik modellerden daha kesin sonuçları verdięini açıklanmıştır. Bu çalışmanın amaçlarından biri olan ANFIS modeli kullanarak Fırat Havzasının aylık akış tahminini yapıp sonuçları, dięer modellerden elde edilmiş sonuçlar ile karşılaştırarak performansı belirlenmiştir.

Bulanık mantık (FL)

Bulanık mantığı insanların düşünmeye dayanan yapay zekâ bir yöntemidir ve problemlere kesin çözüm bulunur. İnsan beyni kararsızlık, belirsizlik vd sebep olabilir ama bilgisayar sadece kesin değerleri değiştirebilme özelliği sahiptir, bunların yanı sıra bulanık mantığı bu ikisinin bir araya getirilme bir teşebbüstür (Üney, 2017).

FL sayısal verisi ile dil bilgisi aynı zamanda işleyebilme özelliklere sahip bir yöntemdir. Bu yöntem diğer yapay zekâ yöntemlere benzer, matematiksel tanımı olmayan belirsiz veri tahmininde kullanılır. Bulanık mantık, siyah veya beyaz, doğru veya yanlış, açık veya kapalı ifadelerin artık olmaması açısından klasik mantıktan farklıdır. FL değişkenlere üyelik dereceleri izin verir. Bulanık sistemin eğer-o halde kurallarına göre her giriş bulanık kümesi farklı durumları değerlendirir. Bu operasyonun bir sonucu olarak, en uygun çıktılar hedeflenen çıktılara çok yakındır. FL'nin en uygun sonuçları vermesi sistemi çalıştırılan uzmanın deneyimine de bağlıdır (Yarar 2010).


2.9.2.3 Uzun kısa vadeli hafıza ağları (LSTM)

LSTM'lerin veriler arasındaki uzun vadeli ilişkileri (tekrar eden değerler, dizi, v.b.) öğrenebilen Tekrarlayan Sinir Ağların (RNN) özel bir türüdür. RNN'ler, sinir ağı modül zinciri şeklindedir. Standart RNN'lerde, bu yinelenen modül, yalnız tanh aktivasyon katmanı gibi basit bir yapısı vardır. LSTM'lerin de RNN'ler gibi zincir benzeri yapıları vardır ama yinelenen modülün yapısı farklıdır. Bu yöntem ile yakın zamanda; konuşma tanıma, doğal dil işleme, finansal analiz, dil çevirisi vb birçok veri alanı ve yapay zekâ uygulamalarında başarılı sonuçlar elde edilmiştir (Kutlu, 2018). LSTM'ler, zaman serilerini sınıflandırmak, öngörmek ve işlemek için zamansal gecikmeler düşünüldüğünde oldukça elverişlidir. Zamansal uzunluğuna göreceli duyarsızlık, alternatif RNN'ler ve farklı uygulamadaki diğer öğrenme yöntemlerine göre LSTM'ye bir avantaj sağlamaktadır. LSTM'ler bilgiyi uzun zaman hatırlarlar ve bu işlemi öğrenme yol ile yaparlar. Tüm RNN'ler, bir sinir ağının yinelenen modülleri zincirinin biçimine sahiptir (Memiş, 2019).

Tekrarlayan Sinir Ağları (RNN)

Normal sinir ağlarında veri tek yönlü olarak girişten çıkışa doğru gider ve serinin önceki bilgilerini koruyamaz. Tekrarlayan Sinir Ağların (RNN)'da ise döngü özelliği vardır ve veri ile ilgili bilgileri zaman içerisinde işlemesine izin verir. RNN'in girdi değerleri anlık olmayıp önceki girdilere göre değerlendirir. Bir girdinin ($t - 1$) andaki değeri için verilen karar, t anında verilecek kararı da etkiler. RNN'lerde girdi değerleri daha önceki ve şimdiki bilgilerin bir araya getirilmesiyle çıktı üretirler ve gelecek işlemde bu çıktıları girdi diye kullanırlar, yöntem bu özelliklerinden dolayı geriye beslemeli ağlardan ayrılmaktadırlar. RNN, dinamik zamansal davranış sergileme eğilimindedirler. Zamanla ilgili istatistiksel verilerin aynısı belirli bir sıra ile gelen verilerin olduğu durumlarda yoğun bir şekilde kullanılan bir yöntemdir (Doğan, 2019).

RNN'in amacı, birbirini izleyen bilgileri kullanmaktır. Geleneksel bir sinir ağında girdi ve çıktıların hepsinin birbirinden bağımsız olduğu farz edilir. RNN'ler bir dizinin tüm öğeleri için aynı işlemi yerine getirir. Çıktı önceki hesaplamalara tabidir, bu nedenle tekrarlayan sinir ağları diye adlandırılırlar. Teoride, RNN'ler uzun dizilere ait veriyi kullanabilir, ama pratikte sadece birkaç adım geriye dönmekle kısıtlıdır. Her uzunluktaki girdinin işlenmesine imkân sağladığında, hesaplama süreleri uzun sürer. İşleyen yöntemin boyutu, girdi sayısındaki artışa bağlı değil, önceki verileri işleme olarak hesaplamalar yapılmasına rağmen, uzun zaman eski veriye ulaşmak bu tür ağlar için zordur (Doğan ve Türkoğlu, 2019). RNN modeli aşağıda Şekil 2.3'te gösterilmiştir.



Şekil 2.3. Tekrarlayan sinir ağı modeli

RNN'lar girdilerini anlık olarak değerlendirmek yerine, eski girdilere göre değerlendirir. Şekil 2.3'de görüldüğü gibi RNN girdi verilerinin yanısıra eski çıktı değerlerini gösteren içerik birimleri (content unit) de ağı etkiler. $t - 1$ anında girdiye verilen karar, t anında verilecek kararı da etkiler. Kısaca, bu tür ağlarda girdiler mevcut ve eski bilgilere göre çıktı üretirler.

2.8.Yapay Zeka Yöntemleri ile Yapılan Bazı Çalışmalar

Yangtze nehri üzerindeki Hankou hidrolojik istasyonun akım tahmini yapmak için yapılan çalışmada derin bir sinir ağı kullanılmıştır. Bu yöntem Ampirik Mod Ayırıştırma (EMD) algoritması, Kodlayıcı-Kod Çözücü Uzun Kısa Süreli Bellek (En-De-LSTM) mimarisine birleştirmiştir. Çalışmada kullanılan EMD yöntem veriyi farklı frekans bileşenlerini ayırıştırıp sadece EMD ve En-De-LSTM hibrid yöntemleri kullanılarak tahminleri yapmıştır. Yöntemlerin performanslara bakıldığında En-De-LSTM esaslı olan LSTM sadece EMD yöntemine göre gözlenen veriye yakın sonuçlar verdiği görülmüştür. Dolayısıyla, bu hibrid yöntemin uzun vadeli akımlar için etkili olduğu söylenebilir (Liu vd., 2020)

Fu vd. (2020), Malezya yarımadasının kuzey doğu tropical bölgesinde yer alan Kelantan Nehri'nin günlük akım similasyonu için derin öğrenme yöntemi uygulamış, akım tahmini için geçmiş yıllara ait veriyi kullanılmışlardır. Model birkaç perspektife göre gerçekleştirilmiştir. Çalışmanın sonunda LSTM modelinin, kurak mevsimde sabit akış verilerini işlemede avantajlı olduğu ayrıca yağmurlu mevsimlerde hızla dalgalanan akış verilerinde veri özelliklerini yakalama konusunda iyi sonuçlar verdiği görülmüştür.

Thapa vd. (2020), Nepalın Himalaya bölgesinde eriyen kar su akım tahmini için; LSTM, doğrusal olmayan otoregresif dışsal (NARX), gauss süreci regresyon (GPR) ve destek vektör regresyonu (SVR) modelleri uygulanarak hesaplamalar yapmışlardır. Modellerin daha uygun girdi kombinasyonları belirlemek için ayrıca Gamma testi yapılmıştır. Bir tane gezli tabakalı olan sığ LSTM yöntem, gezli tabakaları çok olan LSTM yönteme göre daha üst sonuçlar verdiği gözlemlenmiştir. LSTM için kullanılan yedi optimize edici testlerden Adamax bu çalışma için en uygun optimize edici olduğunu görülmüştür. Modellerin performansını öğrenmek için R^2 , MAE, değiştirilmiş Kling–Gupta verimliliği (KGE), NSE ve RMSE istatistiksel kriterleri kullanıp elde edilen yüksek R^2 değerleri ile

düşük hatalar vermiştir. Bundan dolayı öğrenme (ML) yöntemleri bu tür tahminlerde kullanılması uygun görülmüştür.

Khazae Poul vd. (2019), America Birleşik Devletleri ve Kanada arasında yer alan St. Clair Nehir akımı tahmin etmek için; istatistiksel yöntem olarak çoklu doğrusal regresyonu (MLR), ANN ve ANFIS linear olmayan metod ve KNN parametrik olmayan regresyon yöntemi kullanmışlardır. Daha fazla araştırma yapmak için dalgacık dönüşümü (WT) ve adı geçen modeller ile birleştirip hibrit modeller oluşturulmuş ve hesaplamalar için uygulanıp sonuçlar karşılaştırılmıştır. Çalışmada altı girdi kombinasyonları kullanılmıştır ve önceki akım, sıcaklık ve yağış verileri girdi olarak kullanıldığında daha kesin sonuçları verdiğini belirlemiştir. MLR, ANN, ANFIS ve KNN yöntemleri WT ile birleştirerek yapılan tahminleri sadece MLR, ANFIS, ANN ve KNN yöntemleri uygulanarak yapılmış olan tahminlere göre daha kesin sonuçlar verdiği belirlenmiştir.

Hien Le vd. (2019), Vitnamdaki Da Nehir havzasının Hoa Binh barajına gelen günlük suyun sel tahmini yapmak için günlük yağış ve akım; bir, iki ve üç gün önceki kombinasyonları girdi olarak kulanıp LSTM yöntemi uygulanarak tahminleri yapılmıştır. Modelin öngörü yeteneği oldukça etkileyici olduğu görülmüştür. Dolayısıyla, LSTM yöntemi akım tahminlerinde etkili olduğunu söylenmiştir.

Damavandi vd. (2019), Amerika Birleşik Devletleri Teksas eyaletinde bulunan, Brazon Nehir havzasının akım tahmini için LSTM yöntemi kullanılmıştır. Modelin performansını belirlemek için tahmin edilen ve gözlemlenen veriyi kullanarak; Nash–Sutcliffe (NSE) ve Pearson korelasyonu (ρ) istatistiksel değerlendirme kriterlerine bakmıştır. Bu çalışmada LSTM modeli yüksek doğruluk oranlı sonuçları verdiği için, bu model akım tahminleri için uygun görülmüştür.

Calp (2018), İşletmedeki personellere günlük talep edilecek yemek mektarı ANN yöntemi kulanılarak yapılması planlanmıştır. Modelin performansını MSE, RMSE ve R^2 kullanılarak belirlenmiştir. Kullanılan ağı test ve eğitiminde FFNN kullanılmıştır. Çalışma sonunda modelin performansı yüksek ve hata oranı düşük olduğunu görülmüştür. Dolayısıyla, ANN yöntemi günlük yemek talebi tahmininde etkili olduğunu belirlemişlerdir.

Adnan vd. (2017), Yukarı İndus Havzası, Dainyor hidrolojik istasyonun akım tahmini yapmak için ANN ve destek vektör makinesi (SVM) modelleri uygulamışlardır. Kullanılan modellerin performansları; R^2 , RMSE ve MAE istatistiksel değerlendirme kriterleri ile belirlenmiştir. Elde edilen sonuçlara göre SVM yöntemi ANN yöntemine göre aylık akım tahmini için daha başarılı olduğu görülmüştür.

Patel vd. (2014), Hindistanın Gujarat eyaletindeki Mehsana ilçesinin Kheralu Taluka köyünde yer alan Sabarmati Nehri üzerine Dharoi Baraj'ına gelen sel tahmini için ANFIS yöntemi kullanılmıştır. Çeşitli üyelik fonksiyonların yanında birçok girdi kombinasyonları kullanılarak giriş verisini, test ve eğitim olarak ayırıp ANFIS modelinin performansına bakılmıştır. Bu çalışmada ANFIS modeli Log Pearson tip-III istatistiksel yöntem ile karşılaştırılmıştır. Elde edilen sonuçlara bakıldığında, bahsedilen çalışma alanı için ANFIS modelinin daha kullanışlı olduğu görülmüştür.

