

ESKİŞEHİR
ANADOLU ÜNİVERSİTESİ



BİLECİK
ŞEYH EDEBALI ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Ana Bilim Dalı

NEHİR AKIŞININ YAPAY ZEKA VE TREND ANALİZİ
METOTLARI İLE TAHMİNİ

Ali YILDIRAN
Yüksek Lisans

Tez Danışmanı
Doç. Dr. Süheyla YEREL KANDEMİR

BİLECİK 2019
Ref. No. : 10283422



**ESKİŞEHİR
ANADOLU ÜNİVERSİTESİ**



**BİLECİK
ŞEYH EDEBALI ÜNİVERSİTESİ**


**Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Ana Bilim Dalı**

**NEHİR AKIŞININ YAPAY ZEKA VE TREND ANALİZİ
METOTLARI İLE TAHMİNİ**

**Ali YILDIRAN
Yüksek Lisans**

**Tez Danışmanı
Doç. Dr. Süheyla YEREL KANDEMİR**

BİLECİK, 2019



ESKİŞEHİR
ANADOLU UNIVERSITY



BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ
BİLECİK
ŞEYH EDEBALI UNIVERSITY

Graduate School of Sciences
Department of Civil Engineering

**ESTIMATION OF RIVER FLOW BY USING THE
ARTIFICIAL INTELLIGENCE AND TREND ANALYSIS
METHODS**

Ali YILDIRAN
Master's Thesis

Thesis Advisor
Doç. Dr. Süheyla YEREL KANDEMİR

BİLECİK, 2019



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS
JÜRİ ONAY FORMU

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun 19/07/2019 tarih ve 38-06 sayılı kararıyla oluşturulan jüri tarafından 05/08/2019 tarihinde tez savunma sınavı yapılan Ali YILDIRAN'ın "Nehir Akışının Yapay Zeka ve Trend Analizi Metotları ile Tahmini" başlıklı tez çalışması İnşaat Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS tezi olarak oy birliği ile kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Doç. Dr. Süheyla YEREL KANDEMİR

ÜYE : Doç Dr. Özgür AVŞAR (JÜRİ BAŞKANI)

ÜYE : Doç. Dr. Mustafa Özgür YAYLI

ONAY

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun .../.../..... tarih ve/..... sayılı kararı.

İMZA/ MÜHÜR

TEŐEKKÖR

Bu tez alıřmamda benden desteęini hibir zaman esirgemeye aileme ve öęrenim hayatım boyunca tavsiyeleri ile beni yönlendiren saygı deęer hocam Do. DR. Süheyla YEREL KANDEMİR' e sonsuz teşekkürlerimi sunuyorum.



BEYANNAME

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kılavuzu'na uygun olarak hazırladığım bu tez çalışmada, tez içindeki tüm verileri akademik kurallar çerçevesinde elde ettiğimi, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun olarak sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu Üniversite veya başka bir üniversitede herhangi bir tez çalışmada kullanılmadığını beyan ederim.

...../...../ 2019

Ali YILDIRAN

ÖZET

Bu çalışmada akım gözlem istasyonları tarafından ölçümü yapılamamış akım verilerinin tespiti edilmesi için tahmin modelleri geliştirmek amacıyla yapay zeka ve istatistik yöntemleri kullanılmıştır. Yapay zeka yöntemleri; genellikle programlama dilleriyle geliştirilen ve bilgisayar sistemlerinin öğrenme algoritmaları sayesinde datalar üreten yöntemlerdir. İstatiksel yöntemler ise; temeli matematiksel ifadeler ve matematiksel modellemelere dayanan yöntemler olarak ifade edilmektedir.

Sakarya havzasının alt havzası olan Porsuk havzasında yer alan 10 akım gözlem istasyonu ile Eskişehir ilinde ölçüm yapan yağış gözlem istasyon verileri çalışmada kullanılmıştır. Temin edilen verilerle tahmin modelleri geliştirilmiştir. Bu modeller; Bir yapay zeka yöntemi olan yapay sinir ağlarının ileri beslemeli geri yayılım yöntemi, bir diğer yapay zeka yöntemi olan evrimsel algoritmanın gen ifade programlama yöntemi ve parametrik bir trend analizi metodu olan çoklu doğrusal regresyon yöntemiyle oluşturulmuştur. İleri beslemeli geri yayılım ağı; bir yapay sinir ağı yöntemidir.

Farklı değerler ve farklı eğitim girdileriyle hazırlanan modellerden elde edilen sonuçların; belirlilik katsayısı, ortalama karesel hata ve ortalama karesel hatanın karekökü değerlerine bakılarak başarıları kıyaslanmıştır.

Çalışma sonuçları incelendiğinde en iyi veri tahmin modellerini ileri beslemeli geri yayılım sinir ağının ürettiği görülmüştür. Gen ifade programlama yöntemi tahmin verileri oluşturmada ileri beslemeli geri yayılım yönteminden daha başarısız olmuştur. En başarısız sonuçlar çoklu doğrusal regresyon yöntemiyle elde edilmiştir. Çalışmada en başarısız sonuçları çoklu doğrusal regresyon yöntemi vermiştir. Sonuç olarak; ileri beslemeli geri yayılım sinir ağı; ölçülememiş ya da tahmin edilmek istenen akım değerlerini başarıyla tahmin edebilmiş ve hidrolik çalışmalarında kullanılabilir olduğunu göstermiştir.

Anahtar Kelimeler: Yapay Sinir Ağları; Gen İfade Programlama; Çoklu Doğrusal Regresyon; Hidrolojik Modelleme

ABSTRACT

In this study, artificial intelligence and statistical methods were used to develop estimation models for the determination of current data which could not be measured by current observation stations. Artificial intelligence methods; they are generally developed in programming languages and produce data by means of learning algorithms of computer systems. Statistical methods; It is expressed as methods based on mathematical expressions and mathematical modeling.

10 flow monitoring stations in the Porsuk basin, which is the lower basin of Sakarya basin and rainfall observation station data in Eskişehir province were used. Estimation models have been developed with the obtained data. These models; The forward feed back propagation method of artificial neural networks, which is an artificial intelligence method, is formed by the gene expression programming method of another artificial intelligence method and the multiple linear regression method which is a parametric trend analysis method. Forward feed back propagation network; is an artificial neural network method.

The results obtained from the models prepared with different values and different educational inputs; coefficients of determination, mean square error and square root of mean square error were compared.

When the results of the study were examined, it was seen that feed back propagation neural network produced the best data prediction models. Gene expression programming method failed to generate prediction data more than feed back feed propagation method. The most unsuccessful results were obtained by multiple linear regression method. The most unsuccessful results were obtained by multiple linear regression method. As a result; forward-feed back propagation neural network; It was able to successfully estimate the current values that could not be measured or wanted to be estimated and showed that it could be used in hydraulic works.

Keywords: Neural Network; Gene Expression Programming; Multiple Linear Regression; Hydrological Modeling

İÇİNDEKİLER

Sayfa No

TEŞEKKÜR	
BEYANNAME	
ÖZET.....	I
ABSTRACT	II
İÇİNDEKİLER	III
ŞEKİLLER DİZİNİ	V
ÇİZELGELER DİZİNİ	X
SİMGELER ve KISALTMALAR DİZİNİ	XII
1.GİRİŞ	1
2.ÖNCEKİ ÇALIŞMALAR	4
2.1 Türkiye’de Yapılan Çalışmalar	4
2.2 Dünya Genelinde Yapılan Çalışmalar	7
3.HAVZALARDA HİDROLOJİK MODELLEME	9
3.1 Yağış Verilerinin Ölçülmesi ve Analizi	10
3.1.1 Yağış verilerinin ölçümü	10
3.1.2 Yağış verilerinin analizi.....	11
3.2 Akım Ölçümleri ve Akım Verilerinin Analizi	11
3.2.1 Akımların seviye ölçümüyle belirlenmesi	12
3.2.3 Akım verilerinin analizi	13
4. MATERYAL ve METOD	14
4.1. Yapay Zeka Teknolojisi	14
4.1.1 Yapay sinir ağları.....	14
4.2. Evrimsel Algoritmalar	31
4.2.1. Gen ifade programlama	32
4.3. İstatiksel Tahmin ve Trend Analizi	42
4.3.1. Parametrik olmayan testler	43
4.3.2. Parametrik testler	46
4.3.3. Regresyon katsayılarının f testi ile anlamlılığını belirleme	46
5. ARAŞTIRMA BULGULARI ve SONUÇLAR.....	49
5.1. Havza Bilgileri	49

5.2. İstasyon Bilgileri	51
5.2.1. D12A033 no'lu istasyon bilgileri	51
5.2.2. D12A049 No'lu İstasyon bilgileri	51
5.2.3. D12A063 No'lu İstasyon bilgileri	52
5.2.4. D12A173 no'lu İstasyon bilgileri	53
5.2.5. 17126 No'lu istasyon bilgileri	53
5.2.6. D12A054 no'lu istasyon bilgileri	54
5.2.7. D12A171 no'lu istasyon bilgileri	55
5.2.8. E12A003 no'lu istasyon bilgileri.....	55
5.2.9. D12A181 No'lu İstasyon bilgileri	56
5.2.10. D12A152 No'lu İstasyon bilgileri..	57
5.2.11. D12A093 no'lu istasyon bilgileri	58
5.3. Yöntemlere Ait Parametrelerin Düzenlenmesi.....	59
5.3.1 Yapay sinir ağları ileri beslemeli geri yayılım yöntemi için belirlenen parametreler	59
5.3.2. Evrimsel algoritmalar gen ifade programlama yöntemi için belirlenen parametreler	59
5.3.3. Parametrik trend analizi çoklu doğrusal regresyon yöntemi için belirlenen parametreler	60
5.4. İstasyon Akım Tahmini Sonuçları.....	60
5.4.1. D12A033 no'lu istasyonun analiz sonuçları.....	60
5.4.2. E12A003 no'lu istasyonun analiz sonuçları	66
5.4.3. D12A171 no'lu istasyonun analiz sonuçları.....	80
5.4.4. D12A049 no'lu istasyonun analiz sonuçları.....	76
5.4.5. D12A173 no'lu istasyonun analiz sonuçları.....	81
5.4.6. D12A054 no'lu istasyonun analiz sonuçları.....	86
5.4.7. D12A181 no'lu istasyonun analiz sonuçları.....	91
5.4.8. D12A152 no'lu istasyonun analiz sonuçları.....	96
6. SONUÇLAR	102
KAYNAKLAR	105
ÖZ GEÇMİŞ.....	

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 4.1. Nöron yapısı.....	16
Şekil 4.2. Yapay sinir hücresi yapısı.....	16
Şekil 4.3. Sigmoid fonksiyon grafiği	18
Şekil 4.4. Geri beslemeli ağ yapısı.....	20
Şekil 4.5. İleri beslemeli ağ yapısı	20
Şekil 4.6. Tek katmanlı algılayıcı yapısı.....	21
Şekil 4.7. Çok katmanlı algılayıcı yapısı	22
Şekil 4.8. Danışmanlı öğrenme blok şeması	23
Şekil 4.9. Danışmansız öğrenme blok şeması.....	23
Şekil 4.10. Takviyeli (destekleyici) öğrenme blok şeması	24
Şekil 4.11. İleri beslemeli geri yayımlı yapay sinir ağı yapısı.....	25
Şekil 4.12. Sinyal bağlantıları ve doğrultuları	26
Şekil 4.13. Evrimsel algoritmaların genel yapısı	31
Şekil 4.14. Genetik algoritmaların akış şeması.....	33
Şekil 4.15. Genetik programlamanın akış şeması	34
Şekil 4.16. Gen ifade programlamanın akış şeması	35
Şekil 4.17. Örnek kromozomun dizilimi.....	36
Şekil 4.18. Örnek kromozomun ifade ağacı gösterimi.....	36
Şekil 4.19. Çok genli kromozom yapısı	37
Şekil 4.20. Örnek kromozomun ifade ağaçlarıyla gösterimi (a) Kuyruklu ve koyu olarak gösterilenler üç gen takımı ve oklar her genin sonlanma noktası (b) Gen takımlarını ifade eden ifade ağaçları(c) Gen takımlarının bir arada gösterildiği ifade ağacı.....	38
Şekil 5.1. Sakarya havzası.....	49
Şekil 5.2. D12A033 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	63
Şekil 5.3. D12A033 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	63

Şekil 5.4.	D12A033 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	64
Şekil 5.5.	D12A033 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	64
Şekil 5.6.	D12A033 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	65
Şekil 5.7.	D12A033 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	65
Şekil 5.8.	E12A003 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	68
Şekil 5.9.	E12A003 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	68
Şekil 5.10.	E12A003 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	69
Şekil 5.11.	E12A003 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri_	69
Şekil 5.12.	E12A003 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	70
Şekil 5.13.	E12A003 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	70
Şekil 5.14.	D12A171 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	73
Şekil 5.15.	D12A171 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	73

Şekil 5.16.	D12A171 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	74
Şekil 5.17.	D12A171 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	74
Şekil 5.18.	D12A171 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	75
Şekil 5.19.	D12A171 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	75
Şekil 5.20.	D12A049 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	78
Şekil 5.21.	D12A049 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	78
Şekil 5.22.	D12A049 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	79
Şekil 5.23.	D12A049 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	79
Şekil 5.24.	D12A049 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	80
Şekil 5.25.	D12A049 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	80
Şekil 5.26.	D12A173 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	83
Şekil 5.27.	D12A173 No'lu Akım Gözlem İstasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	83

Şekil 5.28.	D12A173 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	84
Şekil 5.29.	D12A173 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	84
Şekil 5.30.	D12A173 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	85
Şekil 5.31.	D12A173 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	85
Şekil 5.32.	D12A054 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	88
Şekil 5.33.	D12A054 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	88
Şekil 5.34.	D12A054 no'lu akım gözlem istasyonu için gen ifade programlama yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	89
Şekil 5.35.	D12A054 no'lu akım gözlem istasyonu için gen ifade programlama yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	89
Şekil 5.36.	D12A054 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	90
Şekil 5.37.	D12A054 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	90
Şekil 5.38.	D12A181 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	93
Şekil 5.39.	D12A181 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	93

Şekil 5.40.	D12A181 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	94
Şekil 5.41.	D12A181 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	94
Şekil 5.42.	D12A181 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	95
Şekil 5.43.	D12A181 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	95
Şekil 5.44.	D12A152 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	98
Şekil 5.45.	D12A152 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri	98
Şekil 5.46.	D12A152 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	99
Şekil 5.47.	D12A152 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri	99
Şekil 5.48.	D12A152 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı	100
Şekil 5.49.	D12A152 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri	100