Sanikhani ve Kisi (2012), iki farklı bulanık yöntem olan ızgara bölümlü ANFIS (ANFIS-GP) ile alt kümeli ANFIS (ANFIS-SC), uygulayarak Fırat-Dicle havzasının aylık akım tahminini yapmışlardır. Modellerin tahmin performanslarını etkileyen periyodikliği de araştırılmıştır. Sonuçlara bakıldığında ANFIS-SC modelin performansı, ANFIS-GP modele göre biraz daha iyi olduğu görülmüştür.

Türkiyenin güney tarafında yer alan Dim Nehri akım tahminleri için ANFIS modeli stokastik hidrolojik modeller ile birleştirip hesaplamaları yapılmıştır. Yöntemler hidrolojik zaman serisi modellemesi için uygulanmıştır. Daha sonra otoregresif hareketli ortalama (ARMA) modeller ile üretilen sentetik serileri, ANFIS'in eğitim verisi seti olarak kullanılmıştır. Sonuç olarak eğitim aşamasında girdi ve çıktı verisini uzatarak ANFIS'in doğruluk oranının yükseldiği görülmüştür (Keskin vd., 2010).

Solaimani (2009), ANN yöntemi kullanarak İranın Semiarid bölgesinde bulunan Jarahi Havzası için yağış akış arasındaki ilişkiyi modellemiştir. Bu çalışmada yağış tahmini için çok katmanlı ileriye beslenmeli geriye yayılmalı ANN yöntemi ile çeşitli algoritmalar uygulanmıştır. Jarahi Havzası için aynı modellerin değişik ayarları kullanarak aylık akım tahmini yapılmıştır. Bu yöntemin performansı, akım tahminleri için kullanılmış olan; Dereceli Alçalma (GDX), Eşlenik Gradyan ve Levenberg-Marquardt (L-M) geleneksel yöntemleri ile karşılaştırılmıştır. Elde edilen sonuçlardan ANN modelin geleneksel modellere göre daha verimli olduğu görülmüştür.

Güldal vd. (2009), Eğridir Gölün gelecekteki su seviye tahmini için ANFIS, Tekrarlayan Sinir Ağları (RNN) ve Stokastik modelleri kullanmıştır. Bu amaç için RNN ve ANFIS modellerine çeşitli girdi yapıları uygulayarak en uygun olan model araştırılmıştır. Bunların yanı sıra, otomatik gerilimli (AR), klasik stokastik modeller ve ARMA modelleri uygulayıp RNN ve ANFIS ile karşılaştırılmıştır. Modellerin performansları grafiksel şekiller ile istatistiksel değerlendirme kriterleri kullanarak karşılaştırılmıştır. Sonuçlar kıyaslandığında RNN ve ANFIS diğer geleneksel; AR, klasik stokastik ve ARMA modellere göre daha yüksek doğruluk gösterdiği sonucu elde edilmiştir. Dolayısıyla göllerin su seviye tahmininde RNN ve ANFIS modellerinin kullanılmasının uygun olduğu bulunmuştur.

Türkiye'nin Seyhan ve Ceyhan Nehirlerinin günlük akım tahminleri için yapılan bir çalışmada; ANN, ANFIS, Genelleştirilmiş Regresyon Sinir Ağları, İleriye Beslenmeli Sinir Ağları ve AR yöntemleri uygulanarak hesaplamaları yapılmıştır. Çalışmada, Seyhan Nehri için geçmişteki günlük nehir akım kombinasyonları, Ceyhan Nehri için günlük nehir akımları kullanılmıştır. Bu iki nehir için veriler eğitim, test ve doğrulama olarak üç kümeye ayrılmıştır. ANN, ANFIS ve AR yöntemlerin uygulanabilirlik ve performansları belirlemek için nehirlerin akım verileri çeşitli yapıları test ve eğitilmiştir. Kullanılmış olan tüm modellere eğitim ve test verileri uygulanarak performanslarına bakılmıştır. Modellerin doğruluğuna bakıldığında ANFIS modeli diğer modellere göre kesin sonuçlar verdiği görülmüştür (Firat, 2007).

Dölling (2002), Arjentinde yer alan San Juan Nehir havzasının Pachon metrolojik istasyonundan almış olan iklimsel verileri alıp yapay zeka yöntemi uygulanarak aylık akım tahmini yapmıştır. Çalışmanın sonucunda istenilen sonuçları elde etmişlerdir.

3. MATERYAL VE YÖNTEM

3.1. Materyal

Su kaynaklarının daha iyi yönetilmesi ve mevcut ve gelecekteki su miktarını belirleyebilmek için Ülkemiz 26 havzaya ayrılmıştır (Şekil 3.1). Bu çalışmada 26 havzadan biri olan Fırat Havzası'nın ileriye dönük akış tahminleri yapılmıştır. Akış tahmini için Aşığa ve Orta Fırat Havzalarında yer alan dört istasyona ait akış verileri kullanılmıştır.




Şekil 3.1. Türkiye'deki büyük akarsu havzaları (Yenigün, 2007, s. 241)

Fırat Havzası Tunceli, Erzincan, Elâzığ, Diyarbakır, Malatya, Adıyaman, Gaziantep, Şanlıurfa illerin sınırını belirlenip Türkiye'nin doğusundan başlayıp kuzeyden güneye doğru geçerek Suriye'ye ardından Irak ve Irak'ın Basra İli'nde Dicle havzası ile bir araya gelmektedir ve ardından Basra Körfezi'ne dökülür. Bu havzanın yüzölçümü 127304 km² ve ortalama yüksekliği 1009,87 m olup Türkiye'nin en büyük su havzalarından biri sayılır. Bu havzaya düşen ortalama yıllık yağış 540,1 mm/yıl ve ortalama yıllık akış ise 31.61 km³ dir. Bu havza Türkiyenin ortalama yıllık akış miktarı açısından en büyük havzasıdır. Havza üzerine 19 adet büyük baraj inşa edilmiştir. Bu barajlardan topladığı su hacmi açısından Atatürk Barajı, gövde yüksekliği açısından ise Keban ve Karakaya Barajları dikkat çekmektedir. Fırat havzası kendi içerisinde Orta Fırat, Yukarı Fırat ve Aşağı Fırat olarak üçe ayrılmıştır. Çalışmada havza üzerinde işletmesi Devlet Su İşleri'ne


(DSİ) ait olan ve havzanın aşığa ve Orta kısımlarında bulunan 4 adet Akım gözlem istasyonu (AGİ) ele alınmıştır. Bu AGİ'lerin havzadaki konumları Şekil 3.2 ve Şekil 3.3'te sunulmuştur.

Fırat Havzası'nın ortalama yıllık akım miktarı 31,38 milyar m³, ortalama yıllık verimi 8,23 l/s/km² ve toplam akış katsayısı % 16,75 olarak belirlenmiştir (EİE, 2003).

Çalışma alanında yer alan Aşığa Fırat Havzası'nın eie_2124, eie_2131 (Şekil 3.2) ve Orta Fırat Havzası'nın eie_2102, eie_2122 (Şekil 3.3) istasyonlarına ait 1981-2011 yılları arası aylık veriler kullanılmıştır.



Şekil 3.2. Aşığa Fırat Havzası 2124, 2131 istasyonları (Altıparmak, 2008, s. 21)



Şekil 3.3. Orta Fırat Havzası 2102, 2122 istasyonları (Altıparmak, 2008, s. 20).

İlgili havzanın belirtilen tarihlerde akım tahminini yapmak için kullanılan Akış Gözlem İstasyonlarından alınan veriler Tablo 3.1 ve Tablo 3.2’de verilmiştir.


Tablo 3.1. eie_2102 ve eie_2122 istasyonlara ait yağış alan ve kotlar (ÖNÖZ, 2015)

AGİ	Gözlem Yılı	Yağış Alanı (km ²)	Kot (m)
2102	1969-2010	25.515,6	859
2122	1969-2009	5.882,4	1552


Tablo 3.2. eie_2124 ve eie_2131 istasyonlara ait yağış alanı ve kotlar (Altıparmak, 2008)

AGİ	Gözlem Yılı	Yağış Alanı (km ²)	Kot (m)
2124	1963-2004	1256,1	1180
2131	1957-2004	277,6	925


Aşığa ve Orta Fırat havzaların çalışma alanında seçilmiş olan dört istasyona ait eğilim çizgileri Şekil 3. 4, 3.5, 3.6 ve 3.7’de verilmiştir. Yatay eksen akım zamanını ifade eder ve bu zaman tüm istasyonlar için 369 aydır. Düşey eksen ise m³/s olarak debiyi ifade etmektedir.




Şekil 3.4. Orta Fırat Havzası eie_2102 nolu istasyonun eğilim çizgisi



Şekil 3.5. Orta Fırat Havzası eie_2122 nolu istasyonun ait eğilim çizgisi



Şekil 3.6. Aşağı Fırat Havzası eie_2124 nolu istasyonun eğilim çizgisi



Şekil 3.7. Aşağı Fırat Havzası eie_2131 nolu istasyona ait eğilim çizgisi

3.2. Yöntem

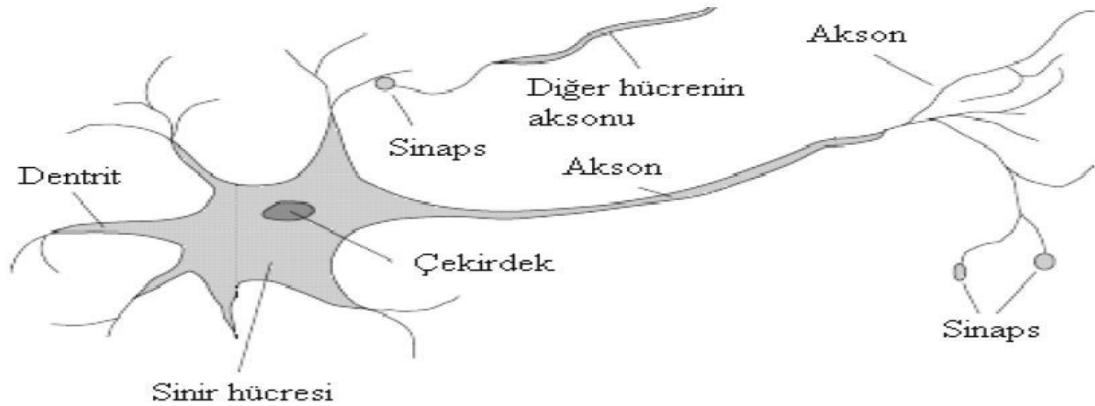
Aşağı ve Orta Fırat Havzası'nın geleceğe yönelik akım tahminlerini yapabilmek için Yapay Zekâ yöntemler'den; İleriye Beslemeli Yapay Sinir Ağları (FFNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Uzun Kısa Vadeli Hafıza Ağlar (LSTM) olmak üzere üç yöntem kullanılmıştır. Bu Yöntemlerin performanslarını belirlemek için Ortalama Mutlak Hata (MAE), Korelasyon Katsayısı (R) ve Nash Sutcliffe Verimlilik (NSE) model değerlendirme indisleri kullanılmıştır.

3.2.1. İleriye belemeli sinir ağları (FFNN)

İleriye Beslemeli Sinir Ağları (FFNN), Yapay Sinir Ağları (ANN) modellerindedir. ANN'larının tarihsel gelişimi 1970 yılından başlamıştır. İzleyen 10 yıl içerisinde birbirinden farklı otuzaya yakın yeni model geliştirilmiştir. (Çölkesen, 2003). Yapay Sinir Ağları, beyin işlem bilgisi gibi biyolojik sinir sistemi ile ilham alan ve paralel bir şekilde dağıtılmış olan bir bilgi işlem sistemidir. Belli bir sorunu çözmek için ortak olarak çalışan çok sayıda birbirine bağlı nöronlardan oluşur. Çeşitli fikirler ve kavramlar için kullanılabilen ve test aşamasında belirli bir geri hata ve yayılım düzeltme mekanizması yoluyla öğrenilmektedir. Hatayı en aza indirgeyerek, bu çok katmanlı sistemler bu günlerde insan düzeltmesi olmadan fikirleri kavramsallaştırabilir ve öğrenebilir (Tsoukalas vd., 1996).

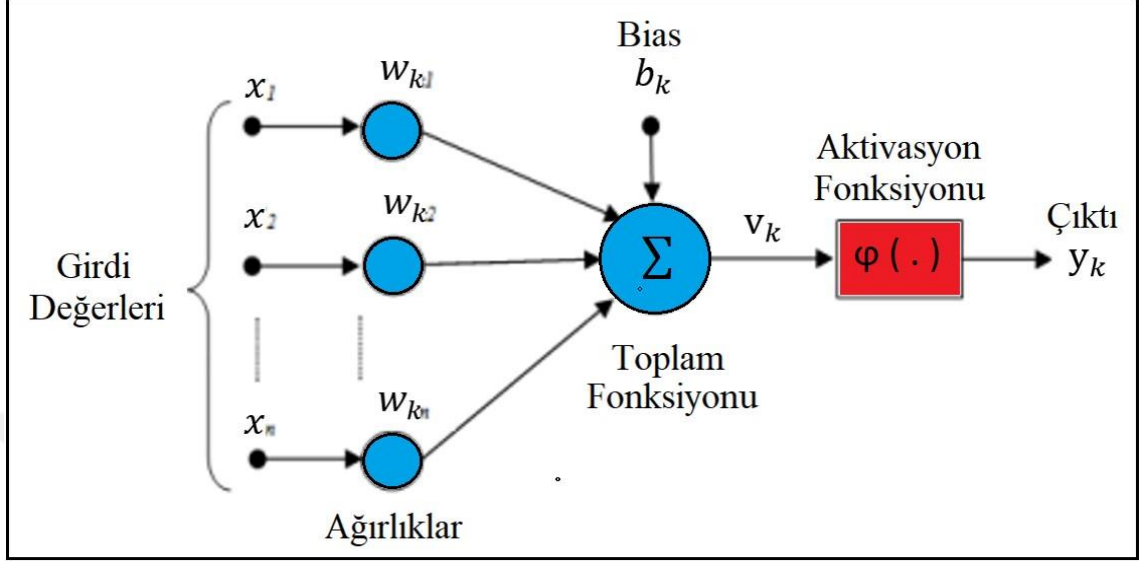
- **Biyolojik Nöron ve Yapay Nöron Hücresi**

Biyolojik sinir hücresi nöron olarak adlandırılır ve dentrit, akson, çekerdek diye üç bölümden oluşur. (Bkz. Şekil 3.8)




Şekil 3.8. Biyolojik sinir ağı yapısı (Yakıt vd., 2017, s. 288)

Yapay nöronun biyolojik nörona göre daha basit bir yapısı vardır. Temel bir yapay nöronun modeli Şekil 3.9’da gösterilmiştir.



Şekil 3.9. Yapay sinir ağı (Calp, 2018, s. 5)

ANN hücresinde esas olarak dışarıdan veya başka nöronun alması gereken veri yanında; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar yer almaktadır. Ağırlıklar dış ortamdan veriyi alıp nörona bağlar ve bunun yanında verinin etkisini belirler. Toplam fonksiyonu ise net girdiyi hesaplar. Net girdi, girdilerle ve bu girdilerle ilgili ağırlıkların çarpım sonucunda meydana gelir. Aktivasyon fonksiyonu işlem süresince net çıkışı hesaplar ve bu işlem aynı zamanda nöron çıktısını verir. Genel olarak aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur (Calp, 2018). Şekil 3.10’da görülen “b” bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri diye adlandırılır. Nöronun matematiksel modeli Şekil 3.10’da gösterilmiştir.



Şekil 3.10. Temel yapay hücresi (Yaşar, 2004, s. 63)

Nöron çıktısı $o = f(W.X + b)$ şeklinde hesaplanır. Matrisin n girdi sayısı olmak üzere;

$$W = w_1, w_2, w_3, \dots, w_n \quad (3.1)$$

$$X = x_1, x_2, x_3, \dots, x_n \quad (3.2)$$


Olarak yazılabilir. Bunlar formülize edildiğinde

$$\text{Net} = \sum_{i=1}^n (W.X + b) \text{ ve } o = f(\text{net}) \quad (3.3)$$

$$\text{Son olarak } o = \sum_{i=1}^n W.X + b \text{ bir şekilde de yazılabilir.} \quad (3.4)$$

Burada W ağırlık matresi, X girdiler, b bias, f aktivasyon fonksiyonudur ve bu fonksiyonun doğrusal olmayan birçok tipleri vardır.

ANN'lerin yapısı, yapay sinir nöronlarının birleşik hali olup insanların biyolojik sinir ağlarına benzer özelliklere sahiptir (Solaimani, 2009). Nöronlar bir araya gelip tabakalar oluşturur. Bazı ANN'lar sadece bir girdi ve bir çıktı katmanlarından oluşur ama genelde ANN'lar bir girdi, bir veya birden daha fazla gizli ve bir çıktı katmanlarından oluşmaktadır ve ikiden daha fazla katmanlardan oluşan ANN'lere çok katmanlı ANN'ler denir (Şekil 3.11). ANN'lerde girdi tabaka veriyi alıp gizli katman'lara transfer eder, gizli tabakada eşlenip çıktı tabakaya gönderilir.



Şekil 3.11. Çok katmanlı yapay sinir ağları

- Aktivasyon Fonksiyonu

Bir AI yöntemin karmaşık bir şeyi öğrenmesi ve anlamlandırması için aktivasyon fonksiyonu oldukça önemlidir. ANN'deki bu fonksiyonun ana amacı, bir düğümün bir giriş sinyalini bir çıkış sinyaline dönüştürüp ve çıkış sinyali, bir sonraki katmana giriş olarak tanıtmaktır. Aktivasyon fonksiyonunu uygulanmadığında, çıkış sinyali basit bir şekilde doğrusal fonksiyonu olacaktır. Bu fonksiyonun çözmek kolaydır yani karmaşık değildir. Aktivasyon fonksiyonu olmadığında, modelimiz görüntüler, ses, videolar, konuşma vb. gibi karmaşık verileri öğrenemeyip modelleyemez. Peki, neden doğrusal olmamaya (Non-Linearity) ihtiyaç duymaktadır sorusu şu şekilde yanıtlanabilir, doğrusal olmayan fonksiyonlar, dereceleri birden daha fazla olup eğriliğe sahip olan fonksiyonlardır. Bir girdiyi çıktı ile eşleştiren herhangi bir keyfi karmaşık işlevi temsil etmek ve öğrenmek için bir sinir ağına ihtiyaç duymaktadır. ANN'lar Evrensel Fonksiyon Yaklaşımcıları diye kabul edilir. Bu işlevi öğrenebilecekleri ve hesaplayabilecekleri anlamına gelmektedir. Düşünebileceğimiz adeta her süreç, ANN'lerde fonksiyonel bir hesaplama olarak temsil edilebilir. Tablo 3.3'te bazı aktivasyon fonksiyonların denklemleri ve aralıkları gösterilmiştir.

Tablo 3.3. Çalışmada kullanılmış olan modeller için seçilen; doğrusal, sigmoid, relu softmax ve tanh aktivasyon fonksiyonların denklem ve aralıkları


Aktivasyon Fonksiyonu	Denklem	Aralık
Doğrusal Fonksiyonu	$F(x) = x$	$(-\infty, \infty)$
Sigmoid Fonksiyonu	$f(x) = \sigma(x) = \frac{1}{1+e^{-x}}$	$\{0,1\}$
Relu Fonksiyonu	$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	$[0, \infty)$
Softmax Fonksiyonu	$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^k e^{z_k}} \quad j = 1, k$	$[0,1]$
Tanh Fonksiyonu	$\text{Tanh } x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, 1)$

3.2.2. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS)

ANFIS sadece görev tahmini veya çıktısı bir olan doğrusal olmayan fonksiyonların tahmininde kullanılmaktadır. Bu yöntem bir sinir ağı platformunda fonksiyon yaklaşımı problemlerinin çözümünü sağlamak için kullanılabilir. MATLAB yazılımı içindeki ANFIS editör ile bulanık mantık modeli uygulanabilmektedir. ANFIS modelinin uygulanabilmesinde girdi ile çıktılarının bulunması gerekir. Seçilmiş olan üyelik fonksiyonuna göre melez öğrenme algoritmasından yararlanarak eğitilmektedir (Bozkurt, 2017). ANFIS modelin en büyük avantajı, parametreleri optimize edebilmesidir. Çözülünecek problem modellenen yapıya göre muhtemel bütün kuralları atayabilmekte veya kuralların veriler vasıtasıyla uzman görüş ile atanmasına olanak sağlamaktadır. Bulanık çıkarım modeli oluşturduğunda üyelik işlevleri seçim sistemi modelleyecek kullanıcıya bağlı olup burada tercih söz konusudur. Ancak modellere bakılarak üyelik işlevinin şeklinin ve adedinin ne olması gerektiğine kolayca karar verilememektedir. Bu yöntem kullanılarak gerçekleştirilen tahmin çalışmaları incelendiğinde çeşitli alanlarda birçok çalışma yapıldığı ve başarılı sonuçlar verildiği görülmektedir (Kaya, 2018).

ANFIS nöro-bulanık yöntemlerin hibrid yapısı olup insan uzmanlığı entegre etme yanında öğrenme yolu ile adapte olur. Bu yöntemin yapısında; düzeltme ve uyarlanabilme diye iki tür düğümleri vardır (Mohd vd., 2016).

Şekil 3.12’de Sugeno bulanık yöntemi için yapıya karşılık gelen, eşdeğer ANFIS mimarisi ve bulanık çıkarım mekanizması yer almaktadır.



Şekil 3.12. Tüm katmanları gösterilen ANFIS yapısı

İki bulanık kuralları; eğer-o halde şöyle yazılır.

Birinci kural: Eğer $x \in A_1$ ve $y \in B_1$ ise o halde $f_1 = p_1 x + q_1 y + r_1$ olur

İkinci kural: Eğer $x \in A_2$ ve $y \in B_2$ ise o halde $f_2 = p_2 x + q_2 y + r_2$ olur

Yukarıda bahsedilen kurallar üyelik dereceleri açısından şöyle yazılabilir.

Birinci kural: Eğer $\mu_{A_1}(x)$ ve $\mu_{B_1}(y)$ ise o halde $p = p_1 x + q_1 y + r_1$ olur

İkinci kural: Eğer $\mu_{A_2}(x)$ ve $\mu_{B_2}(y)$ ise o halde $p = p_2 x + q_2 y + r_2$ olur

Burada A_i ve B_i üyelik fonksiyonları (MF) ve p_i , q_i , ve r_i de bulanık kuralların sonuç bölümün parametreleridir. Birinci katmanın (MF'ler katmanı) ve dördüncü katman (sonuç katman) düğümleri uyarlanabilir, halbuki ikinci katman (ürün katmanı) ve üçüncü katman (normalleştirme katmanı) düzeltme yapar. ANFIS'in beş katmanlı mimarisi aşağıdaki gibi açıklanabilir.

Birinci katman: Bu katman girdi katman olarak adlandırılır ve tüm düğümlerdeki alınan giriş sinyalleri başka katmanlara aktarır. Bu tabakanın her i düğümü parametrelili bir MF'un üçgen, trapez, gauss veya genelleştirilmiş Bell fonksiyonudur. Her MF parametresi önceden hazırlanmış parametre olarak adlandırılır.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) & i &= 1,2 \\ O_{1,i} &= \mu_{B_i}(y) & i &= 3,4 \end{aligned} \quad (3.5)$$

Olduğunda MF'ların Gauss şekli şöyle yazılır.

$$\text{Gauss} = (x; c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (3.6)$$

Burada (c, σ) öğrenme sürecinden eğitilmiş, önceden bilinen parametreleridir.

İkinci katman: Bu tabaka bulanıklaştırma katman olarak isimlendirilir. Girdi değerleri bulanık gruplara ayırmada Jang'ın ANFIS modeli MF'nu şeklinde geliştirilmiş Bel aktivasyon fonksiyonu kullanılır. Burada, her düğümün çıktısı, girdilere ve kullanılan üyelik fonksiyonu ile ilgili üyelik derecelerinden oluşmaktadır. İkinci katmanın $\mu_{A_i}(x)$ ve $\mu_{B_i}(y)$ üyelik dereceleridir.

$$O_{2,i} = W_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2 \quad (3.7)$$

İzgara bölümlenmeyi kullanarak otomatik oluşturulan kurallar m^n dır, burada m her girişte MF'lerin sayısı, n girişlerin toplam sayısıdır.

Üçüncü katman: Bu katman normalizasyon katmanı olarak adlandırılır. Bu katmanın her düğüm bir önceki katmandan gelen bütün düğümleri girdi olarak kabul edip her kuralın normelleştirilmiş düzeyi hesaplanmaktadır. Normelleştirilmiş ateşleme düzeyi ($o_{a,i}$) şöyle hesaplanır.

$$O_{3,i} = O_{3,i} = \bar{w} = \frac{w_i}{w_1 + w_2} \quad i = 1,2 \quad (3.8)$$

Burada w_1, w_1, w_2 ve \bar{w}_i i'inci, birinci, ikinci ve i'inci kuraların normelleştirilmiş ateşleme güçleridir.