ÇİZELGELER DİZİNİ

	Sayfa No
Çizelge 4.1. Biyolojik sinir sistemi ve yapay sinir ağları benzerliği	16
Çizelge 4.2. Toplama f-fonksiyon örnekleri	17
Çizelge 4.3. Transfer fonksiyonu örnekleri	19
Çizelge 5.1. Porsuk alt havzası genel bilgileri	50
Çizelge 5.2. D12A033 no'lu istasyona ait veri bilgileri	51
Çizelge 5.3. D12A049 no'lu İstasyona ait veri bilgileri	52
Çizelge 5.4. D12A063 no'lu istasyona ait veri bilgileri	52
Çizelge 5.5. D12A173 no'lu istasyona ait veri bilgileri	53
Çizelge 5.6. 17126 no'lu istasyona ait veri bilgileri	54
Çizelge 5.7. D12A054 no'lu istasyona ait veri bilgileri	54
Çizelge 5.8. D12A171 no'lu istasyona ait veri bilgileri	55
Çizelge 5.9. E12A003 no'lu istasyona ait ilk veri bilgileri	56
Çizelge 5.10. E12A003 no'lu istasyona ait ikinci veri bilgileri	56
Çizelge 5.11. D12A181 no'lu istasyona ait veri bilgileri	57
Çizelge 5.12. D12A152 no'lu istasyona ait veri bilgileri	58
Çizelge 5.13. D12A093 no'lu istasyona ait veri bilgileri	58
Çizelge 5.14. D12A033 no'lu istasyona ait analiz sonuçları	61
Çizelge 5.15. D12A033 no'lu istasyona ait 30 günlük tahmin değerleri	62
Çizelge 5.16. E12A003 no'lu istasyona ait analiz sonuçları	66
Çizelge 5.17. E12A003 no'lu istasyona ait 30 günlük tahmin değerleri	67
Çizelge 5.18. D12A171 no'lu istasyona ait analiz sonuçları	71
Çizelge 5.19. D12A171 no'lu istasyona ait 30 günlük tahmin değerleri	72
Çizelge 5.20. D12A049 no'lu istasyona ait analiz sonuçları	76
Çizelge 5.21. D12A049 no'lu istasyona ait 30 günlük tahmin değerleri	77
Çizelge 5.22. D12A173 no'lu istasyona ait analiz sonuçları	81
Çizelge 5.23. D12A173 no'lu istasyona ait 30 günlük tahmin değerleri	82
Çizelge 5.24. D12A054 no'lu istasyona ait analiz sonuçları	86
Çizelge 5.25. D12A054 no'lu istasyona ait 30 günlük tahmin değerleri	87
Çizelge 5.26. D12A181 no'lu istasyona ait analiz sonuçları	91
Çizelge 5.27. D12A181 no'lu istasyona ait 30 günlük tahmin değerleri	92

Çizelge 5.28. D12A152 no’lu istasyona ait analiz sonuçları.....	96
Çizelge 5.29. D12A152 no’lu istasyona ait 30 günlük tahmin değerleri.....	97



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

GEP	: Gen İfade Programlama
YSA	: Yapay Sinir Ağları
ÇDR	: Çoklu Doğrusal Regresyon
T_i	: Toplam Fonksiyonu Giriş Değerleri
C_i	: Toplam Fonksiyonu Ağırlık Değerleri
n_i	: Toplam Fonksiyonu Girdi Sayısı
a_k	: Giriş Katmanı Girdi Verileri
p_{hi}^{ga}	: Ağırlık Bağlantı Değeri
NET_j	: Toplam Fonksiyonundan Geçirilmiş Ara Katman Değeri
a_j	: Ara Katman Çıkış Değeri
b_j	: j Katmanına Bağlı Bias Değeri
h_{jh}	: Hata Miktarı
g_{ji}	: Gerçek Çıktı Verileri
$a_{jü}$	: Ağın Ürettiği Çıktı Verileri
h_{jtop}	: Hata Miktarının Karelerinin Toplamı
$p_{ij}^{a\check{c}}$	: Ara ve Çıktı Katmanları Arasındaki Ağırlık Değeri
p_{ki}^{ga}	: Girdi ve Ara Katmanları Arasındaki Ağırlık Değeri
λ	: Öğrenme Oranı
α	: Momentum Değeri
δ_j	: Hata Gradyantı
$f(m)$	: Hata Fonksiyonu
$f'(m)$	: Hata Fonksiyonu Türevi
$\mu_j^{a\check{c}}$	: Ara ve Çıktı Katmanları Arasındaki Bias Değeri
μ_i^{ga}	: Girdi ve Ara Katmanları Arasındaki Bias Değeri
N	: Ortalama Karesel Hata Veri Sayısı
$\hat{y}_1$	: Ortalama Karesel Hata Gerçek Veri Değerleri
y_i	: Ortalama Karesel Hata Tahmin Veri Değerleri
h_g	: Gen İfade Programlama Kromozom Baş Uzunluğu
n_g	: Gen İfade Programlama Değişken Sayısı

t_g	: Gen İfade Programlama Kromozom Kuyruk Uzunluğu
M_m	: Mann Kendall Testi $x_i > x_j$ Şartını Sağlayan Veri Sayısı
S_m	: Mann Kendall Testi İstatistik Değeri
σ_s	: Varyans
t_i	: Mann Kendall Testi Eşit Değere Sahip Gözlem Veri Sayısı
Q_t	: Sen'in T Testine Ait Parametrik Değer
β	: Sen'in T Testinde Trendleri Belirleyen Değer
r_s	: Spearman'ın Rho Testi Değeri
X_i	: Regresyon Analizi Bağımsız Değişken Değeri
Y_i	: Regresyon Analizi Bağımlı Değişken Değeri
Y_i'	: Regresyon Analizi Tahmin Değeri
e_i	: Regresyon Analizi Hata Değeri

1.GİRİŞ

Dünya; oluşum süreci esnasında birçok evreden geçmiştir. Bu evreler esnasında şuanda tüm canlılığın ihtiyacı karşılayan doğal kaynaklar oluşmuştur. Bu doğal kaynaklar içinde en önemli ve canlılar açısından vazgeçilmez bir yere sahip olanı sudur. Su en basit tanımıyla; her molekülü bir adet oksijen ve iki adet hidrojen atomunun bir araya gelmesiyle oluşmuş, tadı ve kokusu olmayan renksiz bir sıvıdır.

Dünyada bulunan su kaynakları güneş enerjisi sayesinde hidrolojik bir döngü içerisinde tüm canlılığın ihtiyacını karşılar ve canlılardan da bazı biyolojik ve kimyasal yollarla tekrardan ayrılarak döngünün içerisine yeniden dahil olur. Bu hidrolojik döngüde canlılara ya da doğaya kazandırılmayan her kayıp dünya üzerinde sınırlı bir miktarda bulunan su kaynaklarını çok ciddi bir şekilde etkilemektedir.

Yeryüzündeki mevcut su kaynağının %97,5 lik kısmını tuzlu sular oluşturur ve geriye kalan %2,5'lük kısmı kullanılabilir durumda olan tatlı sudur. Bu miktarın da %2'lik kısmı kutuplarda buz kütleleri halinde bulunur (Ulusoy, 2007: Özsoy, 2009). Türkiye genelinde yıllık ortalama yağış miktarı yaklaşık 501 milyar m³'tür. Bu miktarın yaklaşık 274 milyar m³'lük kısmı yüzey üzerinden buharlaşarak (toprak ve su yüzeyleri) ve bitki solunumu esnasında açığa çıkarak hidrolojik döngüye geri kazandırılır. 158 milyar m³'lük kısmı ise akıma dönüşerek akarsular vasıtasıyla denizlere ve göllere boşalmaktadır. Bunların haricinde komşu ülkelerden ülkemize 7 milyar m³ su girişi olmaktadır. Teknik donanım ve ekonomik şartlar sebebiyle tüm bu su potansiyeli ülkemizde verimli bir şekilde kullanılamamakta ve gerekli çalışmalar yapılamamaktadır. Akarsulardan toplam 95 milyar m³ ve komşu ülkelerden gelen akarsuların da yaklaşık 3 milyar m³ lük bir kısmı verimli bir şekilde kullanılabilir. Toplamda 98 milyar m³'lük yerüstü kullanılabilir su miktarına ek 14 milyar m³ yeraltı suyu potansiyeli ile birlikte ülkemizde yıllık kullanılabilir su miktarı 112 milyar m³ olmaktadır (oyder-tr.org, Erişim: 18.04.2019).

Ülkemizin sahip olduğu yağış rejimi sebebiyle depolama tesisleri oldukça önemli bir yere sahiptir. Ülkemizde yaz ayları genel olarak kurak ve yağış bakımından verimsiz geçmektedir. Bu tesisler yardımıyla mevcut su yaz ayı boyunca korunarak şehirlerin su ihtiyacı ve tarımsal arazilerin sulama faaliyetleri için yaz aylarında rahatlıkla kullanılabilir. Toplam kullanılabilir su miktarı olan 112 milyar m³ olan ülkemiz bu su potansiyeliyle su yönünden fakir sayılan kategoride yer almaktadır. Bununla birlikte

kullanılabilir su miktarının sadece %40'ı değerlendirilmektedir. Bu oranın içerisinde en büyük paydayı tarım sektörü oluşturur. Tarım sektörü kullanılan su miktarının %75'ini oluşturur (Özlü, 2006).

Yapılan araştırmalar sonucunda gerekli önlemler alınmazsa Türkiye'nin 2030 yılında su kıtlığı yaşayan ülkeler arasına girebileceği öngörülmektedir. Bu sebeple mevcut su potansiyelinin verimli bir şekilde kullanılabilme ve su politikaları geliştirmek için planlama çalışmalarının dikkatli bir şekilde yapılması gerekmektedir. Suyun kontrol altına alınıp verimli bir şekilde kullanılmasını sağlayacak olan projeler büyük bir titizlikle ve verimli sonuçlar ortaya koyan yöntemlerle planlanmalıdır.

Su kaynaklarının mevcut potansiyellerinin belirlenmesinde yönetsel stratejilerin yanında; proje planlama inşa ve işletme gibi birçok konunun ele alınması büyük bir öneme sahiptir. Verimli bir su yapısı planlaması ya da kaynak kontrolü için yeterli miktarda veriye ihtiyaç duyulmaktadır (Turhan ve Çağatay, 2016). Özellikle su kaynağındaki değişim oranları; su kaynağının verimli kullanılması adına hazırlanacak yapı projelerinin temel parametrelerini etkileyen önemli bir husustur. Fakat bu değişim miktarı; su miktarını birinci dereceden etkileyen yağışların bir zaman aralığındaki miktarının tam olarak önceden bilinebilmesinin mümkün olmaması sebebiyle yeterli doğrulukta tespit edilememektedir. Bu yetersizlik su kaynaklarının korunumu adına düzenlenecek projeler için olumsuz sonuçlar doğurmaktadır. Temel yetersizlikler ve günümüz teknolojisini daha verimli kullanabilme arzusu gibi sebeplerden ötürü yeni tahmin modelleme yöntemleri üzerinde durulmaya başlanmış ve bu yönelim sayesinde insanlığa büyük ölçüde katkı sağlayacak yeni metotlar keşfedilmiştir (Uslu ve İçağa, 2010). Mühendislik çalışmalarında veri analizi temelde iki aşamalıdır. Mevcut bir sistemi tanımlayan matematiksel modelin kurgulanması ve kurgulanan bu denklemin analitik olarak ya da çeşitli sayısal metotlar yardımıyla çözümlenmesi işleminde ilk aşama tecrübe ve sezgisel olarak kurgulanmış matematiksel altyapıdır. Bu aşamayı takip eden ikinci aşama da modellemede kullanılan tecrübe ve sezgisel güce ilave olarak hızlı ve kapsamlı bir hesaplama sistemidir. Bilgisayar teknolojisindeki müthiş ilerleme ve getirdiği yeniliklerle birlikte; sonlu elemanlar, regresyon ve varyasyon metotları gibi birçok sayısal analiz metodu verimli bir şekilde kullanılarak günümüze kadar gelmiştir. Bunlara ek olarak bilgisayar teknolojisi yardımıyla insan beyni düşünce, algı, öğrenme ve karar verme yeteneği taklit edilmeye çalışılmış ve yapay zeka kavramını ortaya

çıkarmıştır. Bilgisayar, mühendislik, tıp, istatistik gibi birçok alanda kendine kullanım alanı bulan bu bilgisayar tabanlı düşünce sistemi; istatistiksel veri analizi ve modelleme çalışmalarında da kullanılmaya başlanmıştır (Civalek ve Çatal, 2004). Yapılan bu çalışmada Porsuk alt havzasına ait nehir akım verileri yardımıyla yapay zeka teknolojisi ve istatistik yöntemlerden yararlanılarak oluşturulan tahmin modelleri irdelenmiştir.

Çalışmada yapay zeka teknolojisi başlığı altındaki yapay sinir ağları ve genetik algoritma yöntemleri ile istatistiksel bir analiz yöntemi olan trend analiz yöntemi kullanılarak akım tahmini yapılmıştır. Birden fazla model analiz edilerek alınan sonuçlar karşılaştırılmıştır. Çalışma sonucunda farklı veri gruplandırmalarıyla oluşturulmuş veriler yardımıyla eğitilen bu üç yöntem arasından yapay sinir ağlarının ileri beslemeli geri yayılım ağı en başarılı tahmin sonuçları üretmiştir. Diğer iki model arasından evrimsel algoritma yöntemi olan gen ifade programlama ile hazırlanan tahmin modelleri ortalama bir başarı göstermiştir. En kötü tahmin değerlerini trend analizi yöntemi olan çoklu doğrusal regresyon ile hazırlanan modeller vermiştir. Tüm istasyonlara ait bilgiler ve alınan en iyi sonuçlar çalışmada verilmiştir.

2.ÖNCEKİ ÇALIŞMALAR

Bu konuda yapılmış önceki çalışmalar aşağıda verilmiştir.