Dördüncü katman: Bu katmanın düğümleri, $f_i = p_i x + q_i y + r_i$ düğüm fonksiyonu ile bulanık kuralın sonuç bölümü belirtir.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_1 x + q_1 y + r_1) \quad i = 1,2 \quad (3.9)$$

Burada \bar{w}_i i'inci kuralın normelleştirilmiş ateşleme gücü ve $\{p_i, q_i, r_i\}$ i'inci kuralın sonuç kısmının birinci dereceden bir polinomdur. $\{p_i, q_i, r_i\}$ parametreleri ANFIS'in eğitime aşamasında tanımlanır.

Beşinci katman: Bu katmanda sadece bir düğüm vardır ve \sum şeklinde gösterilir. Burada dördüncü katmandaki her düğümün çıktısı toplama sonucunda ANFIS sistemin asıl çıktısı elde edilir.

$$y = \sum_{i=1}^n \bar{\mu}_i (p_i x_1 + q_i x_2 + r_i) \quad (3.10)$$

ANFIS c, σ ve $\{p_i + q_i + r_i\}$ gibi uyabilen parametreleri tanımlayarak gerçek ve istenen çıktılar arasında hatayı en düşüğe düşürür. ANFIS'in standart iki geçişli öğrenme süreci; dereceli alçalması (GD) ve en küçük kareler tahmincisi (LSE) hibridi bir şekilde kullanılır (Tablo 3.4). Tablo 3.4'te görüldüğü gibi, sonuç parametrelerin ileriye geçişi LSE tarafından güncellenir. Halbuki öncül parametreleri geriye doğru geçiş GD ile eğitilir. Yerel minimumda sakıncası olan öncül parametrelerin tanımlanması ANN'nin BP algoritmasından etkilenir.

Tablo 3.4. ANFIS için iki geçişli hibrit öğrenme algoritması (Mohd vd., 2016, t.1)

Parmetreler	İleri Geçiş	Geri Geçiş
Öncül Parmetreler	belirlenmiş	GD
Sonuç Parmetreler	LSE	belirlenmiş
Sinyaller	Düğüm Çıktıları	Hata Sinyalleri

Hatayı düşürüp performansı yükseltmek için, ANFIS yöntemin etkili bir şekilde eğitilmesine ihtiyaç vardır. Bu nedenle, birçok araştırmacı bu yöntemin performansını yükseltmek için ANFIS yöntemi gradyan yöntemlerinin karması ve tek başına olması şeklinde kullanılmıştır (Mohd vd., 2016).

3.2.3. Uzun kısa vadeli hafıza ağları (LSTM)

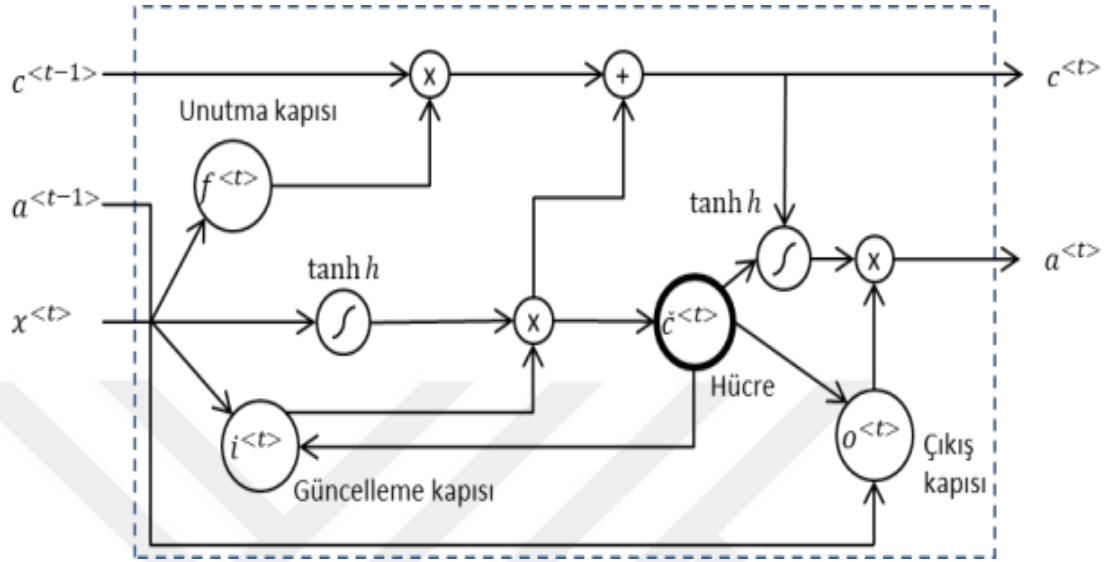
LSTM'ler klasik Çok Katmanlı Algılayıcı (MLP)'dan daha farklı sinir ağlarıdır. Bir MLP gibi, LSTM nöronlardan oluşmuş olan katmanlarından meydana gelmektedir. LSTM'yi kullanarak tahmin yapıldığında giriş verileri ağ üzerinde yayılır. RNN gibi LSTM de tekrarlayan bağlantılara sahiptir, böylece önceki zaman adımındaki nöronun önceki aktivasyonlarından gelen durum, bir çıktıyı hazırlanıp bir sonraki adımda başka girdileri ile girdi olarak kullanılır. Ayrıca LSTM diğer RNN'lerin eğitimini ve ölçeklenmesini engelleyen sorunları önleyip mükemmel bir yapısı vardır. Bu özelliği ve başarılı olan etkiliyici sonuçları bu yöntemin ünlü olmaya neden olmuştur (Brownlee, 2017).

Uzun zaman dilimleri süresince bilgileri aklında tutmak (bellekte tutmak) varsayılan (default) bu yöntemin özelliklerindedir. LSTM ağı, uzun zaman, zaman periyotlarının yanında kısa zaman periyotları da hatırlamaktadır. Saklanan değerlerde sürekli bir şekilde değişiklik meydana gelmez ve zaman içinde geri yayılımla eğitildiğinde eğiminde kayb meydana gelmez (Sak vd., 2014).

Bir LSTM, zaman gecikmeleri dikkate alındığında zaman serilerini işlemek, sınıflandırmak ve tahmin etme konularında sıklıkla uygulanan bir metoddur. Çalışma kapsamında, veri setinin özellikleri göz önüne alıp LSTM ağı uygun olduğu düşünülmüştür.

LSTM'ler RNN'in gelişmiş bir versiyonu olup uzun vadeli bağımlılık problemini çözmü için tasarlanan sinir ağlarıdır ve bilgiyi uzun zaman hatırlama özelliği sahiptir. LSTM'ler

diğer tekrarlayan sinir ağlara bezir, bir sinir ağının tekrar eden hücresi vardır, ama tekrar eden hücre tek bir sinir ağı kapısına sahip olmak yerine, etkileşime giren 3 adet kapısı (Şekil 3.13) vardır (Babüroğlu vd., 2019).



Şekil 3.13. Bir uzun-kısa vadeli belleği hücresi (Babüroğlu vd., s. 3)

Bir LSTM hareketini tanımlayan kapılar; update (güncelleme), forget (unutma) ve output (çıkış) diye üçe ayırır. Burada $f^{<t>}$, $i^{<t>}$ ve $o^{<t>}$ t anındaki unutma, güncelleme ve çıkış kapıları, $c^{<t>}$, hücrenin durumu ve $a^{<t>}$, baştan sonuna kadar işlemlerin en sonda karar verilen bilgiyi belirtmektedir. Bir sigmoid(σ) fonsyonlu unutma kapısı (eşitlik 1) giriş ($x^{<t>}$) ve önceki hücre durumu ($a^{<t-1>}$) bilgisine bakarak bilginin unutulup veya unutulmamaya karar verir.

$$f^{<t>} = \sigma(W_f[a^{<t-1>}, x^{<t>}]) + bf \quad (3.11)$$

Bir sigmoid(σ) Fonsiyonlu güncelleme kapısı, var olan bilgilerinden hangisini güncelleneceğine karar verir.

$$i^{<t>} = \sigma(W_u[a^{<t-1>}, x^{<t>}]) + bu \quad (3.12)$$

Bir tan h fonksiyonu, hücre durumuna ($c^{<t>}$) ilave edilebilecek yeni hücre durumu aday bilgileri ($\tilde{c}^{<t>}$) (eşitlik 3) vektörünü meydana getirir.

$$\tilde{c}^{<t>} = \tan h(W_c[a^{<t-1>}, x^{<t>}]) + bc \quad (3.13)$$

Bu yüzden, var olan hücre durumu ($c^{<t>}$) (Eşitlik 3.14), önceki hücre durumundan ($\tilde{c}^{<t>}$) (Eşitlik 3.13) elde edilen bilgilerin yanında hücre tarafından üretilen mevcut bilgileri kullanılarak elde edilmiş olur.

$$c^{<t>} = i^{<t>} * \tilde{c}^{<t>} + f^{<t>} + c^{<t>} \quad (3.14)$$

Bir sigmoid (σ) fonksiyonlu çıkış kapısı (eşitlik 5) hücre durumunun hangi parçalarını üreteceğimize karar vermektedir. Sonradan hücre durumu ($c^{<t>}$) tan h fonksiyonu ile filtrelenip çıkış kapısının çıktısıyla çarpılır. Bu halde sadece karar verilen bilgilere ($a^{<t>}$) (eşitlik 6) erişir.

$$o^t = \sigma(W_o[a^{<t-1>}, x^{<t>}]) + b_o \quad (3.15)$$

$$a^{<t>} = o^{<t>} \tan h(c^{<t>}) \quad (3.16)$$

Normal LSTM ağları, serileri geçici sırayla işler, ilerideki bağlamı görmezden gelirler.

Bu üç yöntem ile elde edilen sonuçları değerlendirip modellerin performansları karşılaştırmak için kullanılan istatistiksel kriterleri; Ortalama Mutlak Hata (MAE), Korelasyon Katsayısı R ve Nash Sutcliffe Verimlilik (NSE) aşağıda açıklanmıştır.

Ortalama Mutlak Hata (MAE)

İki sürekli değişken arasındaki fark ölçüsüne MAE denir. MAE, her hakiki değer ile veriye en iyi şekilde uyan çizgi arasındaki ortalama dikey uzaklıktır. Bu değer aynı zamanda tüm veri noktaları ile en iyi uyan çizgi arasındaki ortalama yatay uzaklıktır. MAE değeri kolay bir şekilde yorumlanabilen bir değer olduğu için regresyon ve zaman serisi problemlerinde sık sık kullanılmaktadır. MAE değeri 0 ile ∞ arasında değer alır. Değeri ne kadar düşük ise o kadar iyi performans gösterdiği anlamına gelir (Celestin Vd., 2020).

Ortalama mutlak hata Fonksiyonu 3.17'de belirlenmiştir.

$$MAE = \frac{1}{n} \sum_j^n |X_i - Y_i| \quad (3.17)$$

Burada X_i Gerçek verilerin toplamı, Y_i tahmin edilmiş verilerin toplamı ve n ise toplam veri noktalarının sayısıdır.

Korelasyon Katsayısı (R)

Korelasyon katsayısı, deęişkenler arasındaki ilişkinin derecesi, yönünü ve önemini ortaya koyar. Yani, ilişkinin derecesi ve yönünü belirten katsayı korelasyon katsayısı diye adlandırılır. Korelasyon katsayısı R harf ile gösterilir ve $[-1, 1]$ arasında deęer alır. Bu deęer bir olduğunda, veri arasında mükemmel bir ilişki var, eksi bir olduğunda ters yönlü mükemmel bir ilişki var, sıfır olduğunda ilişki yok, 0,80 olduğunda aynı yönlü oldukça iyi bir ilişki var ve -0,60 olduğunda ters yönde orta bir ilişki var anlamına gelir (Jachner Vd., 2007).

Korelasyon katsayısı deęeri denklem 3.18'den elde edilir.

$$R = \frac{\sum(x_i - \bar{x})(Y_i - \bar{Y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(Y_i - \bar{Y})^2}} \quad (3.18)$$

Bu denklemde X_i gerçek verilerin toplamı, \bar{X} gerçek verilerin ortalaması, Y_i tahmin edilmiş verilerin toplamı \bar{Y} tahmin edilmiş verilerin ortalamasıdır.

Nash Sutcliffe Verimlilik (NSE)

NSE genellikle hidrolojik tahliye modellerin tahmin gücünü deęerlendirmek için kullanılır. Bu istatistiksel kriter $-\infty$ ile 1 arasında deęer alır. Gerçek ile tahmin edilmiş veriler arasında NSE verimlilik deęeri bir ise, mükemmel sonuçları elde edilmiş anlamına gelir. Eğer $NSE < 0$ ise tahmin edilmiş very gerçek veriden daha kesin bir şekilde tahmin edilmiş anlamına gelir (Moriasi Vd., 2007)

Bu kriteri ile deęerleri aşıęadaki denklemi kullanarak elde edilir.

$$NSE = 1 - \frac{\sum_{i=1}^n (x - y)^2}{\sum_{i=1}^n (x - \bar{x})^2} \quad (3.19)$$

Burada X_i gerçek verilerin toplamı \bar{X} gerçek verilerin ortalaması, Y_i tahmin edilmiş verilerin toplamıdır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1 İleri Beslemeli Sinir Ağı (FFNN) Tasarımı

Bu çalışmada, Fırat havzasının 4 istasyonun 30 yıllık (1981-2011) aylık akış verilerini kullanarak FFNN ile geleceğe ait aylık akım tahminleri yapılmıştır. Tahmin sürecinin hassasiyetini yükseltmek için verinin %70'i (1981-2002) eğitim ve %30'u (2002-2011) test diye ayrılmıştır. Modeli çalıştırmak için kullanılan kombinasyonları; bir Q_{t-1} , bir ve iki Q_{t-1} , Q_{t-2} ve bir, iki ve üç Q_{t-1} , Q_{t-2} , Q_{t-3} ay önceki akımları girdi olarak kullanılmıştır (Tablo 4.5). FFNN modelde aktivasyon fonksiyonu olarak doğrusal aktivasyon fonksiyonu seçilmiştir. Tasarlanan FFNN yöntemi, 3 tane gezli katman ve 10 nörondan oluşmaktadır ve. FFNN yöntemin geliştirilmesinde deneme bölümünde doğruluk oranı en yüksek ve hata oranı minimum olan sonuçlar 10 nöron ve 3 gezli katman için görülmüştür. Levenberg-Marguardt optimizasyonu modelin eğitim algoritması olarak kullanılmıştır. Eğitim süresi boyunca, çıktıların verilen sonuçlar ile devirlerin her yenilemesinde gereken değerler arasında fark (hata) en aza düşürecek şekilde ağırlıklar tekrar olarak belirlenmiştir. FFNN yöntemi kullanarak elde edilen sonuçları Tablo 4.1.'de gösterilmiştir

Tablo 4.1. Kullanılan 4 istasyon için FFNN yöntem ile elde edilen en yüksek istatistiksel kriterlerin değerleri

Kombinasyon	İstasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
Qt-1, Qt-2	eie_2102	7,870	0,864	0,999	8,970	0,742	0,999
Qt-1, Qt-2, Qt-3	eie_2122	0,711	0,885	1,000	4,405	0,862	0,991
Qt-1, Qt-2, Qt-3	eie_2124	0,048	0,939	1,000	0,086	0,794	0,999
Qt-1, Qt-2, Qt-3	eie_2131	0,079	0,722	0,996	0,089	0,811	0,939


FFNN yöntemi kullanarak eie_2102 istasyon test versisi için; Ortalama Mutlak Hata (MAE) değeri 8,970; Korelasyon Katsayısı (R) 0,742; Nash Sutcliffe Verimlilik (NSE) değeri 0,999 iken eie_2122 istasyon test versisi için; (MAE) değeri 4,405; (R) 0,862; (NSE) değeri 0,991, eie_2124 istasyonun için (MAE) değeri 0,086; (R) 0,794; (NSE) değeri 0,999 ve son olarak eie_2131 istasyon için; MAE değeri 0,089, R değeri 0,811 ve NSE değeri 0,939 olarak hesaplanmıştır. Elde edilen akım tahmin sonuçları ise Tablo

4.2’de verilmiştir. Bu yöntem genelde, girdi kombinasyonlarının aylık miktarı artınca model performanslarında yükselme meydana geldiği görülmüştür. Yani genelde (bir), (bir, iki) ve (bir, iki ve üç) ay önceki veriyi kombinasyon olarak kullanıldığında en iyi sonuçları bir, iki ve üç (Q_{t-1} , Q_{t-2} , Q_{t-3}) ay önceki veri kombinasyonu için elde edilmiştir. İkinci sırada en iyi performanslar bir, iki (Q_{t-1} , Q_{t-2}) üçüncü ise sadece bir (Q_{t-1}) ay önceki akım kombinasyonu girdi olarak kullanıldığında elde edilmiştir. En yüksek R değeri olan (eie_2122) istasyonun gözlenen ve tahmin edilmiş veri dağılım diyagramı Şekil 4.1’de ve gözlenen ile tahmin edilmiş veri arasındaki ilişki Şekil 4.2’de gösterilmiştir. Aynı istasyon için üç değişik kombinasyonu girdi olarak kullanıldığında elde edilen sonuçlar ise Tablo 4.2’de gösterilmiştir.


Akcakoca vd. (2020), Bektaş Deresi’nin günlük akım tahmini için geliştirilmiş Regresyon Sinir Ağı (GRNN) ve İleriye Beslemeli Sinir Ağı modelleri kullanmışlardır. Elde edilen sonuçları ise R ve MAE değerleri üzerinden yorumlamışlardır.

Tablo 4.2. FFNN ile elde edilen akım tahmin sonuçları (İstasyon eie_2122)

İstasyon	Kombinasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
eie_2122	Q_{t-1}	0,210	0,743	1,000	18,541	0,714	0,846
	Q_{t-1}, Q_{t-2}	15,613	0,740	0,898	24,256	0,783	0,736
	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	0,711	0,873	1,000	4,405	0,862	0,991



Şekil 4.1. Gözlenen ve tahmin edilmiş verinin dağılım diyagramı (İstasyon eie_2122)



Şekil 4.2. Gözlenen ve FFNN ile tahmin edilmiş veri arasındaki ilişki

4.2 Uyarlamalı Ağ abanlı Bulanık Çıkarım Sistemi (ANFIS) Tasarımı

Yapay Sinir Ağları gibi bu yöntem için de Fırat Havzasının 4 istasyonundan alınan 1981-2011 yılları arasındaki 30 yıllık veriye ANFIS modeli uygulanmıştır. Veriler %70'i eğitim ve %30'u test diye ayrılmıştır.

Bu modelde ANN'ye Bulanık Çıkarım Sistemi (FİS) ekleyip çeşitli üyelik fonksiyonların sonuçlarına bakmıştır. Kullanılan üyelik fonksiyonları [0,1] aralığı olmaktadır. FİS'i eğitmek için, Geri Yayılma (BP) yöntemi, uyarlanabilir bir ağın esas kuralı olan FİS'te parametre tanıma sorunu ile başa çıkmak için kullanılır. Bu modelde sigmoid ve doğrusal aktivasyon fonksiyonu kullanılmıştır. ANFIS yöntemi kullanıp R değeri en yüksek olan eie_2122 istasyon için elde edilen sonuçları Tablo 4.3'te gösterilmiştir.

Tablo 4.3. Kullanılan 4 istasyon için ANFIS yöntemi kullanarak elde edilen en yüksek olan istatistiksel kriterlerin değerleri

Kombinasyon	İstasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
Q _{t-1}	eie_2102	32,225	0,960	0,995	2,446	0,977	1,000
Q _{t-1}	eie_2122	1,146	0,986	0,999	1,2190	0,980	0,999
Q _{t-1}	eie_2124	0,024	0,980	1,000	0,575	0,944	0,995
Q _{t-1}	eie_2131	0,002	0,973	1,000	0,189	0,966	0,983

ANFIS yöntem uygulandığında eie_2102 istasyon test verisinin performans kriterleri; MAE değeri 2,446, R değeri 0,977 ve NSE değerin 1,000, iken eie_2122 istasyonun MAE değeri 1,2190, R değeri 0,980 ve NSE değeri 0,999, eie_2124 istasyonun; MAE değeri 0,575, R değeri 0,944ve NSE değeri 0,983 ve son olarak eie_2131 istasyonun MAE değeri 0,189, R değeri 0,966ve NSE değeri 0,983 olarak hesaplanmıştır.


FFNN gibi bu modeli çalıştırdığımızda da (bir) (bir, iki) ve (bir, iki ile üç) ay önceki veri kombinasyonları kullanılmıştır (Tablo 4.5). En iyi sonuçları sırasıyla bir (Q_{t-1}), bir, iki (Q_{t-1}, Q_{t-2}) ve bir, iki üç ($Q_{t-1}, Q_{t-2}, Q_{t-3}$) ay önceki kombinasyonları girdi olarak kullanıldığında elde edilmiştir.

ANFIS yöntemi ile en yüksek R değeri (eie_2122) istasyonundan alınan veriler ile elde edilmiştir. Tahmin edilen ve gözlenen veri dağılım diyagramı Şekil 4.3 ve tahmin edilen ve gözlenen veri arasındaki ilişki Şekil 4.4'te gösterilmiştir. Bu istasyon için üç farklı kombinasyonları girdi olarak kullanıldığında elde edilmiş sonuçları Tablo 4.4'te gösterilmiştir.


Carvalho vd. (2015), Destek Vektör Makinesi (SVM), Yapay Sinir Ağları (ANN) ve ANFIS yöntemleri kullanarak bir gün önceden akım tahminleri yapmıştır. Modellerin performansları karşılaştırmak için; Kök Ortalama Kare Hatası (RMSE), Nash Sutcliffe Verimlilik (NSE), Ortalama Mutlak Hata (MAE), Korelasyon Katsayısı (R), ve Ortalama Mutlak Bağlı Hata (MARE) istatistiksel kriterleri kullanılmıştır. Bu değerlendirmede; RMSE, MAE ve MARE değerlerin küçüklüğü ve NSE ile R değerlerin bire yakanlığına göre değerlendirme yapmışlardır.

Tablo 4.4. ANFIS ile elde edilen akım tahmin sonuçları (İstasyon eie_2122)

İstasyon	Kombinasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
eie_2122	Q_{t-1}	1,1464	0,9864	0,9994	0,026	0,983	0,999
	Q_{t-1}, Q_{t-2}	1,5853	0,3423	0,9990	4,898	0,202	0,991
	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	1,1239	0,3222	0,9995	3,160	0,285	0,996



Şekil 4.3. Tahmin edilmiş ve gözlenen verinin dağılım diyagramı (İstasyon eie_2122)



Şekil 4.4. Gözlenen ve ANFIS ile tahmin edilmiş veri arasındaki ilişki

Tablo 4.5. ANN ve ANFIS yöntemleri için kullanılan kombinasyonlar

Girdi	Ot(Tahmin)
Q_{t-1}	Ot(Tahmin)
Q_{t-1}, Q_{t-2}	Ot(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}$	Ot(Tahmin)

4.3 Uzun Kısa Vadeli Hafıza Ağları (LSTM) Tasarımı

Bu çalışmada uygulanmış olan LSTM modelinin gizli katmanı olmayıp sadece giriş ve çıkış katmanları vardır. LSTM yöntemi uygulayarak en iyi sonuçları elde etmek için çeşitli epochs (devirlerde) denenmiştir ve en iyi sonuçları sayısı 200 olduğunda elde edilmiştir. Modelde Adam, Adamax ve Nadam optimize edicileri kullanılarak; Doğrusal, Relu, Softsign, Sigmoid ve Tanh aktivasyon fonksiyonları denenmiştir. Konu edilen tüm aktivasyon fonksiyonları uygulanarak sonuçlara bakılmıştır ve genel olarak en iyi sonuçları Adamax optimize edici kullanıp Relu aktivasyon fonksiyon ile elde edilmiştir.

LSTM yöntemi uygulanarak; bir ay önceki (Q_{t-1}), bir ve iki ay önceki (Q_{t-1}, Q_{t-2}), bir, iki ve üç ay önceki ($Q_{t-1}, Q_{t-2}, Q_{t-3}$) ay önceki... ve bir, iki, üç, dört, beş, altı, yedi, sekiz, dokuz, on, onbir ve oniki ay önceki ($Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}, Q_{t-9}, Q_{t-10}, Q_{t-11}, Q_{t-12}$) akım kombinasyonları girdi olarak kullanıp hesaplamalar yapmıştır. Normalde geriye gidince performanslarıda yükselmenin meydana geldiğini görülmüştür ama eie_2124 istasyon için; bir, iki, üç, dört ve beş ay önceki ($Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$) akımların kombinasyonu girdi olarak kullanıldığında en yüksek R değeri elde edilmiştir (Tablo 4.7).

LSTM yöntemin kullanarak elde edilen istatistiksel kriterleri Tablo 4.6'da gösterilmiştir.