2.1. Türkiye’de Yapılan Çalışmalar

Büyükyıldız (2004) yaptığı çalışmada; Sakarya Havzası’na ait aylık ortalama yağış verilerinden yararlanarak trend analizi yapmış ve stokastik modeller kurgulamıştır. Toplamda 25 adet yağış gözlem istasyonundan alınan veriler yardımıyla; Sen’in T testi, Spearman’ın Rho testi, Mann-Kendall ve Mevsimsel Mann-Kendall testleri ile trend analizi yapılmış ve alınan sonuçlar incelenmiştir. İstasyonlara ait ölçümlerde eksik olan yerler çoklu regresyon analiz yöntemi kullanılarak türetilmiştir.

Kaynar (2005) yaptığı çalışmada; Doğu Karadeniz Bölgesine ait maksimum akımları analizi yapmıştır. Çalışmada istasyonların istatistik parametreleri bulunmuş eksik veriler çoklu doğrusal regresyon ve lineer regresyon analizlerinden faydalanmıştır.

Yurdusev vd. (2008); Akarçay kapalı havzasındaki aylık akım verilerinin tahmini üzerine bir çalışma yürütmüşlerdir. Çalışmada havzada bulunan akım ve yağış gözlem istasyonlarından temin edilen aylık veriler kullanılmıştır. Yapay sinir ağları ve çok değişkenli regresyon analizi ile hazırlanan tahmin modelleri karşılaştırılmış ve yapay sinir ağları modelinin veri tahmininde daha verimli olduğu görülmüştür.

Karabulut ve Cosun (2009) yaptıkları çalışmada; Kahramanmaraş iline ait yağış verilerini kullanarak trend analizi yapmışlardır. Çalışmada meteoroloji istasyonundan temin edilen yağış verilerinde eksik kısımlar parametrik lineer regresyon analizi yardımıyla tamamlanmış ve kullanmışlardır. Mann-Kendall testi yardımıyla yapılan trend analizi sonucunda özellikle sonbahar mevsiminde istatistiksel anlamca ciddi bir artış trendi olduğu gözlemlenmişlerdir.

Okkan ve Mollamahmutoğlu (2010) yaptıkları çalışmada; Yiğitler Çayı üzerinde yer alan akım gözlem istasyonları yardımıyla ölçülmüş günlük akım verilerini modellemişlerdir. Modelleme işleminde yapay sinir ağları ile regresyon analizini kullanmışlardır. Analiz sonucunda yapay sinir ağı algoritmasının performansını regresyon analiz modellerine göre daha başarılı bulmuşlardır.

Uslu ve İçağa (2010) yaptıkları çalışmada; 6 akım gözlem istasyon verisi kullanılarak yapay sinir ağı ile tahmin modelleri geliştirmişlerdir. Temin edilen akım gözlem istasyon verileri aylık ve yıllık olarak kullanmışlar ve ağ modelleri hazırlanırken yapay sinir ağı özelliklerinden faydalanmışlardır. Ağ modelleri farklı öğrenme oranları,

farklı gizli katman sayıları ve nöron adetleri ile hazırlanmışlar ve genel olarak başarılı sonuçlar elde etmişlerdir.

Beşiktaş (2010); Doğu Karadeniz’de debi-süreklilik eğrilerinin regresyon analizi yardımıyla belirlenmesi ve eksik akım verilerinin tahmin edilmesi amacıyla bir çalışma yapmıştır. Çalışma sonucunda elde edilen bağıntılar yardımıyla bölgesel olarak debi tahmininde bulunmuş ve literatürdeki farklı istatistik tahmin yöntemiyle alınan sonuçları karşılaştırmıştır. Karşılaştırma sonucu incelendiğinde regresyon analizi yardımıyla alınan sonuçların bölgeyi oldukça iyi bir şekilde temsil ettiğini görmüştür.

Akdemir vd (2013), Ozon ve meteorolojik parametreler arasındaki korelasyon ilişkisini belirlemek için çoklu regresyon analizi yönteminden yararlanmışlardır. Meteorolojik veri olarak; sıcaklık, nispi nem, rüzgar hızı, güneş radyasyon ve dış basınç verileri kullanmışlardır. Çalışma sonucunda ozon değerlerinin; sıcaklık ve radyasyon ile zayıf pozitif ilişkisi olduğu tespit etmişlerdir

Gümüş vd (2013) yaptıkları çalışmada; Orta Fırat Havzasında ölçüm yapan akım ve yağış gözlem istasyon verilerinden faydalananarak bir çalışma ortaya koymuşlardır. Yapılan çalışmada akım-yağış ilişkisi modellenmiştir. Bu modelleme işleminde yapay sinir ağları yöntemlerinden; ileri beslemeli geri yayılım ağı, genelleştirilmiş regresyon ağı ve radyal tabanlı sinir ağı kullanılmışlardır. Bu 3 yapay sinir ağı yönteminden alınan sonuçlar geleneksel bir yöntem olan çoklu doğrusal regresyon analiz sonuçlarıyla karşılaştırılmıştır. Çalışma sonucunda yapay sinir ağı modellerinin geleneksel yöntemlere göre çok daha başarılı sonuçlar vermiştir.

Terzi (2013); Türkiye’de bulunan Eğirdir gölü günlük buharlaşma verilerinden faydalananarak bir çalışma yürütmüştür. Çalışmada gen ifade programlama (GEP) ve bulanık mantık yapay sinir ağı (ANFIS) metotları kullanmıştır. Çalışma sonucunda GEP modellerinin ANFIS modellerine göre daha başarılı sonuçlar vermiştir.

Traore ve Güven (2013) yaptıkları çalışmada; tahmini bir hayli güç olan bitkilerin su tüketimi ve buharlaşma ile birlikte toplam su kaybı hesabı için tahmin modelleri hazırlamışlardır. Çalışmada çok sayıda farklı veri kullanmışlardır. Tahmin modelleri gen ifade programlama ile hazırlanmış ve çalışma sonucunda yüksek doğruluk değerlerine ulaşarak gen ifade programlamanın birden fazla ve farklı yapıdaki verinin ilişkilendirilmesini başarılı bir şekilde yerine getirebildiğini görmüşlerdir

Kızılaslan vd. (2014) yaptıkları çalışmada; Sakarya Havzasında yer alan Sakarya Nehri üzerinde yer alan Doğançay Akım Gözlem istasyonu verileriyle akım tahmin modelleri geliştirmişlerdir. Çalışmada yapay sinir ağlarının ileri beslemeli geri yayılım ağı kullanmış ve bu ağ ile oluşturulan tahmin modelleri yardımıyla gerçek verileri yakın veriler üretmiştir.

Terzi ve Barak (2015) yaptıkları çalışmada; Kızılırmak Nehri üzerinde yer alan Söğütlühan akım gözlem istasyon verileri ile Sivas Meteoroloji istasyonuna ait yağış verilerini kullanarak yağış-akış ilişkini modellemeye çalışmışlardır. Çalışmada dalgacık dönüşüm tekniği ve yapay sinir ağlarının birbiri ile sentezlendiği yeni bir model kullanılmış ve başarılı sonuçlar elde etmişlerdir.

Altınışık (2015) yaptığı çalışmada; Doğu Karadeniz Havzasında ölçüm yapan 12 adet akım gözlem istasyonundan temin edilen akım verileriyle ortalama akım ve taşkın akım grafikleri çizilerek yorumlanmıştır. 2215 numaralı akım gözlem istasyonunun 1991 yılına ait eksik verileri doğrusal regresyon analizi ile tahmin edilerek tamamlamıştır. Çalışma sonucunda temin edilen verileri lineer ve çoklu regresyon yöntemleri ile tamamlanmış ve her bir akım gözlem istasyonuna ait maksimum ve minimum akım değerlerinin görüldüğü ayları belirlemiştir. Genellikle en yüksek değer okunduğu ayların Nisan ve Mayıs ayları olduğunu görmüştür.

Turhan ve Çağatay (2016); Asi Nehri üzerindeki bir akım gözlem istasyonuna ait debi ölçümlerindeki eksik verilerin; yapay sinir ağları, çoklu doğrusal regresyon ve çoklu doğrusal olmayan regresyon analizi yöntemleriyle tahmin edilmesi üzerine bir çalışma yürütmüşlerdir. Hazırlanan model sonuçları birbirleriyle karşılaştırılmış ve yapay sinir ağlarının ileri beslemeli geri yayılım ağı ile hazırlanmış modellerinin diğer iki istatistiksel yöntemle göre daha iyi sonuçlar verdiği sonucuna ulaşmışlardır.

Karakuş (2017) yaptığı çalışmada; yağış, sıcaklık ve akım değerlerini kullanarak trend analizi yapmıştır. Verilerdeki eksik kısımlar lineer regresyon ve çoklu doğrusal regresyon yöntemleriyle üretmiştir. Çalışma sonunda Mann-Kendall testi ve Sen'in eğimi tahmini yöntemi kullanılarak trend analizi üzerine genel bir değerlendirme yapmıştır.

Terzi ve Özcanoglu (2017) yaptıkları çalışmada; gen ifade programı yöntemi yardımıyla Doğu Akdeniz havzasında yer alan Göksü Nehri için bir çalışma yürütmüşlerdir. Yapılan çalışmada Göksü Nehri'nin aylık akım verileri kullanılarak

tahmin modelleri oluşturulmuş ve 2006-2010 yılları arasında ölçülen akım verileri kullanılarak yapılan çalışmada gen ifade programlama yöntemiyle başarılı sonuçlar elde etmişlerdir.

2.2. Dünya Geneline Yapılan Çalışmalar

Shamseldin (1997) yaptığı çalışmada; yapay sinir ağlarının ileri beslemeli geri yayılım ağını kullanarak yağış akış tahmin modelleri oluşturmuştur. Hazırlanan tahmin modellerinden gerçeğe yakın sonuçlar elde etmiş ve yapay sinir ağlarının yağış akış modellemesinde verimli bir şekilde kullanılabileceği sonucuna varmıştır.

Tokar ve Jonshon (1999) yaptıkları çalışmada; Yapay sinir ağları ile günlük yağış, sıcaklık ve kar erimesi verilerini kullanarak günlük akım tahmini modelleri kurgulamışlardır. Çalışma sonucunda birbirleri ile anlamlı ilişki içerisinde olan farklı veriler yardımıyla akım tahmininin yapılabilirdiği ve yapay sinir ağları modellerinin oldukça verimli sonuçlar verdiğini görmüşlerdir.

Dawson, vd. (2002); Çin’de bulunan Yangtze Nehrinin akım verilerinden faydalanarak bir çalışma yürütmüşlerdir. Çalışmada 1991-1993 yılları arasındaki nehir debi ölçüm değerlerini kullanmışlardır. Mevcut veriler yapay sinir ağları ve radyal tabanlı sinir ağları yöntemleriyle birlikte klasik istatistik yöntemleri kullanarak modellemişlerdir. Yapay zeka teknolojisiyle geliştirilen modellerin klasik istatistiksel yöntemlere göre daha iyi sonuçlar elde etmişlerdir

Baratti vd. (2003) yaptıkları çalışmada; İtalyada bulunan Tirso havzasının yağış akış sürecini modellemişlerdir. Çalışmada modelleme işlemi için fiziksel tabanlı yaklaşımlar ile yapay sinir ağları modelleri kullanmışlardır. Alınan sonuçlar doğrultusunda fiziksel tabanlı yaklaşımların veri yetersizliği çektiği ve verimli değerler oluşturamadığı durumlarda yapay sinir ağlarının başarılı sonuçlar verdiği ve bu gibi kriz anlarında kullanılabilecek bir modelleme yöntemi olduğu sonucuna varmışlardır.

Sudheer ve Jain (2003) yaptıkları çalışmada; nehir debi miktarlarının modellenmesi amacıyla radyal tabanlı sinir ağları ile ileri beslemeli geri yayılım ağlarının performansını incelemişlerdir. Çalışma sonucunda ileri beslemeli geri yayılım ağının radyal tabanlı ağlara göre daha hızlı ve gerçeğe yakın tahmin verileri ürettiğini görmüşlerdir.

Mohamoud (2008) yaptığı çalışmada; ABD’nin Mid-Atlantic bölgesinde ölçüm yapılamamış havzalar üzerine bir çalışma yürütmüştür. Akım tahminleri ve debi

süreklilik eğrilerinin belirlenmesi için çoklu doğrusal regresyon analizi yöntemiyle analiz yapmıştır. Toplamda 29 adet havzada yaptığı çalışmada çoklu doğrusal regresyon analizi başarılı sonuçlar vermiş ve havza karakteristiğine uygun debi verileri oluşturduğu sonucuna ulaşmıştır.

Azamathulla vd. (2011); Malezya sınırları içinde yer alan Pahang Nehri'nin debi verilerinden yararlanarak tahmin modelleri geliştirmişlerdir. Çalışmada genetik programlama ve gen ifade programlama yöntemleriyle hazırlanan model sonuçlarını karşılaştırmışlardır. Çalışma sonuçları incelendiğinde gen ifade programlama yönteminin genetik programlaya göre çok daha başarılı tahmin verileri üretmiştir.

Shiri ve vd., (2014) yaptıkları çalışmada; ABD'de bulunan 6 adet istasyondan temin ettikleri iklim verileri yardımıyla tahmin modelleri geliştirmişlerdir. Çalışmada gen ifade programlama modelleri ile ampirik yollarla elde edilen model sonuçları karşılaştırılmıştır. Alınan sonuçlar değerlendirildiğinde GEP modelinin başarılı bir şekilde iklimsel veri tahmini yapabildiğini görmüşlerdir.

3.HAVZALARDA HİDROLOJİK MODELLEME

Havzalar, ölçülebilir belirli parametrelerin var olduğu doğal sistemlerdir. Bu sistem içerisinde; iklim, yağış, nem, bitki örtüsü, jeomorfolojik özellikler gibi pek çok parametre ve havzaya düşen yağışın bu parametrelerden etkilenerek akıma dönüştüğü bir döngü bulunmaktadır. Havza sisteminde, bu parametrelerden yararlanarak hazırlanan hidrolojik modeller yardımıyla mevcut giriş akımından çıkış akımının belirlenmesi mümkün olmaktadır (Singh and Fiorentino, 1996; Özcan, 2007).

Hidrolojik modeller; havza yönetiminde projelendirme, karar alımı, kullanılabilir su potansiyelinin belirlenmesi, kaynakların korunması ve değerlendirilmesi, hidrolojik veri tahmini ve hidrolojik süreçler hakkında bilgi sahibi olunması açısından büyük rol oynar. Tüm hidrolojik sürecin uygun ölçekte temsil eden matematiksel modellerin geliştirilmesi ve verimli bir şekilde kullanılması; suyun yönetimi, değerlendirilmesi ve su tesislerinin zaman içerisindeki veriminin belirlenebilmesinde etkilidir (Uğuroğlu, 2017). Fakat bu hidrolojik süreci meydana getiren değişkenler oldukça karmaşıktır ve değişimleri tam olarak tahmin ve kontrol edilememektedir. Bu nedenle elde edilen veriler doğru ve eksiksiz olarak ölçülmüş bile olsalar hidrolojik süreçlerin sistem kavramı altında daha basite indirgenerek değerlendirilmesi daha sağlıklı sonuçların alınmasını sağlamaktadır (Chow vd, 1988; Bayazıt, 1998; Cüceloğlu 2013).

Hidrolojik modeller;

- Depolama tesislerinin planlama, işletim ve geliştirilmesi gibi konularda ihtiyaç duyulan geleceğe dönük verilerin tahmin edilmesi

- Ölçüm aletleri bulunmayan ya da ölçüm yapılamayan havzalarda hidrolojik verilerin üretilmesi

- Havzanın karakteristik parametrelerinden bir ya da birkaçının değişiminin havzaya olan etkilerinin belirlenmesi

- Hidroloji ve meteoroloji biliminin ortak çalışmasıyla Global İklim Modellerinin oluşturulması

amaçlarıyla kullanılmaktadır (Wheater vd., 2007; Uğurluoğlu, 2017).

Havzanın iki önemli parametresi olan akım ve yağış değerlerinin ölçümü ve eksik verilerinin tamamlanması için birçok hidrolojik yöntem geliştirilmiştir. Günümüzde bu yöntemlerin bir kısmı hala kullanılmaya devam etmektedir.

3.1 Yağış Verilerinin Ölçülmesi ve Analizi

3.1.1 Yağış verilerinin ölçümü

Yağış hidrolojik verilerin temelidir. Yağışın meydana gelmesinde öncelikli etmen atmosferik nemdir. Atmosferik nem tek başına yağışın oluşumu için yeterli olmaz. Mevcut nem atmosferde yukarılara doğru yükseldikçe soğur ve yoğunlaşır. Bu da su damlalarının oluşmasını sağlar ve bu su damlaları da yağış olarak yeryüzüne iner. Yağış hava hareketini oluşturan koşullara göre konvektif, siklonik ve orografik olarak 3 sınıfa ayrılır. Konvektif yağışlar; havanın yer yüzeyinde ısınarak atmosfere yükselmesi ve burada da soğuyup genişleyerek yağışa dönüşmesi ile sonuçlanan bir yağış türüdür. Siklonik yağışlar; basıncın yüksek olduğu bölgelerden düşük olan bölgelere doğru hava hareketi yaşanmasıyla gerçekleşir. Bu basınç farkının sebebi yüzeydeki sıcaklık farkıdır. Sıcak ve soğuk hava kütlesi bu basınç hareketi sebebiyle karşılaşır ve yağışa dönüşür. Orografik yağışlar; Nemli hava kütlelerinin yüksek bir bölgeyle karşılaşması sonucu yukarı doğru hareketinden sonra soğumasıyla gerçekleşir. Bu yağış tipi genellikle kıyılara paralel sıradağların bulunduğu bölgelerde sıkça görülür (jeoloji.kocaeli.edu.tr Erişim: 18.04.2019).

En yaygın olarak aşağıdaki yağış ölçüm aletleri kullanılmaktadır (Gençer vd., 2005):

Plüviometre: Yağmur sularının aletin toplama kabında birikmesi ve bu biriken suyun mihber adı verilen ölçekle ölçülmesi ise yağış miktarını hesaplar. Huni, gövde, kova, istavroz, askı demiri ve mesnet direği olmak üzere 6 parçadan oluşur. (Gençer vd., 2005).

Plüviograf: Yağış miktarı ve şiddetini, içerisinde yer alan diyagram üzerine kaydeden bir alettir. Yağışın başlangıç saatini, ne kadar süre devam ettiğini ve bitiş saatini 24 saat boyunca takip ederek kayda alır. Plüviometreye göre daha hassas ölçüm yapmaktadır. Huni, rezervuar kısmı, alet saati ve gövde kapağı olmak üzere 4 parçadan oluşur (Gençer vd., 2005).

Yağış Totalizatörleri: Her zaman ölçüm yapılması mümkün olmayan genellikle dağlık bölgelerde kullanılır. Aletin ağız alanı plüviometre ile aynıdır. Kar savruntu önleyici bir parça, yağışın toplandığı kap, ayaklı demir sehpa ve boşaltma musluğu olmak üzere 4 parçadan oluşur. Aletten, ilki kış mevsimine girildiğinde diğeri de kış mevsimi sonunda olmak üzere yılda 2 kez ölçüm alınmaktadır (Gençer vd., 2005).

3.1.2 Yağış Verilerinin Analizi

Yazıcı ya da yazıcı olmayan ölçerler sayesinde belirlenmiş yağış miktarları; tüm alana ve zamana bağlı değişiminin bulunması ile frekansının belirlenmesi için kullanılır. Bu işlemin gerçekleştirilmesi için öncelikle yağışölçerler tarafından ölçülememiş eksik verilerin tamamlanması gerekir. Bu tamamlama işlemi için 3 yöntem kullanılır. Bu yöntemler aşağıda verilmiştir.

- 1- Aritmetik ortalama metodu
- 2- Normal oran metodu
- 3- Ağırlıklı ortalama metodu

Eksik verilerin tamamlanmasının ardından yağış verilerindeki hatalar giderilir. Bu hatalar rastgele ve sistematik olmak üzere iki gruba ayrılır. Rastgele hata; yanlış okuma, yazma ya da değerlerin yuvarlanması sebebiyle meydana gelir. Sistematik hata ise; istasyonun başka bir yere taşınması, istasyon içerisindeki düzeneğin yanlış kurulması ya da aletin yağışı kısmen ya da sürekli ölçmesine engel olacak teknik ya da çevresel tüm problemler yüzünden meydana gelir (Usul, 2013).

Bu iki tip hata içerisinde rastgele hata olarak değerlendirilen durumlar verilere bazen negatif bazen ise pozitif olarak etkidiği için herhangi bir düzeltme işlemine genellikle gidilmez. Sistematik hataların gerçekleştiği durumlarda ise sürekliliği bozan daima negatif ya da pozitif bir etki oluşumu söz konusudur ve bu hatanın düzeltilmesi gerekmektedir. Sistematik hataların düzeltilmesi için uygunluk analizi yöntemi kullanılır.

Ölçme istasyonlarından elde edilen noktasal veriler; hataları düzeltildikten sonra hidrolojik çalışmalarda kullanılabilmesi için alansal ortalama yağış miktarı tespit edilir. Bu noktasal değerlerden alansal ortalama değere geçilmesi için 3 farklı yöntem geliştirilmiştir. Bu yöntemler aşağıda verilmiştir.

- 1-Aritmetik ortalama metodu
- 2-Thiessen çokgenleri metodu
- 3-Ortalama yağış yöntemi

3.2 Akım Ölçümleri ve Akım Verilerinin Analizi

Yüzeysel akım miktarının belirlenmesi hidrolojide en büyük problemlerden bir tanesidir. Su kaynaklarından verimli bir şekilde faydalanmak, projelendirmeyi uygun bir şekilde yapabilmek ve su tesislerinin potansiyellerini belirleyebilmek için su miktarının doğru bir şekilde ölçülmüş olması gerekmektedir. Bu yüzden akım miktarını belirlemek

amacıyla; seviye, hız ve kesit ölçümleri yapan yöntemler ve sistemler geliştirilmiştir (Bayazıt, 2013).

3.2.1 Akımların seviye ölçümüyle belirlenmesi

Bir akarsuda belirlenen bir kesitten, belirlenen zaman aralığında geçen su miktarının ölçülmesi amacıyla kurulan tesislere akım gözlem istasyonu adı verilir (Yılmaz, 2012). Akım gözlem istasyonlarında belirlenen bir zaman aralığındaki su seviyesinin tespiti için seviye değişimleri gözlenir. Bu gözlem için yazıcı ve yazıcı olmayan ölçerler kullanılmaktadır (Güresinli, 2010).

Limnometreler yazıcı olmayan ölçerlerdir. Akarsuyun herhangi bir yerinde belirli sürelerle yüksekliğinin (8:00-16:00 olmak üzere günde 2 kez) ölçülmesi prensibine dayanır. Bu ölçüm için üzerinde metrik ölçek bulunan tahta ya da metalden imal edilmiş cetvel şeklindeki aletler kullanılır. Bu alete eşel denilmektedir. Boyları genellikle 2 metredir. Eşellerin sıfır noktası akarsu tabanında talveg kotu olarak belirlenir. Bu sayede eşel ölçümü daima pozitif değer okunabilmektedir. Eşellerin; sıfır noktalarının sabit kalması, civarında değişikliğe uğramayan bir röpere bağlanması ve taşkın ya da fırtına sebebiyle yıkılmayacak sağlamlıkta imal ve tesis edilmesi gerekmektedir. Ölçüm şekilleri itibarıyla eşellerin; sabit, hareketli, tel ağırlıklı olmak üzere farklı çeşitleri bulunur (Güresinli, 2010).

Limnigraflar yazıcı ölçerlerdir. Su değerlerini otomatik olarak kayıt altına alırlar. Belirli bir zaman periyodu süresince devamlı olarak suyun yüksekliğini ölçer ve grafiğe aktarır. Genel olarak 4 tip limnigraf kullanılır. Yatay tamburlu limnigraflarda zaman parametresi tambur eksenine paralel olarak kaydedilmektedir. Dikey tamburlu limnigraflarda yatay olanlarının aksine ölçüm değerleri tambur eksenine paralel olarak kaydedilmektedir. Yatay rüleli limnigraflarda ise eşelin ölçümleri rulenin üzerine paralel olarak kaydedilmektedir. Ülkemizde genellikle Alman üretimi Ott ile Amerikan üretimi Stevens limnigrafları kullanılmaktadır (Güresinli, 2010). İstasyonlarda limnigraf bulunması durumunda günlük ortalama seviyesi için istasyon kayıtlarında yararlanılır.

Yazıcı veya yazıcı olmayan ölçerler yardımıyla nehirdeki su seviyesi ölçümü devamlı olarak yapılır. Ölçüm yapılan kesitin şekli genellikle düzgün değildir ve seviye değerlerinin debi değerlerine çevrilmesi arazide yapılan debi ölçümlerinin aynı andaki debi değerlerine çevrilmesiyle yapılır. Bu sayede ortalama seviye hesaplandıktan sonra anahtar eğrisinden günlük debiler okunabilmektedir.

3.2.3 Akım Verilerinin Analizi

Havza biriktirme etkisi sebebiyle herhangi bir güne ait debi ölçümü ondan önceki günleri debi ölçümleriyle doğrudan ilişkilidir. Ölçülen bu debiler hazne işletmesi, insandan kaynaklanan ölçüm hataları gibi sebeplerden ötürü hatalı değerler içerebilir. Bu değerlerin düzeltilerek akımın doğal akış debisine uygun değerlere sahip olması sağlanmalıdır (Bayazıt, 2013).

Günlük debilerin hesaplanmasının ardından istasyona ait debi gidiş çizgisi çizilir. Daha sonra çizilen bu debi gidiş çizgisi yardımıyla debinin belirli bir değere eşit ya da ondan büyük olduğu zamanki yüzdesi hesaplanır ve yatay eksene zaman yüzdeleri taşınarak debi süreklilik çizgileri elde edilir. Debi süreklilik çizgisi akarsularda belirli bir zaman dilimi içerisindeki debinin bilinmesi gerektiği durumlarda kullanılır (Bayazıt, 2013).

4. MATERYAL ve METOD

4.1. Yapay Zeka Teknolojisi

Modern dünyamızda programlama, bilgisayar sistemleri her türlü olay analizi ve bilgi depolanmasında kullanılmaktadır. Bu analiz ve depolamayı olaylar arasında ilişki kurmak için kullanabilen bu sistemler; matematiksel formülünün kurulması zor veya imkansız olan birçok problemin çözümünde sezgisel yöntemler kullanarak sonuca ulaşabilmekte problemi çözümleyebilmektedir. Bilgisayar sistemlerini bu kadar geliştiren ve bu özellikleri kazandıran çalışmalara ‘‘yapay zeka’’ çalışmaları adı verilmektedir. (Akkaya, 2005)

Yapay zeka teknolojisinin başlıca özelliği; belirli bir problem ya da olay için mevcut bilgilerle tecrübe kazanıp daha sonra bu tecrübe sayesinde çözümler üretebilmesidir. Günümüzde teknoloji ilerledikçe yapay zeka teknolojisi donanımı da gelişmekte ve çok daha hızlı çalışabilen, daha yüksek hafızalı ve çok daha karmaşık problemler için çözüm algoritmaları üretebilen bilgisayarlar ve bilgisayar teknolojileri geliştirilmektedir. Bununla birlikte gelişen yazılım teknolojisi; bilgi işleme, öğrenme, karar verebilme, problem çözme gibi yöntemlerin de geliştirilmesine öncülük etmektedir (Özel, 2011).

4.1.1 Yapay sinir ağları

Yapay sinir ağları adına yapılmış ilk çalışma 1943 Warren McCulloch ve Walter Pitts, nörolojik ağ modellerini tanıtmıştır. Nöronlara dayalı eşik anahtarları yeniden tasarladı ve bu tür basit ağların bile neredeyse her türlü mantık ya da aritmetik işlevi hesaplayabildiğini göstermiştir. 1947 yılına gelindiğinde Walter Pitts ve Warren McCulloch, 1943'ten itibaren çalışmalarında bahsedilmeyen, mekansal kalıpların sinir ağları tarafından tanınması adına çalışma yürütmüşlerdir (McCulloch and Pitts, 1943; Pitts and McCulloch, 1947).

Yapay zeka çalışmaları ile birlikte ortaya çıkan ve yapay zeka çalışmalarına büyük ölçüde katkı sağlayan alanlardan bir tanesi de yapay sinir ağları teknolojisidir. Yapay zeka teknolojisinin bir alt başlığı olan yapay sinir ağları teknolojisi; öğrenebilen sistemlerin temelini oluşturur. İnsan beyninde temel işlem elemanı olma görevi gören nöronu şekilsel ve işlevsel olarak taklit etmeyi amaçlayan yapay sinir ağları, biyolojik düşünce sisteminin simülasyonu için oluşturulmuş bir programdır. Bu sayede insana özgü

öğrenme yeteneğini bilgisayar ortamına taşıyan yapay sinir ağı teknolojisi; mevcut bilgisayar sistemlerine yüksek oranda “girdi verileriyle öğrenme” yeteneği sağlamaktadır (Yurtoğlu, 2005).