Tablo 4.6. LSTM yöntem kullanarak 4 istasyon için elde edilen en yüksek istatistiksel kriterlerin değerleri

Kombinasyon	İstasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
$Q_{t-1}, Q_{t-2}, \dots, Q_{t-11}$	eie_2102	1,066	0,946	1,000	2,169	0,855	1,000
$Q_{t-1}, Q_{t-2}, \dots, Q_{t-11}$	eie_2122	0,510	0,946	1,000	4,825	0,867	0,991
$Q_{t-1}, Q_{t-2}, \dots, Q_{t-5}$	eie_2124	0,001	0,773	1,000	0,133	0,884	0,998
$Q_{t-1}, Q_{t-2}, \dots, Q_{t-12}$	eie_2131	0,013	0,924	1,000	0,131	0,749	0,988

LSTM yönteminde eie_2102 istasyonun test verisi için; MAE değeri 2,169; R değeri 0,855 ve NSE değeri 1,000 olup on bir ay önceki veriyi girdi olarak kullanıldığında elde edilmiştir, eie_2122 istasyonun için de; MAE değeri 4,825, R değeri 0,867 ve NSE değerleri 0,991 on bir ay önceki veriyi girdi olarak kullanıldığında elde edilmiştir, üçüncüsü (eie_2124) istasyon için MAE değeri 0,133; R değeri 0,884 ve NSE değeri 0,998 olup beş ay öncek akımın veriyi girdi olarak kullanıldığında elde edilmiştir. Son

olarak eie_2131 istasyon için on iki ay önceki akım verileri girdi olarak kullanıldığında MAE değeri 0,131; R değeri 0,749 ve NSE değeri 0,998 olarak hesap edilmiştir.


LSTM yöntemini çalıştırmak için (bir) (bir, iki) ... ve (bir, iki... on iki) ay önceki veri girdi kombinasyonları Tablo 4.8’de göstermiştir.

LSTM yöntem ile en yüksek R değeri, (eie_2122) istasyonunundan alınan veriler ile elde edilmiştir. Tahmin edilen ve gözlenen veri dağılım diyagramı Şekil 4.5 ve tahmin edilen ile gözlenen veri arasındaki ilişki Şekil 4.6’de gösterilmiştir. eie_2122 istasyon için on iki farklı kombinasyon girdi olarak kullanılmış elde edilen sonuçlar Tablo 4.7’de gösterilmiştir.


Xu vd. (2020), Hun ve Yukarı Yangtze Nehirleri’nin günlük ve ortalama olarak on günlük akım tahmin için LSTM modeli uygulamışlardır. Performansını belirlemek için; R^2 , NSE ve RE istatistiksel kriterleri kullanmışlardır. Çalışmanın sonuçlarına bakıldığında; Bire yakın R^2 ve NSE değeri ve sıfıra yakın RE değerleri ile bu yöntemin akım tahmini için oldukça uygun bir yöntem olduğunu söylemişlerdir.

Tablo 4.7. LSTM ile elde edilen eie_2124 istasyonun akım tahmin sonuçları

İstasyon	Kombinasyon	Eğitim			Test		
		MAE	R	NSE	MAE	R	NSE
eie_2124	Q_{t-1}	0,830	0,835	0,925	0,830	0,835	0,925
	Q_{t-1}, Q_{t-2}	0,865	0,834	0,919	0,865	0,834	0,919
	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	0,498	0,871	0,973	0,498	0,871	0,973
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-4}$	0,010	0,881	1,000	0,010	0,861	1,000
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-5}$	0,133	0,773	0,998	0,133	0,884	0,998
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-6}$	0,848	0,833	0,920	0,848	0,833	0,920
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-7}$	0,378	0,833	0,983	0,378	0,833	0,983
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-8}$	0,468	0,806	0,981	0,468	0,806	0,981
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-9}$	0,056	0,794	1,000	0,056	0,794	1,000
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-10}$	0,082	0,820	0,001	0,082	0,820	0,001
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-11}$	0,412	0,802	0,980	0,412	0,802	0,980
	$Q_{t-1}, Q_{t-2}, \dots, Q_{t-12}$	1,748	0,722	0,642	1,748	0,722	0,642



Şekil 4.5. Gözlenen ve tahmin edilmiş verinin dağılım diyagramı (İstasyon eie_2124)



Şekil 4.6. Gözlenen ve LSTM ile tahmin edilmiş veri arasındaki ilişki (Test Verisi)

Tablo 4.8. LSTM yöntem için kullınılan kombinasyonlar

Girdi	Qt(Tahmin)
Q_{t-1}	Qt(Tahmin)
Q_{t-1}, Q_{t-2}	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}, Q_{t-9}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}, Q_{t-9}, Q_{t-10}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}, Q_{t-9}, Q_{t-10}, Q_{t-11}$	Qt(Tahmin)
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}, Q_{t-8}, Q_{t-9}, Q_{t-10}, Q_{t-11}, Q_{t-12}$	Qt(Tahmin)

Çalışmada kullanılan modellerin sonuçlarına bakıldığında genellikle ANFIS yöntem ile elde edilen R ile NSE değerleri FFNN ve LSTM'den yüksek, MAE değerinin ise düşük olduğu görülmektedir. Dolayısı ile bu durum ANFIS modelinin diğer modellerden daha iyi performans gösterdiği anlamına gelmektedir. ANFIS'ten sonra LSTM ile genellikle eie_2102, eie_2122 ve eie_2124 istasyonları için FFNN'den daha yüksek R ve NSE değeri daha düşük MAE değerleri elde edilmiştir. eie_2131 istasyonu için bunun tersi bir durum olduğu söylenebilir. Elde edilen sonuçlar Tablo 4.9'da gösterilmiştir.

Chowdhury vd. (2020), LSTM ve ANFIS yöntemleri kullanarak Bangladeş'teki COVID-19 pandemisinin tahmin analizini yapmışlardır. Modellerin performansları karşılaştırıldığında LSTM yönteminin performansı ANFIS yöntemine göre biraz daha kesin olduğu görülmüştür.

Ludwig (2019), sera gazı analizine uygulanan zaman serisi yaklaşımlarının karşılaştırılmak için ANFIS, RNN ve LSTM modelleri uygulamıştır. RNN yöntemine

göre ANFIS ve LSTM yöntemleri ile daha yüksek performans elde edilmiş olsa da LSTM ve ANFIS modellerinin performanslarının birbirlerine çok yakın olduğu görülmüştür.

Firat vd. (2010), aylık nehir akışı tahmini için ANFIS, FFNN ve geleneksel Otoregresif (AR) yöntemleri uygulamışlardır. Elde edilen sonuçlara göre ANFIS yönteminin en iyi sonuçları verdiğini görmüştür.

Literatürdeki çalışmalara bakılırsa LSTM yöntemleri, ANFIS yöntemlere göre biraz daha kesin sonuçlar verdiğini görülmektedir. Bu çalışmada LSTM yönteminin ANFIS yöntemine göre biraz daha düşük performansları gösterme sebebi, modelin mimarisinde gizli tabaka olmayıp sadece giriş ve çıkış tabakaların olmasıdır.

Bu çalışmada, literatürdeki çalışmalarına benzer olarak FFNN yönteminin sonuçları ANFIS ve LSTM modellerin sonuçlarından daha düşük olduğunu görülmüştür.

Tablo 4.9. eie_2131 İstasyon İçin FFNN ve LSTM Akım Tahmin Sonuçları

İstasyon	Model	Kombinasyon	Eğitim			Test		
			MAE	R	NSE	MAE	R	NSE
eie_2131	FFNN	Q _{t-1}	0,079	0,722	0,996	0,035	0,665	0,999
		Q _{t-1} , Q _{t-2}	0,048	0,719	0,999	0,015	0,754	1,000
		Q _{t-1} , Q _{t-2} , Q _{t-3}	0,021	0,674	1,000	0,089	0,811	0,938
	LSTM	Q _{t-1}	5,609	0,713	0,990	5,609	0,713	0,990
		Q _{t-1} , Q _{t-2}	0,115	0,701	0,992	0,115	0,701	0,992
		Q _{t-1} , Q _{t-2} , Q _{t-3}	0,140	0,636	0,988	0,140	0,636	0,988
		Q _{t-1} , Q _{t-2} ,..., Q _{t-4}	0,123	0,615	0,990	0,123	0,615	0,990
		Q _{t-1} , Q _{t-2} ,..., Q _{t-5}	0,099	0,632	0,993	0,099	0,632	0,993
		Q _{t-1} , Q _{t-2} ,..., Q _{t-6}	0,084	0,663	0,995	0,084	0,663	0,995
		Q _{t-1} , Q _{t-2} ,..., Q _{t-7}	0,074	0,592	0,996	0,074	0,592	0,996
		Q _{t-1} , Q _{t-2} ,..., Q _{t-8}	0,074	0,626	0,996	0,074	0,626	0,996
		Q _{t-1} , Q _{t-2} ,..., Q _{t-9}	0,115	0,601	0,991	0,115	0,601	0,991
		Q _{t-1} , Q _{t-2} ,..., Q _{t-10}	0,173	0,605	0,980	0,173	0,605	0,980
		Q _{t-1} , Q _{t-2} ,..., Q _{t-11}	0,013	0,709	1,000	0,013	0,709	1,000
Q _{t-1} , Q _{t-2} ,..., Q _{t-12}	0,131	0,748	0,988	0,131	0,748	0,988		

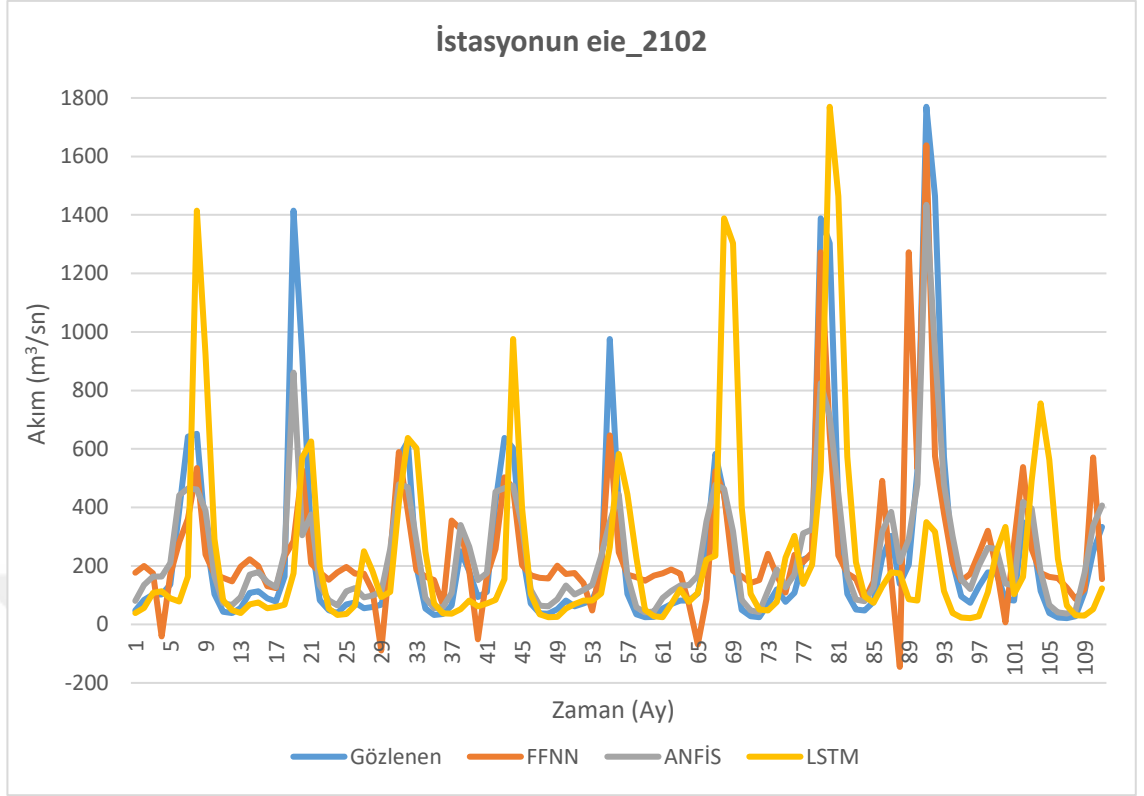
5. SONUÇLAR

Türkiye'nin en büyük havzalarından biri olan ayrıca Doğu ve Güneydoğu Anadolu Bölgelerini besleyen Fırat Havzası üzerine özellikle son yıllarda ulusal ve uluslararası birçok çalışma yapılmıştır. Diğer çalışmalardan farklı olarak, bu çalışmada Fırat Havzası'na ait geleceğe ait akım tahminleri yapmak için en etkili ve yaygın olarak kullanılan Yapay Zekâ (AI) yöntemlerden üç tanesi; İleriye Beslemeli Sinir Ağları (FFNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Uzun Kısa Vadeli Hafıza Ağları (LSTM) uygulanmıştır. Çalışmada MAE, R ve NSE performans değerlendirme ölçütleri kullanılarak modellerin performansları karşılaştırılmıştır,


Çalışma alanı olarak seçilen Fırat Havzası ve havzanın dört istasyonuna (eie_2102, eie_2122, eie_2124, ve eie_2131) ait veriler kullanılarak aylık akım tahminleri seçilen bu modeller üzerinden yapılmıştır. Bütün istasyonlarda akım tahmini için, sadece geçmiş ayların akış verilerinin değişik kombinasyonları girdi olarak kullanılarak tahmin modelleri geliştirilmiştir. Akış tahmininde, veriyi eğitim ve test kümelerine bölmeye bölündüğünde modellerin davranışları daha etkili olduğu bilinmektedir dolayısıyla veri %70 eğitim verisi ve %30 test verisi olarak ayrılmıştır, Adı geçen modeller uygulanarak bu verilerden elde edilen sonuçlardan test verisi değerlendirmeye alınmıştır.