Yapay sinir ağları, sinir sistemlerinin bilgi işlem yeteneklerini modelleme girişimidir. Bu nedenle, her şeyden önce, biyolojik sinir ağlarının temel özelliklerini bilgi işlem bakış açısıyla değerlendirmemiz gerekir. Bu değerlendirme, daha sonra simüle edilip analiz edilebilen yapay sinir ağlarının soyut modellerini tasarlamamıza izin vermektedir (Rojas, 1996).

Günümüzde yapay sinir ağları ile alakalı dünya çapında çeşitli araştırmalar yapılmaktadır. Yapay sinir ağlarını eğitmek uzun zaman gerektirdiğinden, araştırmalar özellikle bu probleme odaklanmıştır. Burada ki amaç daha verimli ve yeni öğrenme algoritmaları keşfetmektir. 1943 yılından günümüze kadar olan süreçte yaşanan gelişmelerde bu konu temel odak noktasıdır. Gelişen yapay sinir ağları yakın gelecekte, sistemlerin özellikle robotların günlük hayatta yaşam kalitesinin artırılmasına yönelik nedenli önemli bir etken olabileceklerine işaret etmektedir (Efe ve Kaynak, 2000; Keskenler ve Keskenler, 2017).

4.1.1.1. Yapay sinir ağlarının yapısı

İnsanlarda sinir sistemini sinir hücreleri oluşturmaktadır. Beyinde bulunan yaklaşık 100 milyar sinir hücresi ve bu hücrelerin de yaklaşık 1 katrilyon bağlayıcısı bulunmaktadır. Beyindeki bu 100 milyar sinir hücresi ortak karakteristik özelliklere sahiptir. Ancak beynin haberleşme sisteminde yer alan sinir hücreleri sinyal alma, işlem yapma ve elektrokimyasal sinyallerin sinir ağları içindeki iletimi sağlamakla görevlidir (Akkaya, 2007).

Sinir sistemleri, değişken karmaşıklıkta küresel mimarilere sahiptir, ancak hepsi benzer yapı taşlarından, sinir hücreleri veya nöronlardan oluşur. Bir sinir hücresi nöron olarak adlandırılır ve beyinde bilgi giriş-çıkışı olan bir anahtar görevi görür. Bu anahtar, bilgi girişine isabet eden diğer nöronları yeterince uyaran varsa aktif hale gelir ve bilgi çıkışında diğer nöronlara sinyal gönderir. Tipik bir nöronun yapısı Şekil 4.1.’de verilmiştir (Kriesel, 2009).




Şekil 4.1. Nöron yapısı (Kriesel, 2009).

Günümüzdeki birçok veri işleme sistemi ve bilgisayar programlama algoritmaları; mevcut teknolojik imkanlarla bile nöronlar arasındaki veri paylaşımı ve genel olarak bir beynin düşünce sistemi kadar başarılı ve verimli olamamaktadır. Bu yüzden yapay sinir ağları geliştirilmiştir. Yapay sinir ağlarının çalışma prensibi ve ağı oluşturan elemanlar tipik bir nöron yapısı ile benzerlik göstermektedir. Bu benzer elemanlar Çizelge 4.1.'de verilmiştir.

Çizelge 4.1. Biyolojik sinir sistemi ve yapay sinir ağları benzerliği (Yalçın, 2012).

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Dentrit	Toplama Fonksiyonu
Hücre gövdesi	Aktivasyon Fonksiyonu
Akson	Çıkış katmanı
Sinaps	Bağlantı Ağırlıkları

Bir yapay sinir hücresi; giriş, toplama fonksiyonu, giriş ile toplama fonksiyonunu birbirine bağlayan bağlantı ağırlıkları, transfer fonksiyonu ve çıkış olmak üzere beş bölümden oluşmaktadır. Bu beş yapay sinir hücresinin yapısı Şekil 4.2.'de verilmiştir.



Şekil 4.2. Yapay sinir hücresi yapısı.

Giriş ($g_1, g_2, g_3, \dots$): Yapay sinir hücresine dış uzaydan gelen verilerdir (Önal, 2009).

Ağırlıklar ($a_1, a_2, a_3, \dots$): Ağırlık değerleri bir nörondan diğerine aktarılan verinin önemini ve hücre üzerindeki etkisinin ayarlanmasını sağlamaktadır (Önal, 2009).

Toplama Fonksiyonu: Toplama fonksiyonu, bir nörona gelen net girdinin hesaplanmasında rol almaktadır. Giriş değerleri ağırlık değerleriyle çarpılarak burada değişik fonksiyonlar yardımıyla birleştirilir (Önal, 2009).

Bu fonksiyon ve bunun dışında genellikle kullanılan diğer toplama fonksiyonları Çizelge 4.2.'de verilmiştir.

Çizelge 4.2. Toplama f-fonksiyon örnekleri (Öztemel, 2006).


Toplama Foksiyonları	Açıklama
Toplam $Net = \sum_{i=1}^n T_i \cdot C_i$	Ağırlık değerleri ile çarpılmış olan girdi verileri toplanır ve ağa gelen net girdi hesaplanır.
Çarpım $Net = \prod_i T_i \cdot C_i$	Ağırlık değerleri girdi değerleri ile sonrasında bulunan bu değerler de birbirleri ile çarpılır.
Maksimum $Net = \max (T_i \cdot C_i) \ i = 1, 2, \dots n$	n adet girdi değeri ağırlıkları ile çarpılır ve bu değerler arasından en büyük olanı sinir hücresinin net girdisi olarak kabul edilir.
Minimum $Net = \min (T_i \cdot C_i) \ i = 1, 2, \dots n$	n adet girdi değeri ağırlıkları ile çarpılır ve bu değerler arasından en küçük olanı sinir hücresinin net girdisi olarak kabul edilir.
Çoğunluk $Net = \sum_i sng (T_i \cdot C_i)$	N adet girdi değeri ağırlıkları ile çarpılır ve bu değerler pozitif ve negatif olarak gruplandırılır. Pozitif ve negatif değerlerin hangisinin sayısı daha çoksa o toplam değer hücrenin net girdisi olarak kabul edilir
Kümülatif toplam $Net = Net_{(eski)} + \sum_i T_i \cdot C_i$	Hücreye gelen girdi verileri ağırlıklı olarak toplanır ve önceki gelen diğer bilgilere eklenerek net girdi değerleri bulunur

Aktivasyon Fonksiyonu: Transfer fonksiyonu olarak da adlandırılır. Hücreye gelen girdi verilerini işleyerek hücrenin bu girdiye karşılık gelen çıkış değerlerini belirler.

Toplama fonksiyonunda da olduđu gibi birden fazla transfer fonksiyonu bulunmaktadır. Bu fonksiyonlar arasında en yaygın olarak kullanılanı sigmoid transfer fonksiyonudur. Eşik fonksiyonu olarak da adlandırılan sigmoid fonksiyonu; doğrusal olmayan, seviyeli ve monoton olarak artan bir fonksiyondur. Fonksiyon aşağıdaki şekilde Eşitlik 4.2 ile edilmektedir (Can, 2012).

$$F(x) = \frac{1}{1+e^{-x}} \quad (4.2)$$

Buradaki x , toplam fonksiyonu tarafından hesaplanmış olan giriş değerlerini göstermektedir. Fonksiyon grafiđi Şekil 4.3.'de verilmiştir.



Şekil 4.3. Sigmoid fonksiyon grafiđi (Özel, 2011).

Sigmoid fonksiyonu en çok tercih edilen ve paket programlarda en yaygın şekilde bilgisayar program dillerine uyarlanmış fonksiyondur. Bu fonksiyonun dışında; Lineer, Step, Sinüs, Eşik Deđer ve Hiperbolik Tanjant gibi diđer fonksiyonlardan da yararlanılmaktadır. Kullanılan diđer transfer fonksiyonları Çizelge 4.3.'de verilmiştir.

Çizelge 4.3. Transfer fonksiyonu örnekleri (Öztemel, 2006).


Aktivasyon Fonksiyonu	Açıklama
Lineer $F(x) = x$	Girdi değerleri hiçbir matematiksel işleme tabi tutulmadan direk çıktı değeri olarak kabul edilir
Step $F(x) = 1 \quad x > 0$ $F(x) = 0 \quad x \leq 0$	Girdi değerleri belirlenmiş olan eşik değerinin altında ya da üstünde olması durumuna göre hücrenin çıktısı 1 veya 0 değerlerini alır
Sinüs $F(x) = \sin(x)$	Sinüs fonksiyonuna uygun dağılım gösteren durumlarda kullanılır
Eşik değer $F(x) = 0 \quad x \leq 0$ $F(x) = x \quad 0 < x < 1$ $F(x) = 1 \quad x \geq 1$	Girdi değerlerinin 0 ya da 1'den büyük ya da küçük olmasına göre 0-1 aralığında değerler alabildiği fonksiyondur. Değer 1'den büyük ise 1, 0'dan küçük ise 0 değerlerini alır
Hiperbolik tanjant $F(x) = (e^x + e^{-x}) / (e^x - e^{-x})$	Gelen girdi değerleri tanjant fonksiyonundan geçirilerek kullanılır

Çıkış: Transfer fonksiyonu ile belirlenmiş çıktı değerleridir. Üretilen bu değer sonuç kısmına ya da başka bir hücreye giriş verisi olarak kullanılmak üzere gönderilir. Hücre kendi çıktısını tekrardan girdi olarak da gönderebilir. (Öztemel, 2006; Can, 2012)

4.1.1.2. Yapılarına göre yapay sinir ağları

Yapay sinir ağları iç yapı bağlantılarına göre gruplandırıldığında geri beslemeli ve ileri beslemeli olmak üzere ikiye ayrılabilir.


Geri beslemeli yapay sinir ağları: Geri beslemeli yapay sinir ağlarında çıkış ve gizli katmanlardaki sonuçlar, giriş katmanına ya da kendilerinden önceki katmanlara geri gönderilir. Bu sayede giriş verileri hem ileri doğru hem de geriye doğru aktarılır. Geri besleme işlemi katmanlar ve hücreler arasında olabildiği için ağı doğrusal olmayan dinamik bir yapısı vardır. Bu sebeple verilerin geri gönderilerek hücre ya da katmanları besleme işleminin yapılışına göre farklı yapı ve davranışta geri beslemeli yapay sinir ağları geliştirilebilir. En yaygın geri beslemeli yapay sinir ağları Hopfield, Elman ve Jordan ağlarıdır (Bolat, 2003 Şeker, S. 2001 Tosun, 2007). Geri beslemeli bir yapay sinir ağı yapısı Şekil 4.4.'de verilmiştir.



Şekil 4.4. Geri beslemeli ağ yapısı (Tosun, 2007).

İleri beslemeli yapay sinir ağları: İleri beslemeli ağlarda katman nöronları girişten çıkışa doğru sıralı bir şekilde dizilir. Bir katman yalnızca kendinden sonra gelen diğer bir katman ile bağlantı kurar. Ağa gelen bilgi ağ eğer tek katmanlı ise ilk önce giriş katmanına ve daha sonra çıkış katmanına doğru sıralı bir şekilde yol izler. Ağ yapısı eğer çok katmanlı ise ağa gelen bilgi akışı giriş katmanından sonra gizli katmana ve daha sonrasında çıkış katmanına aktarılır (Yalçın, 2012).


Ağın giriş ve çıkış katmanları arasında bulunan gizli katmanları nöron sayıları; çözülmeye çalışılan problem yapısına ve içeriğine göre belirlenmektedir. Gizli katmanların sayısının belirlenmesi adına herhangi bir analitik yöntem geliştirilememiştir ve katman sayıları deneme yanılma yöntemiyle düzenlenmektedir (Efe ve Kaynak, 2000; Ergin, 2012). İleri beslemeli bir yapay sinir ağı yapısı Şekil 4.5.'de verilmiştir.



Şekil 4.5. İleri beslemeli ağ yapısı (Yaşar, 2004).

4.1.1.3. Tek katmanlı ileri beslemeli yapay sinir ağıları

1943 yılında ilk kez geliştirilen yapay sinir ağıları, ilk başlarda girdilerin ağırlıklı toplamalarının giriş değerleriyle kıyaslayarak çıktılar üreten bir yapıdaydı. Eşik değerinden büyük ya da eşit değerler 1, eşik değerinin altında kalan değerler ise 0 sonucuna ulaşıyordu. 1950'li yıllara gelindiğinde ilk basit tek katmanlı algılayıcı modeli geliştirilmiştir. Basit algılayıcı ya da tek katmanlı algılayıcı olarak da adlandırılan bu yapay sinir ağı modeli bir giriş bir de çıkış elemanından oluşmaktadır ve gelen verileri ağırlık değerleri ile çarparak elde edilen değerleri sabit bir sayı ile toplayıp çıkış katmanına gönderen bir yapıya sahiptir (Yetkin, 2014). Ağ; çıktı değerlerinin sıfır olmasını engelleyen bir eşik değerine sahiptir ve bu eşik değer girdisi her zaman birdir. Giriş katmanında ağırlık değerleriyle çarpılmış veriler eşik değeri ile toplanır ve çıkış katmanına aktarılır (Önal, 2009). Tek katmanlı algılayıcı yapısı Şekil 4.6.'da verilmiştir.




Şekil 4.6. Tek katmanlı algılayıcı yapısı (Yetkin, 2014).

4.1.1.4. Çok katmanlı ileri beslemeli yapay sinir ağıları

Tek katmanlı algılayıcılar basit ve hızlıdır ama yalnızca karmaşık olmayan lineer problemlerin çözümünde kullanılabilmektedirler ve mühendislik uygulamaları açısından yeterli olmadıkları birçok durum bulunmaktadır. Bunun sebebi tek bir ağırlık matrisine sahip olmalarından kaynaklanmaktadır. Bu yüzden karmaşık ve non-lineer problemlerde çok katmanlı yapay sinir ağıları kullanılır.

Çok katmanlı algılayıcılarda veriler giriş katmanında gelir ve gizli katmanlara aktarılır. Gizli katmanlardaki işlemlerden elde edilen sonuçlar çıkış katmanına gönderilir. İstenen hata toleransına ulaşınca kadar giriş katmanını, gizli katman ve ağırlık değerleri üzerinde

değişiklikler yapılarak işleme devam edilir. (Öğücü, 2006). En basit haliyle çok katmanlı algılayıcı yapısı Şekil 4.7.'de verilmiştir



Şekil 4.7. Çok katmanlı algılayıcı yapısı (Yetkin, 2014).


4.1.1.5. Yapay sinir ağlarında öğrenme

Yapay sinir ağları girdi verilerindeki değişiklikleri değerlendirip öğrenerek çıktılar üreten bir yapıya sahiptir. Bu öğrenme sürecinde, dış uzaydan alınan veriler giriş katmanından toplama fonksiyonuna ardından aktivasyon fonksiyonuna gönderilir. En sonunda çıkış katmanına ulaşan veriler tüm bu katman değişimi esnasında sürekli olarak değişime uğrar. Yapay sinir ağı gerçek verilerle kendi çıktılarını sürekli olarak karşılaştırır ya da mevcut bir gerçek çıktı verisine sahip olmadan belirli algoritmalar kullanarak verilerini düzeltir. Tüm bu süreç boyunca ağırlık değerlerinin sürekli olarak değişimi ve sonuca ulaşılana kadar geçen zamana “öğrenme” denilmektedir (Yılmaz, 2015).

Yapay sinir ağlarında birçok öğrenme yöntemi vardır. Genel olarak en çok tercih edilenler öğrenme algoritmaları; danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılmaktadır (Yılmaz, 2015).


Danışmanlı (Eğiticili) Öğrenme: En yaygın öğrenme algoritmalarından biridir. Yapay sinir ağının eğitim verileri ve bu eğitim sonucu ağın performansının test edilmesi için test verileri bulunmaktadır. Öncelikle eğitim verileri ağı işlenir ve ağın ürettiği çıkış verileri istenen verilerle karşılaştırılır. Aradaki hata miktarına göre ağırlık değerleri düzenlenir ve bu işlem eğitim verileri istenen hata değerine ulaşınca kadar devam eder. Ağın eğitim süreci tamamlandıktan sonra ağın performansını test etmek için kullanılacak olan test verileri ağın giriş katmanından gönderilir. Ağın eğitilmesinden sonra mutlaka

test verileriyle tekrardan sınanması ve hata miktarının gözlemlenmesi gerekmektedir. Eğer test aşaması da istenen başarıyı gösteremezse ağ mimarisi, eğitim veri miktarı ve ağırlık değerleri yeniden düzenlenir (Şahin, 2002; Tosun, 2007). Danışmanlı öğrenme yapısının şematik gösterimi Şekil 4.8.'de verilmiştir.



Şekil 4.8. Danışmanlı öğrenme blok şeması (Canan, 2006).


Danışmansız (Eğitici-siz) Öğrenme: Eğitici-siz, danışmansız ya da başka bir adıyla kendi kendini organize eden öğrenme yönteminde harici hiçbir öğretici kullanılmaz. Giriş verilerinden elde edilen bilgilere göre ağ kendi öğrenme kurallarını kendisi düzenler (Haykin, 1994; Canan, 2006). Gözetimli öğrenme ile aralarındaki fark eğitim veriler için çıktı değerlerinin bilinmesine gerek olmamasıdır. Bu öğrenme algoritmasıyla eğitilen ağ, danışmanlı öğrenme yöntemine göre daha anlaşılabilir (Tosun, 2007). Eğitici-siz öğrenme yapısının şematik olarak gösterimi Şekil 4.9.'da verilmiştir.



Şekil 4.9. Danışmansız öğrenme blok şeması (Sancakdar, 2002).

Takviyeli (Destekleyici) Öğrenme: Takviyeli öğrenme danışmanlı öğrenme algoritmasına oldukça benzemektedir. Danışmanlı öğrenme algoritmasında elde edilen çıktılar istenen çıktılarla karşılaştırılırken; takviyeli öğrenmede ağın çıktılarının ne ölçüde doğru olduğunu belirten bir skor ya da derece ağa tanıtılır. Bu sayede üretilen verilerin

hata oranları bu skor ya da derecelere göre düzeltilir (Saraç, 2012). Takviyeli öğrenme yapısının şematik olarak gösterimi Şekil 4.10.'da verilmiştir.



Şekil 4.10. Takviyeli (destekleyici) öğrenme blok şeması (Yazıcı, 2010; Sarı, 2016).

4.1.1.6. Yapay sinir ağlarında öğrenme kuralları

Yapay sinir ağlarının eğitimi esnasında kullanılacak yöntemler istenen verilere ulaşılmasında büyük bir öneme sahiptir. Ağın veri yapısı arasındaki ilişkiyi öğrenmesi bu verilere ait problemlerin çözülmesinde hata oranını minimuma düşüreceğinden öğrenme kurallarına ağın eğitiminde büyük rol düşmektedir (Doğan, 2010).

Ağda öğrenme işlemi deneme-yanılma yoluyla bir dizi tekrarlamaların sonucunda istenen hata oranına ulaşılması esasına dayanmaktadır. Ağın eğitimi için birbirinden farklı optimizasyon yöntemleri bulunmasına karşın istenen optimum veri değerlerini kesin olarak bulabilecek bir algoritma bulunmamaktadır. Yapay sinir ağlarında yaygın olarak kullanılan bazı öğrenme kuralları aşağıda verilmiştir (Doğan, 2010).

- 1-Hebb Kuralı
- 2-Hopfield Kuralı
- 3-Kohonen Kuralı
- 4-Delta Kuralı


4.1.1.7. Çok katmanlı ileri beslemeli ağlarda geri yayımlı öğrenme

Çok katmanlı algılayıcılar danışmanlı öğrenme stratejisine göre çalışmaktadırlar. Bu ağlara girilen eğitim verileri; bulunması istenen verilerle birlikte ağa verilir. Ağın görevi her giriş değeri için o girdiye karşılık gelen çıktı değerini minimum hata oranıyla üretmektir. Geri yayılım ağının bir diğer ismi de genelleştirilmiş delta kuralıdır. Bu kural en küçük kareler yöntemine dayalı delta öğrenme kuralının gelişmiş ve genelleştirilmiş

halidir. Ağı eğitimi için gerekli eğitim verilerine ihtiyaç duyan bu ağ yapısında, ara katmanlardaki birimlerinin hatalarının, çıkış katman verilerindeki hatalarının geriye yayılması ile belirlenmesi şeklinde bir mantık söz konusudur. Bundan dolayı geri yayılım öğrenme algoritması olarak isimlendirilmektedir (Öztemel, 2006).


Geri yayılım ağı, tek katmanlı algılayıcılardan farklı olarak doğrusal olmayan problemlerin çözümünde kullanılabilir ve bu da ileri beslemeli geri yayımlı ağlara çok daha geniş bir kullanım alanı sunmaktadır. Bu kullanım alanlarının daha da genişletilmesi için ve daha geniş uygulama alanları bulunabilmesi için ağda sigmoid transfer fonksiyonu ile doğrusal olmaktan çıkarılmış birden fazla çıktı birimi kullanılabilir. Bu sayede çıktı verileri kesikli yapıdan sürekli hale geçirilir ve bu sayede de yumuşak geçişli karar bölgeleri elde edilmiş olunur. Bunun anlamı çıkış verilerinin tek katmanlı algılayıcılardaki $-1,0,1$ değerlerinin haricinde $[-1, 1]$ değerleri aralığında çıktı verisi elde edebilmesidir (Bayır, 2006).

Bir adet giriş katmanı, bir adet çıkış katmanı ve bir adet gizli katmanı bulunan basit bir ileri beslemeli geri yayılım ağı yapısı Şekil 4.11.'de verilmiştir.



Şekil 4.11. İleri beslemeli geri yayımlı yapay sinir ağı yapısı (Aydın 2017).

Bu ağ yapısında iki farklı sinyal çeşidi bulunmaktadır. Şekil 4.12.'de her iki sinyalin bağlantıları ve yönleri gösterilmiştir. Şekilde sol taraf giriş katmanını sağ taraf ise çıkış katmanını temsil etmektedir.



Şekil 4.12. Sinyal bağlantıları ve doğrultuları (Yurtoğlu, 2005).

Şekil 4.12.'de görüldüğü gibi yönleri birbirine zıt olan bu iki sinyal çeşidi fonksiyon sinyalleri ve hata sinyalleri olarak adlandırılmaktadır. Fonksiyon sinyali, ağına girdi verilerini ağ içerisinde ileri doğru yayılan ve çıkış katmanına çıktı sinyali olarak giden bir girdi sinyalidir. Fonksiyon sinyali olarak anılmasında iki temel sebep bulunmaktadır. Bunlardan ilki ağına çıktısının elde edilebilmesi için gerekli olan fonksiyonları uyguladığının kabul edilmesidir. Bir diğer sebep ise fonksiyon sinyalinin birbirine bağladığı her bir nöron gelen sinyalleri ve o nörona uygulanan ağırlıkların bir fonksiyonu olarak hesaplanmaktadır. Bu yüzden fonksiyon sinyalleri girdi sinyalleri olarak da adlandırılır. Hata sinyali ise fonksiyon sinyalinin tersi yönde bir hareket doğrultusuna sahiptir. Tüm nöronları birbirine hata tabanlı fonksiyon ile bağladığından bu ismi almıştır. (Parker , 1987; Yurtoğlu, 2005).

İleri beslemeli geri yayılım ağı temelinde aşağıda verilmiş olan iki safhadan oluşmaktadır.

İleri Besleme Aşaması: İleri besleme aşaması ağına gönderilen verilerin işleme alındığı kısımdır. Giriş katmanına gelen girdi verileri giriş katmanına gelene kadar hiçbir değişime uğramaz.

Giriş katmanından gizli katmanlara gönderilirken nöronlar arasında belirlenmiş ağırlık değerleri ile çarpılır. Ağırlık değerleriyle çarpılmış olan girdiler ara katmanlarda seçilen toplama fonksiyonuna göre işleme alınır ve hücrenin net girdisi hesaplanır. Ağırlıklı toplam fonksiyonu seçilen bir ağda ara katmanın net girdisi Eşitlik 4.3 yardımıyla hesaplanır (Öztemel, 2006).

$$\text{Net}_j = \sum_{k=1}^n p_{ki}^{ga} a_k \quad (4.3)$$

Burada p_{ki}^{ga} değeri, k giriş katmanı elemanını j ara katmanın elemanını bağlayan ağırlık bağlantı değerleri, a_k ise giriş katmanındaki girdi verilerini temsil etmektedir. Net_j j ara katman elemanının toplama fonksiyonundan geçirildikten sonra elde edilen değeridir. Bu değer daha sonra bir aktivasyon fonksiyonundan geçirilir. Burada dikkat edilmesi gereken nokta türevi alınabilir bir fonksiyon seçilmesidir. Geri yayılım açısından ötürü aktivasyon fonksiyonunun türevlenebilir olması gerekmektedir. Sigmoid fonksiyonu diğer aktivasyon fonksiyonlarına göre daha fazla kullanılmaktadır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu seçildiğinde ara katman çıkış değeri Eşitlik 4.4 ile hesaplanır (Öztemel, 2006).

$$a_j = \frac{1}{1 + e^{-(NET_j + B_j)}} \quad (4.4)$$

Burada a_j ara katman elemanının çıkış değeridir. B_j ise j ara katman elemanına bağlı bias değer elemanının ağırlık değerini göstermektedir. Bu eşik değeri sabit bir değer olup 1'e eşittir. Ağın eğitimi esnasında ağ bu değeri kendisi belirlemektedir. Ara katmanda bulunan tüm nöronlar ve çıktı katmanında bulunan nöronların çıktıları, kendilerine gelen NET girdilerin hesaplanması ve sigmoid fonksiyonundan geçirilmesi ile birlikte hesaplanmış olur. Çıktı katmanından geçen çıkış verileri ($a_1, a_2, \dots$) bulunduğu ileri besleme safhası tamamlanmış olur (Öztemel, 2006).

Geri Yayılma Aşaması: Ağın geri yayılım aşaması; hata sinyallerinin bulunarak, ağırlıkların bu sinyallere göre güncellenmesidir. Hata değeri istenen çıktı ile ağın ürettiği çıktı arasındaki farktır ve Eşitlik 4.5 ile hesaplanır (Yaşar, 2004).

$$h_{jh} = g_{ji} - a_j \quad (4.5)$$

h_{jh} hata miktarı, g_{ji} istenen gerçek çıktılarıdır. Her girdi grubu için hata karelerinin toplamı h_{jtop} Eşitlik 4.6 ile hesaplanmaktadır (Alp, 2003).

$$h_{jtop} = \frac{1}{2} \sum_j h_{jh}^2 \quad (4.6)$$

Toplam hatanın minimum olabilmesi için, işlemci nöronları hatayı önceki katmanlara doğru geri yayar ve hatanın iletimi katmanlar halinde geriye doğru olmaktadır. Hata sinyalleri önceki katmanlara ulaştığında bağlantı ağırlıkları delta kuralı yardımıyla düzenlenir (Alp, 2003).