Çalışmanın sonunda elde edilen sonuçlara bakıldığında genel olarak ANFIS yöntemi ile en iyi tahmin sonuçlarına ulaşılmıştır. ANFIS'ten sonra sadece girdi ve çıktı tabakalı LSTM yöntem çoğu istasyonlar için ikinci derecede yüksek performans göstermiştir. ANFIS ve LSTM yöntemlerden sonra FFNN yöntem üçüncü sırada iyi sonuç vermiştir. Bu yöntemler ile elde edilen test sonuçlarının dört farklı istasyon için uygulanan bütün modeller için gözlenen ve tahmin edilmiş veri arasındaki ilişkiler Şekil 5.1, 5.2, 5.3 ve 5.4'te göstermiştir.


Son olarak, bu tez çalışmasının sonucundan yola çıkarak ANFIS, LSTM ve FFNN yöntemleri kullanarak aylık akım tahmini daha kesin bir şekilde yapılabilir bir sonuç elde edilmiştir,




Şekil 5.1. Tahmin edilmiş ve gözlenen veri arasında İlişki (test)



Şekil 5.2. Tahmin edilmiş ve gözlenen veri arasında ilişki (test)



Şekil 5.3. Tahmin edilmiş ve gözlenen veri arasında ilişki (test)



Şekil 5.4. Tahmin edilmiş ve gözlenen veri arasında ilişki (test)

KAYNAKLAR

- Acar, O. C. (2019) “Akış Verisinde Anormallik Tespiti”, Yüksek Lisans Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, 1–137.
- Akcakoca, F. and Apaydın, H. (2020) “Modelling of Bektas Creek Daily Streamflow with Generalized Regression Neural Network Method”, *International Journal of Advances in Scientific Research and Engineering*, 6(2), 97-103.
- Ahmadlou, M., Karimi, M., Alizadeh, S., Shirzadi, A., Parvinnejhad, D., Shahabi, H. and Panahi, N. (2018) “Flood susceptibility assessment using integration of adaptive network-based fuzzy inference system (ANFIS) and biogeography-based optimization (BBO) and BAT algorithms (BA)”, *Geocarto International Journal*, 1252–1272.
- Altunparmak, A., Başakın, E.B. (2018) “Zaman Serileri Kullanılarak Nehir Akım Tahmini ve Farklı Yöntemlerle Karşılaştırılması”, *Journal of Science and Technology*, 11(1), 92-101.
- Adnan, R. N., Yuan, X., Kisi, K., Yuan, Y. (2017) “Streamflow Forecasting Using Artificial Neural Network and Support Vector Machine Models”, *Technology and Sciences (ASRJETS)*, 29(1) 286–294.
- Altıparmak, B. (2008) “Fırat Havzası Taşkın Mevsimselliğinin Belirlenmesi”, Yüksek Lisans Tezi, **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi**, 1-82.
- Buraghoain, M. (2008) “Adaptive Network based Fuzzy Inference System (ANFIS) as a Tool for System Identification with Special Emphasis on Training Data Minimization”, Master Thesis, **Department of Electronics and Communication Engineering Indian Institute of Technology Guwahati Guwahati**, 1-122.
- Brownlee, J. (2017) Long Short-Term Memory Networks With Python, *Machine Learning Mastery* (1), 1-229.
- Bayır, F. (2006) “Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama”, Yüksek Lisans Tezi, **İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı**, 1-122.
- Bengio, Y., Simard, P., and Frasconi, P. (1994) “Learning long-term dependencies with gradient descent is difficult”, *IEEE Transactions On Neural Networks*, 5(2), 157–166.
- Babüroğlu, B., Tekerek, A., Tekerek, M. (2019) “Türkçe İçin Derin Öğrenme Tabanlı Doğal Dil İşleme Modeli Geliştirilmesi”, **Kahramanmaraş Sütçüimam Üniversitesi, Enformatik Anabilim Dalı**, 1-8.
- Chowdhury, A.A., Hasan, K.T., Hoque, K.K.S. (2020) “Analysis and Prediction of COVID-19 Pandemic in Bangladesh by using Long short-term memory network (LSTM) and Adaptive neuro-fuzzy inference system (ANFIS)”, *Research Square*, 1–10.

- Celestin, S., Qi, F., Li, R., Yu, T., Cheng, W. (2020) “Evaluation of 32 Simple Equations against the Penman–Monteith Method to Estimate the Reference Evapotranspiration in the Hexi Corridor, Northwest China”, *Water Journal*, 12(10), 1-22.
- Calp, M. H. (2018) “An Estimation of Personnel Food Demand Quantity for Businesses by Using Artificial Neural Networks”, *Journal Of Polytechnic*, 22(3), 675-686.
- Carvalho, J.P., Camelo, F. V. (2015) “ROne Day Ahead Stream Flow Forecasting”, *Instituto Superior Técnico, Universidade de Lisboa, Portugal*, 1169-1175.
- Chang, L.C., Chang, F. J. (2001) “Intelligent control for modelling of real-time reservoir operation”, *Hydrological Processes*, 15(9) ,1621-1634.
- Changchun, X., Yaning, C., Weihong, L., Yapeng, C. (2010) “Climate change and hydrologic process response in the Tarim River Basin over the past 50 years”, *Chinese Science Bulletin*, 51(1), 25-36.
- Damavandi, H.R., Shah, R., Stampoulis, D., Wei, Y., Boscovic, D. and Sabo, J (2019) “Accurate Prediction of Streamflow Using Long Short-Term Memory Network”, *International Journal of Environmental Science and Development*, 10(10), 294–300.
- Doğan, H.B. (2019) “Beklenmedik Uçak Yönlendirmelerini Azaltma: Zaman Serisi Analizi ve Yapay Sinir Ağları ile Modelleme”, Yüksek Lisans Tezi, *Tobb Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü*, 1-69.
- Doğan, F., Türkoğlu, İ. (2019) “Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme”, *DÜMF mühendislik dergisi*, 10(2), 409-445.
- Dölling, O.R. (2002) “Artificial Neural Networks for Streamflow Prediction”, *Technology, and Sciences (ASRJETS)*, 40(5), 547–555.
- Dursun, D. (2006) “Sınırtaşan Sular Fırat ve Dicle Nehirlerinin, Türkiye, Suriye ve Irak İlişkileri Üzerine Etkileri”, Yüksek Lisans Tezi, *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Uluslararası İlişkiler Anabilim Dalı*, 1-187.
- EİE. (2003) “Su Akımları Aylık Ortalamaları”, *Elektrik İşleri Etüt İdaresi Genel Müdürlüğü*, 671s, Ankara.
- Ekinci, B. (2015) “Su Kaynaklarının Verimli Kullanılmasına Yönelik Örnek Ülke Uygulamaları ve Ülkemizde Bu Çalışmaların Uygulanabilirliği”, Uzmanlık Tezi, *Orman ve Su İşleri Bakanlığı*, 1–134.
- Bozkurt, N. (2017) “Uydu Verilerine Ve Yapay Sinir Ağlarına Dayalı Olarak Bitki Örtüsü Tahmini Ve Analizi”, Yüksek Lisans Tezi, *İstanbul Aydın Üniversitesi Fen Bilimler Enstitüsü*, 1-53.
- Firat, M. (2007) “Comparison of Artificial Intelligence Techniques for river flow forecasting”, *Hydrology and Earth System Sciences*, (12), 123–139.

- Firat, M. (2007) “Comparison of Artificial Intelligence Techniques for river flow forecasting”, *Hydrology and Earth System Sciences*, 123–139.
- Guppy, N. İ. (2010) “Binalarda Su Korunumu”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 1–109.
- Garbero, A., Muttarak, R. (2013) “Impacts of the 2010 Droughts and Floods on Community Welfare in Rural Thailand: Differential Effects of Village Educational Attainment”, *Ecology and Society*, 18(4), 27-45.
- Güldal, V., Tongal, H. (2009) “Comparison of Recurrent Neural Network, Adaptive Neuro-Fuzzy Inference System and Stochastic Models in Eğirdir Lake Level Forecasting”, *Water Resour Manage*, 24(1), 105-128.
- Haykin, S. (1999) “Neural networks: a comprehensive foundation (2nd edn)”, *London Prentice Hall*, 281-323
- Harmancıoğlu, N. B., Gül, A. ve Fıstıkoğlu, O. (2002) “Entegre Su Kaynakları Yönetimi”, *Türkiye Mühendýslyk Haberler*, 419, 29–39.
- Hochreiter, S., Schmidhuber, J. (1997) “Long Short-Term Memory”, *Neural Comput*, 9(8), 1735–1780.
- Hu, Y., Yan, L., Hang, T. (2019) “Stream-Flow Forecasting of Small Rivers Based on LSTM”, *Proceedings of the 13th International Conference on Ubiquitous Information Management and Communication (IMCOM)*, 1006-1014.
- Hien Le, X., Viet Ho, H., Lee, G. and Jung, S. (2019) “Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting”, *Water Journal*, 11(7), 1–19.
- Jang, J. (1993) “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, *IEEE*, 23(3), 665-685.
- Jachner, S., Boogaart, K., G. and Petzoldt, T. (2007) “Statistical Methods for the Qualitative Assessment of Dynamic Models with Time Delay (R Package qualV)”, *Journal of Statistical Software*, 22(8) 1-30.
- Kara, T., Gürel, C. (2013) “Farklı Su Derinliklerinin Çeltik Verimine Etkisi”, *Anadolu Tarım Bilim, Derg*, 28(2), 82-86.
- Keskin, E., Taylan, T., Terzi, Ö. (2010) “Adaptive neural-based fuzzy inference system (ANFIS) approach for modelling hydrological time series”, *Hydrological Sciences Journal*, 51(4), 588-598.
- Khazae Poul, A., Shourian, M., Ebrahimi, H. (2019) “A Comparative Study of MLR, KNN, ANN and ANFIS Models with Wavelet Transform in Monthly Stream Flow Prediction”, *Springer*, 2907–2923.

- Koç, C. (2018) “Entegre Havza Yönetiminde Su Kaynaklarını Modern Yöntemler ile Ölçme, İzleme ve Değerlendirme Olanaklarının Araştırılması”, *European Journal of Science and Technology*, (14), 222-227.
- Kutlu, H. (2018) “Biyostatistik Temelli Bilimsel Araştırmalarda Derin Öğrenme Uygulamaları”, Yüksek Lisans Tezi, *Yakındoğu Üniversitesi Sağlık Bilimleri Enstitüsü*, 1-66.
- Kratzert, F., Klotz, D., Brenner, C., Shculz, K. and Herrnegger, M. (2018) “Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks”, *Hydrology and Earth System Sciences*, 6005-6022.
- Kaya, H. (2018) “Akçğğ Hastalıkları Teğğsgnde Sınıflandırma Ve Bulanık Mantık Yöntemlerğğn Uygulanması”, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, 1-99.
- Kang, K.W., Park, C.Y., Kim, J. H. (1992) “Neural network and its application to rainfall-runoff forecasting”, *Korean Journal of Hydroscience*, 1-9.
- Ludwig, S.A. (2019) “Comparison of Time Series Approaches applied to Greenhouse Gas Analysis: ANFIS, RNN, and LSTM”, *IEEE*, 1-6.
- Moriasi, D., N, Arnold, J., G, Van Liew, M., W, Bingner, R., L, Harmel, R., D and Veith, T., L (2007) “Model Evaluation Guidelines For Systematic Quantification Of Accuracy In Watershed Simulations”, *ASABE*, 50(3), 885 – 900.
- Memiş, G. (2019) “İnsan Sağlığı Takibi İçin Giyilebilir Sensör Verilerinin Çok Kipli ve Füzyon Tabanlı Analizi”, Yüksek Lisans Tezi, *Başkent Üniversitesi Fen Bilimleri Enstitüsü*, 1-100.
- Mohd, N., Kashif, H. (2016) “A Review of Training Methods of ANFIS for Applications in Business and Economics”, *Research Gate*, 9(7), 165-172.
- Önöz, B. 2015 “Ölçüm Olmayan Havzalarda Akım Tahmin Yöntemi”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi, Türkiye Ulusal Hidroloji Toplantısı*, 1 – 118.
- Öztemel, E. (2003) “Yapay Sinir Ağları”, *Papatya Yayıncılık Eğitim*, 11(3), 1-44.
- Partal, T., Kâhya, E. and Cıgızoğlu, K. (2008) “Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini”, *İTÜ İnşaat Fakültesi, İnşaat Mühendisliği Bölümü*, 7(3), 73-85, Ayazağa, İstanbul.
- Patel, D., Parekh, F. (2014) “Flood Forecasting using Adaptive Neuro-Fuzzy Inference System (ANFIS)”, *IJETT*, 12(10), 510-514.
- Sak, H., Senior, A., Beaufays, F. (2014) “Long Short-Term Memory Recurrent Neural Network Architectures for Large Scale Acoustic Modeling”, *Interspeech*, 338-342.