Ara katman ve çıktı katmanı arasındaki ağırlıklar; gizli katmandaki i işlem elemanını çıktı katmanındaki j elemanına bağlayan bağlantıların ağırlıklarının değişimi p_{ij}^{ac} olmak üzere herhangi bir t zaman diliminde ağırlık değerinin değişim miktarı Eşitlik 4.7 ile hesaplanır (Sarı, 2016).

$$\Delta p_{ij}^{ac}(t) = \lambda \delta_j a_j + \alpha \Delta p_{ij}^{ac}(t-1) \quad (4.7)$$

Burada λ değeri öğrenme oranının ve α ise momentum değerini gösterir. Geriye doğru yayılma algoritmasında temel amaç ortalama kare hatasının iterasyonla en aza indirilmesidir. Bunun mümkün olabilmesi için yukarıdaki denklemde kullanılan δ_j hata gradyanının hesaplanması gerekmektedir. δ_j j işlem elemanına ait hatayı gösterir ve Eşitlik 4.8 ile hesaplanır. (Alp, 2003; Es, 2013; Sarı, 2016).

$$\delta_j = f'(m) \cdot h_{jh} \quad (4.8)$$

Burada $f'(m)$ aktivasyon fonksiyonunun türevidir. Aktivasyon fonksiyonu sigmoid fonksiyonu seçilirse δ_j hata gradyanı Eşitlik 4.9'da gösterildiği gibi hesaplanır.

$$\delta_j = a_j * (1 - a_j) * h_{jh} \quad (4.9)$$

Değişim miktarı hesaplandıktan sonra ağırlıkların t zaman dilimi sonrasındaki değerleri Eşitlik 4.10 yardımıyla hesaplanır.

$$\Delta p_{ij}^{ac}(t) = \Delta p_{ij}^{ac}(t-1) + \alpha \Delta p_{ij}^{ac}(t) \quad (4.10)$$

Bu işlemden sonra bias değerlerinin de ağırlıklarının değiştirilmesi gerekir. Bunun için değişim miktarı hesaplanır. Çıktı katmanındaki işlem elemanının bias değeri ağırlığı μ_j^{ac} olarak gösterilirse, bu eleman çıktısının sabit bir değer ve 1 olması nedeniyle değişim miktarı herhangi bir t anı için Eşitlik 4.11'den yararlanılır.

$$\Delta \mu_j^{ac}(t) = \lambda \delta_j + \alpha \Delta \mu_j^{ac}(t-1) \quad (4.11)$$

ve yeni bias değeri Eşitlik 4.12 ile hesaplanır.

$$\Delta \mu_j^{ac}(t) = \Delta \mu_j^{ac}(t-1) + \Delta \mu_j^{ac}(t) \quad (4.12)$$

Gizli katmanların birbiri arasında ya da gizli katman ile giriş katmanı arasındaki ağırlıklar değiştirilirken çıktı katmanındaki tüm işlem elemanlarının hatası dikkate alınır. Ara katman ve giriş katmanı arasındaki ağırlık değişimi Δp_{ki}^{ga} olmak üzere ara katmandaki i , işlem elemanını giriş katmanındaki k , işlem elemanına bağlayan bağlantıların ağırlıklarının herhangi bir t zaman diliminde değişim miktarı Eşitlik 4.13 ile hesaplanır.

$$\Delta p_{ki}^{ga}(t) = \lambda \delta_i a_k^{ga} + \alpha \Delta \mu_{ki}^{ga}(t-1) \quad (4.13)$$

Yukarıdaki denklemde yer alan δ_i hata gradyanı Eşitlik 4.14 ile hesaplanır.

$$\delta_i = f'(m) \sum_j \delta_j p_{ij}^{ga} \quad (4.14)$$

Sigmoid aktivasyon fonksiyonu seçildiği kabul edilirse hata değeri Eşitlik 4.15 ile hesaplanır.

$$\delta_i = a_i (1 - a_i) \sum_j \delta_j p_{ij}^{ga} \quad (4.15)$$

Değişim miktarı bulunduktan sonra ağırlık değerlerinin herhangi bir t anındaki yeni değerleri Eşitlik 4.16 ile bulunur.

$$p_{ki}^{ga}(t) = p_{ki}^{ga}(t-1) + \Delta p_{ki}^{ga}(t) \quad (4.16)$$

Ara katmanla çıkış katmanı arasındaki bias değerlerinde olduğu gibi, ara katman ile giriş katmanı arasındaki bias ağırlık değerleri de güncellenir. Bias değişim ağırlık değeri μ_i^{ga} , Eşitlik 4.17 ile hesaplanır.

$$\Delta \mu_i^{ga}(t) = \lambda \delta_i + \alpha \Delta \mu_i^{ga}(t-1) \quad (4.17)$$

Ağırlıkların yeni değerleri herhangi bir t anı için Eşitlik 4.18 ile hesaplanır.

$$\mu_i^{ga}(t) = \mu_i^{ga}(t-1) + \Delta \mu_i^{ga}(t) \quad (4.18)$$

Bir iterasyon önce ileri yönde daha sonra da geri yönde yapılarak hesaplanır. İstenilen hata düzeyine ulaşıncaya kadar ağırlık değişimleri devam etmektedir (Sarı, 2016).

4.1.1.8. Yapay sinir ağlarında ölçüm hatalarının belirlenmesi

Elde edilen sonuçlar gerçek sonuçlarla karşılaştırılır. Aradaki hata miktarları ve tahminlerin doğrulukları ortalama karesel hata (MSE) ve belirlilik katsayısı (R^2) değerlerinin hesaplanmasıyla bulunur.

-Ortalama Karesel Hata (MSE): Tahmin edilen değerlerin ortalama kare sapma miktarını verir. Ortalama karesel hata değeri ne kadar küçükse, veri tahmin başarısı da o kadar yüksektir. Ortalama karesel hata (MSE) değeri Eşitlik 4.19 ile hesaplanır.

$$MSE = \frac{1}{N} \sum_1^N (y_i - \hat{y}_i)^2 \quad (4.19)$$

Burada N adet verinin ortalama karesel hatası için; y_i ifadesi tahmin verilerini, $\hat{y}_i$ ifadesi ise gerçek verileri ifade etmektedir (Kırbaş, 2017).

-Belirlilik Katsayısı (R^2): Tahmin verilerinin gerçek verilerle olan uyumunun ne ölçüde sağlandığının göstergesi olarak açıklanabilen değişim miktarının toplam değişim miktarına oranı şeklinde tanımlanır ve Eşitlik 4.20 ile hesaplanır.

$$R^2 = \frac{\sum_1^N (\hat{y}_i - \bar{y})^2}{\sum_1^N (\hat{y}_i - y_i)^2 + \sum_1^N (\hat{y}_i - \bar{y})^2} \quad (4.20)$$

Burada ortalama karesel hata denkleminde farklı olarak $\bar{y}_i$ ifadesi kullanılır. Bu ifade gerçek veri değerlerinin ortalamasıdır. R^2 değerin 1'e yakın olması tahmin verilerinin istenilen veri değerlerini tahminde başarılı olduğunu gösterir (Yavuz, 2009).

4.1.1.9. Yapay sinir ağlarında momentum ve öğrenme oranı

Momentum değeri α , ağdan elde edilen sonuçların yerel minimum değerlerde takılıp kalmasını önlemek amacıyla ve hata miktarının azaltılması için kullanılır. Değer olarak [0,1] değer aralığında seçilen bu değer ağı verildiğinde; ağırlık değerleri ve eğim aynı işaretli ise ağırlıklara uygulanacak düzeltme miktarı artar, farklı işaretli ise azalır (Sağırlıoğlu, 2003; Levent ve Diri, 2014).


Öğrenme oranı λ , momentum değeriyle benzer şekilde yapay sinir ağlarının geri yayılım algoritmasında kullanılan bir parametredir. Momentum değerine benzer olarak ağı üreteceği değerlerin yerel minimum değerlerde takılmasını önlemek ve ağı performansını kullanmak amacıyla ağırlık değişimleri formüllerinde yer alırlar. Sistemin

performansı bakımından öğrenme oranı büyük bir etkiye sahiptir. Öğrenme oranı deneme yanılma yoluyla ağın ihtiyaç duyduğu şekilde $[0,1]$ değer aralığında istenilen değer seçilebilir. Öğrenme oranının sıfıra yakın seçilmesi ağın daha doğru sonuçlara ulaşmasını sağlar ancak süre açısından olumsuz etkilenir. Büyük değerlerin seçilmesi de ağın veri üretim hızını artırır ancak hata miktarını artırabilir. Yapay sinir ağlarında hata miktarı ve süre büyük önem teşkil ettiğinden bu iki temel husus dikkate alınarak öğrenme oranı belirlenmelidir (Elmas, 2003; Levent ve Diri, 2014).

4.2. Evrimsel Algoritmalar

Evrimin temel prensibinden hareketle hazırlanmış arama yöntemlerinin tümü evrimsel algoritmalar olarak ya da evrimsel hesaplama yöntemleri olarak adlandırılmaktadır. Özellikle son 20 yıl içerisinde evrimsel algoritmalara olan ilgi büyük oranda artmıştır (Taşkın ve Emel, 2009).

Evrimsel Algoritmalar genel yapıları itibariyle çeşitli paradigmalara sahiptir. Bu paradigmlar; evrimsel programlama, evrim stratejileri, genetik programlama ve genetik algoritmalar ve yeni bir yöntem olan gen ifade programlama olarak sıralanabilir. Ayrıca bu paradigmalara ek olarak melez yöntemler olarak adlandırılan bazı karma yöntemler de mevcuttur. Bu melez yöntemlerin sınıflandırılması ve özelliklerinin kategorize edilmesi zor olacağından tüm bu yöntemler evrimsel algoritmalar başlığı altında toplanmıştır. Evrimsel algoritmaların genel işleyişi Şekil 4.13.'de gösterilmektedir (Dipankar ve Zbigniev, 1997; Taşkın ve Emel, 2009).




Şekil 4.13. Evrimsel algoritmaların genel yapısı (Dipankar ve Zbigniev, 1997; Taşkın ve Emel, 2009).

Evrimsel Algoritma her t aşamasında bireylerden meydana gelen bir $P(t)$ popülasyonunu içermektedir. Her bir birey, hesaplanan problem için potansiyel çözümleri ifade etmektedir. Her çözümün uyum değerleri hesaplanır ve sonraki adımda bu uyum değerleri içinden yüksek olanları seçilir. Bu seçilen bireyler yeni bir popülasyonu oluşturur ve bu yeni popülasyonun bazı üyeleri çaprazlama ve mutasyon operatörleri vasıtasıyla değişime uğrar. Bu işlemin ardından yeni popülasyonun uyum değerleri tekrar hesaplanır ve tüm bu adımlar bir durdurma kriteri sağlanana dek devam eder (Taşkın ve Emel, 2009).

4.2.1. Gen ifade programlama

Genetik Algoritmalar, John Holland tarafından 1960'larda icat edilmiş ve biyolojik evrim teorisini bilgisayar sistemlerine uygulanmıştır (Holland, 1975). 1970'li yıllara gelindiğinde John Holland ve bir grup öğrencisi tarafından Michigan üniversitesinde gerçekleştirilen çalışmalar yardımıyla genetik algoritmalar ortaya çıkmıştır. Genetik algoritmaların ortaya çıkmasında Holland ve ekibinin evrim fenomeninin teorik özelliklerini daha iyi çözümlemeye yardımcı olacak bir bilgisayar programı geliştirmeye çalışmaları büyük rol oynamıştır. (Michell, 1998; İcan, 2013).

Genetik algoritmalarda, bir soruna yönelik çözümler genellikle 0'lar ve 1'lerin (kromozomlar) sabit uzunluklu dizelerinde kodlanır ve belirli bir soruna daha iyi bir çözüm geliştirmek için bu dizelerin popülasyonları (bireyleri veya aday çözümleri) manipüle edilir. Nesilden nesile bireyler modifikasyonla çoğaltılır ve uygunluğa göre seçilir. (Ferreira, 2006). Genetik algoritmaların çalışma prensibi gösteren akış şeması Şekil 4.14.'de verilmiştir.




Şekil 4.14. Genetik algoritmaların akış şeması (Vural, 2005).

Yukarıdaki akış şemasında da görüldüğü üzere genetik algoritmalarda başlangıç olarak eldeki mevcut verilerle rastgele bir popülasyon oluşturulur. Sonrasında gelen değerler ile birlikte popülasyonu oluşturan tüm kromozomların uyum değerleri hesaplanır. Uyum değerleri hesaplandıktan sonra genetik operatörler yani çaprazlama ve mutasyon yardımıyla yeni kromozomlar oluşturulur. Yeni kromozomların uyum değerleri hesaplandıktan sonra istenen sonuçlar elde edildiyse işlem sonlandırılır aksi halde istenen sonuçlar elde edilene kadar işlemler tekrar edilir. Çözümü sonlandırma işlemi için sonlandırma kriterleri belirlenir. Bu kriterler popülasyonun uyum değerlerinin ortalamasının istenen değerlere yaklaşması, maksimum nesil sayısına ulaşılması gibi farklı kriterler olabilir (İcan, 2013).

Genetik programlama; 1992 yılında Koza tarafından ortaya atılmış olup üreme, mutasyon, çaprazlama ve doğal seçim mekanizmalarının hepsini içeren sistemlerdir. Genetik algoritmaya göre karmaşık problemlerde daha başarılı olan genetik programlamada 0 ve 1'lerden oluşan sayı dizileri yerine boyut ve şekil olarak değişim

gösteren yapılar kullanılır. Bu ifade kolaylığı sayesinde genetik programlamaya daha fazla ilgi duyulmaktadır. Bireylerin gösterimi ağaç yapısı şeklindedir ve her bir birey birden fazla veri yapısı ile temsil edilebilir. Genetik programlamanın çalışma prensibi gösteren şema Şekil 4.15.'de verilmiştir (Aydoğan, 2014).




Şekil 4.15. Genetik programlamanın akış şeması (Aydoğan, 2014).

2000’li yıllara gelindiğinde Cândida Ferreira tarafından genetik algoritmalar ve genetik programlama yöntemlerinin sentezlenerek işlevselliğinin artırıldığı gen ifade programlama (GEP) adında bir melez yöntem geliştirilmiştir (Ferreira, 2001).

Gen ifade programlama temel olarak iki yapıdan oluşur. Bunlar kodlanmış genetik bilginin ifadelerinden oluşan kromozomlar ve ifade ağaçlarıdır. Bilginin kod çözme işlemine yani kromozomlardan ifade ağaçlarına doğru giden bilgi akışına çeviri denir. Bu çeviri bir tür kod ve bir dizi kural anlamına gelmektedir. Gen ifade programlamada genetik kod oldukça basittir. Kromozom sembolleri ile temsil ettikleri fonksiyonlar ve terminaller arasında birebir bir ilişki bulunur. Bu ilişki İfade ağaçlarındaki fonksiyonların ve terminallerin mekânsal organizasyonunu ve alt ifade ağaçları arasındaki etkileşimin türünü belirler. Ayrıca kromozom yapısı, her biri daha küçük bir program veya alt ifade ağacını kodlayan çoklu genlerin oluşturulmasına izin verecek şekilde tasarlanmıştır. Gen ifade programı çoklu gen yapısına sahip tek genetik algoritmadır. Bu özelliği sayesinde

gen ifade programlama ile daha karmaşık bireylerin üretilmesi basitleştirilmiştir (Ferreira, 2006).

GEP çalışma yapısının şematik olarak gösterimi Şekil 4.16.'da verilmiştir.



Şekil 4.16. Gen ifade programlamanın akış şeması (Ferreira, 2001).