- Dođan, S. (2013) “Konya Kapalı Havzası Kuraklık Karakterizasyonunun Zamansal Konumsal Analizi”, Doktora Tezi, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü*, 1-187.
- Sanikhani, H., Kisi, O. (2012) “River Flow Estimation and Forecasting by Using Two Different Adaptive Neuro-Fuzzy Approaches”, *Springer*, 1715-1729.
- Solaimani, K. (2009) “Rainfall-runoff Prediction Based on Artificial Neural Network”, *American-Eurasian J, Agric, & Environ, Sci*, 5(6), 856-865.
- Sanchez, İ., Pena, D. (2001) “Properties of Predictors in Overdifferenced Nearly Nonstationary Autoregression”, *Journal of Time Series Analysis*, 22(1), 45-66.
- Şahin, L., Anderson, K. (2017) “Global Water Crisis”, *United Nations University Institute for Water, Environment and Health*, 1–12.
- Tosunođlu, F., İspirli, M. N., Gürbüz, F. and Şengül, S. (2017) “Fırat Havzası’ndaki Eksik Akım Verilerinin Debi Süreklilik Çizgileri ve Regresyon Modelleri ile Tahmin Edilmesi”, *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(4), 85–94.
- T.C Kalkınma Bakanlığı. (2014) “Su Kaynakları Yönetimi ve Güvenliđi,” Özel **İhtisas Komisyonu Raporu**, 1–72, Ankara.
- Taylan, E. D., (2008) “Akdeniz Bölgesindeki Akımların Tahmini İçin Akıllı Sistemlerin Uygulanması”, Doktora Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, 1-168.
- Tsoukalas, L. H., Uhrig, R.E. (1996) “Fuzzy and Neural Approaches in Engineering”, *Wiley-Interscience; 1st Edition*, 1-587.
- Thapa, D., Zebin, Z., Li, B., Lu, L., Fu, D., Shi, X., Tang, B., Qi, H. (2020) “Snowmelt-Driven Streamflow Prediction Using Machine Learning Techniques (LSTM, NARX, GPR, and SVR)”, *Water Journal*, 12(6), 1-18.
- Üney, İ. (2017) “Modern ve Klasik Optimizasyon Yöntemlerinin Entomolojide Yeni Bir Uygulaması”, Yüksek Lisans Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, 1-35.
- Wilhite, D. A., Glantz, M. (1987) “Understanding: the Drought Phenomenon: The Role of Definitions”, *WATER INT*, 10(3),111-120.
- Wu, Y., Liu, Z., Xu, W., Feng, J., Palaiahnakote, S., Lu, T. (2020) “Context-Aware Attention LSTM Network for Flood Prediction”, *IEEE Xplore*, 1301–1306.
- Wu, Y, Liu, Z, Xu, W, Feng, J, Palaiahnakote, S., Lu, T, (2020) “Context-Aware Attention LSTM Network for Flood Prediction”, *IEEE Xplore*, 1301-1306,
- Yakıt, O., Özkan, Y. (2017) “Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Deđerlendirilmesi Yaklaşımı”, *Research Journal Of Polttics, Economics And Management*, 5(2), 287-296.

- Yaseen, Z. M., El-Shafie, A., Afan, H. A., Hameed, M., Wan Muhtar, W. H. M. and Hussain, A. “2015”, RBFNN versus FFNN for daily river flow forecasting at Johor River, *Malaysia, neural comput & applic*, 1533–1542.
- Yakıt, O. ve Özkan, Y. (2017) “Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Değerlendirilmesi Yaklaşımı”, *PESA*, 5(2), 287-296.
- Yaşar, M. (2004) “Günlük Akıřlardaki Bořlukların Yapay Sinir Ağları Kullanılarak Tamamlanması”, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, 1–97.
- Yenigün, K. ve Gümüő, V. (2007) “Fırat Havzası Akımlarında Görülen Trendlerin Nedenlerinin Arařtırılması”, *Ulusal Hidroloji Kongresi Orta Doęu Teknik Üniversitesi*, 239-248.
- Yaşar, M. (1942) “Günlük Akıřlardaki Bořlukların Yapay Sinir Ağları Kullanılarak Tamamlanması”, Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, 278-292.
- Zaifoęlu, H., (2013) “Fırat Akarsu Havzası İçin Topoęrafik ve Hidrometeorolojik Veriye Dayanan Taban Akıřı Ayırma Model”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 1–71.

EKLER

Ek-1. Tüm modeller ile eie_2102 istasyon için elde edilmiş sonuçlar

Gözlünen	FFNN	ANFIS	LSTM
47,616	176,430	80,188	39,093
83,223	199,836	135,354	56,135
102,855	174,446	164,019	107,327
102,539	-41,558	163,568	113,548
136,418	170,067	210,140	89,516
391,097	281,558	441,540	78,086
642,467	360,616	464,467	163,161
651,548	535,169	461,475	1414,633
308,167	239,587	389,196	923,484
103,181	171,539	164,485	291,433
43,129	159,623	72,945	82,590
39,093	147,198	66,375	49,181
56,135	197,483	93,759	38,363
107,327	223,182	170,374	68,713
113,548	199,831	179,108	75,503
89,516	130,313	144,678	55,561
78,086	124,416	127,648	59,703
163,161	233,000	244,285	67,321
1414,633	283,988	861,161	174,526
923,484	527,620	304,505	570,633
291,433	209,034	375,940	625,355
82,590	177,755	134,409	197,357
49,181	152,862	82,699	53,626
38,363	177,741	65,181	32,023
68,713	196,869	113,368	35,077
75,503	173,094	123,741	65,148
55,561	173,096	92,852	250,497
59,703	114,609	99,374	181,161
67,321	-89,762	111,223	93,948
174,526	232,487	258,096	111,431
570,633	589,271	478,746	416,926

Ek-2. Tüm modeller ile eie_2122 istasyon için elde edilmiş sonuçlar

Gözlenen	FFNN	ANFIS	LSTM
12,026	24,574	19,659	5,602
18,323	20,670	28,983	8,577
16,616	7,749	26,502	16,105
14,123	12,425	22,816	18,795
17,939	15,576	28,428	20,233
30,255	54,081	45,358	15,410
123,193	116,578	115,029	28,269
114,639	159,026	112,895	123,094
71,220	71,051	88,697	226,660
25,690	16,988	39,294	85,117
7,243	4,468	12,260	17,808
5,453	9,548	9,422	7,921
11,695	21,523	19,156	7,815
18,020	25,134	28,546	15,408
18,213	18,900	28,825	21,619
15,235	11,124	24,470	14,437
14,900	11,758	23,973	12,484
16,052	6,954	25,675	12,119
248,680	142,937	130,916	19,961
209,742	168,556	130,325	188,772
65,570	24,676	83,904	144,353
11,530	14,664	18,904	46,946
9,379	6,319	15,598	6,748
8,191	21,310	13,748	7,793
15,887	32,460	25,432	10,002
17,250	21,556	27,428	14,237
11,761	5,249	19,256	21,382
9,855	8,268	16,334	26,189
11,197	20,816	18,396	13,079
30,274	48,042	45,383	13,235
127,447	139,737	115,768	70,295
162,203	144,268	119,583	207,871


Ek-3. Tüm modeller ile eie_2124 istasyon için elde edilmiş sonuçlar

Gözlenen	FFNN	ANFIS	LSTM
10,216	10,914	8,351	18,126
9,827	10,205	8,060	15,760
9,500	9,131	7,359	13,077
9,171	9,521	20,012	11,910
8,493	16,691	11,672	10,008
18,126	21,767	7,292	8,706
15,760	16,195	8,143	8,385
13,077	12,333	8,429	9,501
11,910	10,370	7,925	9,207
10,008	8,810	7,410	8,221
8,706	9,167	8,526	8,088
8,385	10,147	7,755	8,250
9,501	9,442	6,991	8,282
9,207	8,399	7,367	17,630
8,221	8,318	7,760	11,113
8,088	7,275	7,410	8,973
8,250	6,909	18,313	8,061
8,282	8,542	9,627	7,474
17,630	10,922	8,308	7,913
11,113	9,194	7,163	8,029
8,973	8,065	6,788	7,852
8,061	7,587	8,498	7,250
7,474	8,147	7,672	6,715
7,913	8,336	7,258	6,727
8,029	8,140	6,727	6,904
7,852	7,455	6,792	16,400
7,250	6,882	7,405	10,719
6,715	3,594	7,564	9,600
6,727	5,262	14,021	7,581
6,904	12,271	8,459	7,300
16,400	10,573	8,459	6,717
10,719	9,428	6,322	7,361


Ek-4. Tüm modeller ile eie_2131 istasyon için elde edilmiş sonuçlar

Gözlenen	FFNN	ANFIS	LSTM
1,161	1,685	1,366	1,088
1,124	1,743	1,363	1,018
1,117	0,689	1,355	0,939
1,125	1,211	1,364	0,858
1,473	1,671	1,742	0,919
6,690	6,055	2,982	2,389
7,883	5,315	3,856	5,123
2,995	3,321	2,775	2,574
1,772	2,260	2,032	1,420
1,379	2,039	1,644	0,997
1,225	1,483	1,477	0,860
1,062	1,733	1,291	0,685
1,135	1,500	1,375	0,658
0,984	0,850	1,200	0,703
0,758	1,401	0,931	0,868
0,915	1,459	1,119	0,852
0,849	3,030	1,041	0,920
2,429	2,858	2,533	1,549
5,514	5,719	2,458	4,316
3,555	1,653	2,787	4,808
1,095	1,492	1,329	1,122
0,984	1,147	1,200	1,090
0,829	0,894	1,017	0,708
0,706	1,110	0,868	0,612
0,745	0,903	0,915	0,638
0,663	0,589	0,815	0,580
0,528	0,102	0,645	0,719
0,565	1,150	0,692	0,755
0,562	0,441	0,688	0,856
1,637	3,161	1,906	1,912
5,027	3,268	2,246	5,238
2,257	2,262	2,422	1,837
1,324	1,285	1,585	1,076


Ek-5. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2122)




Ek-6. Gözlenen ve FFNN ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim)




Ek-7. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2122)




Ek-8. Gözlenen ve ANFIS ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim)



Ek-9. Gözlenen ve Tahmin Edilmiş Verinin Dağılım Diyagramı (İstasyon eie_2124)



Ek-10. Gözlenen ve LSTM ile Tahmin Edilmiş Veri Arasındaki İlişki (Eğitim)



Ek-11. Tez Çalışması Süresince Yapılan Akademik Çalışma

Nazimi, N., Ertugay, N. (2020) “FFNN, ANFIS, ve LSTM Modelleri Kullanarak Fırat havzasının Aylık Akış Tahmini”, **2. Uluslararası 30 Ağustos Bilimsel Araştırmalar Kongresi**, ANKARA 28-30 Ağustos, 220.



ÖZGEÇMİŞ

Nazim NAZİMİ, 1993 yılında Afganistan'nın Paktya ilinde doğdu. İlk ve orta okulu Paktya ilin Aryoob ilçesinde yer alan 'De Bayankhilo Lise'sinde, liseyi ise aynı il aynı ilçenin 'De Aryoob Lise' sinde 2012 yılında tamamladı. 2013'da Afganistan Devlet burslusu olarak Türkiye'ye gelip, Türkçe Dil Hazırlığına (TÖMER) Trabzon'da başladı. Ardından 2014'de Erzincan Binali Yıldırım Üniversitesi'nde (EBYÜ) İnşaat Mühendisliği Bölümü lisans eğitimi başlayıp 2018'de tamamladı. 2018'den beri EBYÜ Fen Bilimler Enstitüsü İnşaat Mühendisliği Anabilim Dalı'nda Yüksek Lisans eğitimi sürdürmektedir. 2019-2020 öğrenim yıl boyunca Technical University of Cluj Napoca Üniversitesin'ne erasmus+ program için gönderildi.

Mail: nazimzazai20@gmail.com

Tel: +905353010483