4.2.1.1. Gen ifade programlamada kromozom yapısı

Gen İfade programlamada ifade ağaçları popülasyonları oluşturan kromozom dizinlerini matematiksel olarak ifade etmek amacıyla kullanılmaktadır. İfade ağaçlarında


sıra dizilimli kromozomlar; deęişken deęerleri ve bu deęişken deęerleri arasındaki matematiksel ilişkiyi ifade eden çeşitli fonksiyon ve sabitlerden oluşmaktadır (Ferreira, 2001). En basit haliyle kromozom dizilimi Şekil 4.17.'de gösterilmiştir.

0 1 2 3 4 56
 -.*.karekök (Q).a.karekök (Q),.a.b

Şekil 4.17. Örnek kromozom dizilimi.

Bu şekilde bir kromozom oluşturulduğunda; a ve b deęişken deęerleri, karekök (Q) matematiksel karekök ifadesini, - ve * işaretleri de sırasıyla çıkarma ve çarpma işlemlerini ifade eder ve tüm bu genler bir araya gelerek kromozomu oluşturur. Aradaki noktalar genleri ayırmak ve ifadelerin kolay ayrıştırılabilmesi için kullanılır.

Candida Fereire; Gen İfade Programlamanın kromozomlarında kodlanmış bilgilerin okunması ve ifade edilmesi için ‘‘karva dili’’ ni geliştirmiştir. Bu dil genetik programlamada kullanılan postfix ve prefix kromozomlarından gösterim açısından farklıdır (Ferreira, 2006). Yukarıda verilmiş olan kromozom yapısının gen ifade programlamaya ait karva diliyle hazırlanmış ifade ağacı Şekil 4.18’de verilmiştir.



Şekil 4.18. Örnek kromozomun ifade ağacı gösterimi.

Gen ekspresyonu programlama genleri bir baş ve bir kuyruktan oluşur. Baş hem fonksiyonları hem de terminalleri yani deęişken ya da sabit deęerlerini temsil eden semboller içerir. Kuyruk kısmında ise sadece terminaller bulunur. Baş ve kuyruk arasında

belirli bir oran vardır ve bu oran aşağıdaki denklem yardımıyla bulunur (Ferreira, 2002a). Bu oran Eşitlik 4.21 ile hesaplanır.

$$t_g = h_g (n_g - 1) + 1 \quad (4.21)$$

Her problem için, h_g ifadesi baş kısmını ifade eder ve bu değerin uzunluğu seçilir, t_g kuyruk uzunluğu, h_g 'nin bir fonksiyonudur ve fonksiyonun n_g değişkenlerinin sayısını ifade eder.

4.2.1.2. Gen ifade programlamada çok genli kromozomlar


Gen İfade Programlama kromozomları genellikle eşit uzunluklara sahip birden fazla genden oluşur. Her problem için genlerin sayısı ile başın uzunluğu belirlenir. Her bir gen bir alt ifade ağacını kodlar ve alt ifade ağaçları birbirleriyle etkileşime girerek daha karmaşık çok birimli ifade ağaçlarını oluşturur (Ferreira, 2001). Örneğin 27 birim uzunluklu ve 3 genden oluşan bir kromozomun gösterimi Şekil 4.19.'da verilmiştir.

012345678012345678012345678

-b*babbab*Qb+abbba-*Qabbbaba

Şekil 4.19. Çok genli kromozom yapısı.

0 konumu her genin başlangıcını işaretler ve her bir genin sonu yalnızca ilgili alt ifade ağacının kurgulanmasına açıktır. Yani kuyruk kısmında baş kısmın tasarlanmasına göre açıklanmayan ifadeler yer alabilir. Tüm bu genler bir araya gelerek kromozomu oluşturur. Şekil 4.19.'da görüldüğü gibi birinci gen takımı 4. Pozisyonda biter; ikinci gen takımı 5. Pozisyonda sonlanır ve son gen takımı da 5. Pozisyonda sona erer. Dolayısıyla gen ifade programlama kromozomları, her biri belirli bir alt ifade ağacı temsil eden bir ya da birden çok gen takımını kodlar. Eldeki probleme bağlı olarak bu alt ifade ağaçları uygunluklarına göre (örneğin birden fazla çıktıya sahip problemlerin çözümünde) ayrı ayrı seçilebilir ya da daha karmaşık, çok alt üniteli bir ifade ağacı oluşturulabilir. Tüm gen takımlarını içerisinde barındıran çok alt üniteli bu ifade ağacının gösterimi ise Şekil 4.20.'de verilmiştir.



Şekil 4.20. Örnek kromozomun ifade ağaçlarıyla gösterimi (a) Kuyruklu ve koyu olarak gösterilenler üç gen takımı ve oklar her genin sonlanma noktası (b) Gen takımlarını ifade eden ifade ağaçları(c) Gen takımlarının bir arada gösterildiği ifade ağacı (Ferreira, 2001).

4.2.1.3. Gen ifade programlamada popülasyonun seçimi

Popülasyon, içinde çözüm bilgilerini barındıran ve birbirleriyle ilişkili kromozomların bir araya getirilerek kurgulandığı çözüm kümesine verilen isimdir. Başlangıç popülasyonunun oluşturulmasındaki en önemli husus popülasyon büyüklüğünün belirlenmesi işlemidir (Elmas, 2011; Turfan, 2014).

Seçim işleminde, istenilen çözüme en yakın bireylerin daha yüksek olasılıkla seçilmeleri amaçlanmaktadır. Bu seçimi yapmak üzere belirlenmiş seçim algoritması

sadece en iyi bireyleri seçerse, popülasyon bu bireyler çevresinde gelişir ve bu değerlere yakın sonuçlar elde edilir. Bu nedenle seçim mekanizmaları en iyi bireyleri seçmeye yönlendirilir ancak en iyi olmayıp da genetik açıdan yarar sağlayabilecek bilgiye sahip bireylerin de bu mekanizmalar tarafından seçilebilir olması gerekmektedir (Genel, 2004). Uygulamada birçok seçim mekanizması kullanılmaktadır. Bunlar içinde en çok kullanılanları; rastgele seçim, sıralı seçim, rulet seçimi, turnuva seçimi ve Elitizm seçimidir.

-Rastgele Seçim: Bu yöntemde popülasyonu oluşturan bireyler rastgele seçilmektedir. (Engelbrecht, 2007; Özçalıcı, 2015).

-Sıralı Seçim: Bu seçim yönteminde seçilme ihtimali bireylerin sıralamasına göre belirlenir. Popülasyondaki bireyler en iyiden en kötüye doğru sıralandırılır ve her bireyin beklenen değeri uygunluk fonksiyonuna pek bağlı olmadan daha çok sıralamasına bağlıdır (Sakawa, 2002; Özçalıcı, 2015).

-Rulet Seçimi: Bu seçim yönteminde popülasyonu oluşturan her bir birey rulet çarkında uygunluk oranı kadar yer kaplar. Yöntem çarkın n kez döndürüldükten sonra n adet yeni bireyin seçilmesi şeklinde tanımlanır (Tuğ, 2005).

-Turnuva Seçimi: Bu seçim yönteminde popülasyona ait bireylerden rastgele olarak seçilen kromozomlar ile alt kümeler oluşturulur. Bu alt kümeler popülasyon büyüklüğüne göre belirlenmektedir. Popülasyon büyüklüğü arttığında seçilen alt kümelerin sayısı da artmaktadır. Bu alt kümelerdeki en iyi uygunluk değerine sahip kromozomlar bir sonraki nesle aktarılır. (Alıkalfa, 2013).

-Elitizm Seçimi: Çaprazlama ve mutasyon işlemlerinden sonra popülasyondaki en iyi bireylerin sonraki kuşaklara aktarımı ve daha iyi bireylerin oluşturulması temel amaç olsa da bu durum garanti değildir (Coley, 1999; Sakawa, 2002; Vural, 2005).

4.2.1.4. Gen ifade programlamada uygunluk fonksiyonu

Uygunluk fonksiyonu başlangıç popülasyonunu oluşturan bireylerin diğer bir adıyla kromozomların hangileri ile yeni bir nesil kurgulanacağına karar vermede kullanılan bir değerlendirme kriteridir (Turfan, 2014). Seçilecek olan fonksiyonun mevcut problemin çözümlenmesi adına kullanılabilir olması gerekmektedir. Problemin yapısına göre başlangıçta belirlenmiş olan uygunluk fonksiyonu yardımıyla popülasyonu oluşturan tüm kromozomların $f(x_i)$ uygunluk fonksiyon değerleri hesaplanır. Bu değerler popülasyonu oluşturan n adet birey sayısı kadardır (Candan, 2010; Turfan, 2014).

Uygunluk fonksiyonu kısaca hata miktarının belirlendikten sonra hesaplanan değerlerle istenen değerleri karşılaştırarak anlamlı çıkarımlar yapmamıza olanak sağlayan matematiksel ifadelerdir. Hemen hemen tüm veri analiz işlemlerinde ortalama karesel hata (MSE), Kök ortalama karesel hata (RMSE) ya da belirlilik katsayısı (R^2) hesaplanarak hata miktarı belirlenir.

4.2.1.5. Gen ifade programlamada kromozomların kopyalanması

Kopyalama işlemi tek başına genetik çeşitliliğe hiçbir şekilde katkıda bulunmaz. Gelecek nesile aktarılacak yeni bireylerin uygunluğu ve rulet seçimindeki şans faktörüne bağlı olarak kromozomlar gelecek nesillere tam anlamıyla kopyalanır. Birey ne kadar iyi olursa gelecek nesile aktarılma olasılığı da o kadar yüksektir (Ferreira, 2002a).

4.2.1.6. Gen ifade programlamada mutasyon

Mutasyon; birden fazla optimum noktaya sahip fonksiyonları yerel optimum noktalarına yakınlaştıran ve işlem ağının bir tekrara ya da çıkmaza düşmesini engelleyen bir işlemdir (Güçlü, 2004).

Mutasyon olasılığı (p_m); mutasyon işleminin hangi sıklıkla yapılacağına ve işlemde mutasyona uğrayacak birey sayısını belirler. Mutasyon olasılığı 0 kabul edilirse yeni bireyler çaprazlama ya da koplama işleminden çıktıkları gibi bırakılır ve herhangi bir değişime uğratılmaz. Eğer mutasyon olasılığı %100 alınırsa bu durumda da bireyler tamamen değiştirilir (Kurt ve Semetay, 2004; Vural, 2005).

Mutasyon oranı genetik algoritma ve gen ifade programlama işlemlerinde genellikle 0.01-0.001 aralığında seçilir. Popülasyonda farklılığın azaldığı ve çaprazlama işleminin etkinliğini kaybettiği durumlarda mutasyonun önemi artar ve mutasyon oranının artırılması işlem ağına olumlu bir katkı sağlar (Biethahn ve Nissen, 1995; Vural, 2005).

Mutasyon oranı, popülasyon büyüklüğü ve kromozom uzunluğu değerlerinin çarpılmasıyla elde edilen mutasyon değeri kadar mutasyon her nesil için gerçekleşir ve mutasyon oranının çok düşük olması çoğu genin değişim görmeyerek sabit bir değerde kalmasına sebep olur. Bu da popülasyonun sabit bir değere yakınsanmasına neden olabilir. Çok yüksek olması da araştırma uzayını genişletir ve gerçek değerlere ulaşmamızı zorlaştırır. Yani kısacası mutasyon oranı işlem yapısına göre dikkatli bir şekilde belirlenmelidir (Grefenstette, 1992; Vural, 2005).

4.2.1.7. Gen ifade programlamada kromozomların yeniden oluşturulması

Gen İfade Programlamada kromozomları oluşturan gen gruplarının birbirleri arasında yer değiştirmesi ya da bir genin ya da gen grubunun başka bir gen ya da gen grubu yerine kopyalanması ile yeni kromozomlar oluşturulur. Bu yeni bireylerin oluşturulmasında 3 farklı yöntem kullanılır.

IS Transferi: Bu işlem kromozomun kafa kısmında yer alan gen ya da gen grubunun seçilerek; kromozom diziliminde yer alan ve seçilen gen grubuyla aynı sayıda genin birbirleri ile yer değiştirmesi şeklinde gerçekleştirilir. Yapılan bu işlem kromozom üzerinde mutasyona benzer bir etki oluşturur ve yeni bireylerin oluşturulmasında kullanılır. IS transfer oranı gen ifade programlama algoritması için $[0,1]$ aralığında belirlenen bir değerdir ve algoritmanın yapısı gereği oranın 0,1 olarak seçilmesi uygundur (Ferreira, 2002b; Çolak, 2006).

RIS Transferi: Kök transferi olarak da adlandırılan bu yöntemde yine kromozomun kafa kısmından rastgele sayıda seçilen genler yine kafa kısmında seçilen diğer bir gen grubuyla yer değiştirir. Kök transfer oranı $[0,1]$ aralığında istenilen değer seçilebilir ama gen ifade programlama çalışmalarında genellikle bu oran 0.1 olarak belirlenir (Çolak, 2006).

Gen Transferi: Gen transferi işleminde IS ve RIS transferinden farklı olarak yer değiştirilecek kromozomun kafa kısmında bulunan genlerden seçilmesi şartı yoktur.

Ayrıca gen transferinde diğer iki transfer yöntemine göre daha büyük gen grupları arasında yer değiştirme işlemi gerçekleştirilir. Yer değiştirme işlemi karşılıklı olmakla birlikte sıralamayı değiştirme şeklinde de gerçekleştirilebilir. Yani ortadaki bir gen grubu kafa kısmına gönderilir ve kafa kısmında bulunan gen grubu böylelikle orta kısma kayar. Gen transfer oranı $[0,1]$ aralığında istenilen bir değer seçilebilir. (Lutton, vd., 2002; Çolak 2006).

4.2.1.8. Gen ifade programlamada çaprazlama işlemi

Çaprazlama işlemi; mutasyon ve yeniden oluşturma evrelerinden geçmiş olan kromozomlar arasında gerçekleşen son aşamadır. Gen ifade programlama algoritmasında iki kromozomu oluşturan genler; belirli şekillerde birbirleriyle yer değiştirir ve bu sayede kromozomun yapısında büyük değişimlere neden olarak üretilen verilerde çeşitlilik sağlanması amaçlanır. GEP algoritmasında 3 tip çaprazlama yöntemi kullanılır.

Tek Noktada Çaprazlama: En basit çaprazlama yöntemidir. Çaprazlama işlemi yapılacak olacak seçilmiş 2 kromozom üzerinde belirlenen rastgele bir noktadan seçilen genlerin yer değiştirmeye gerçekleştirilir. Çaprazlama işlemi gerçekleştirilmek için bir P çaprazlama oranı belirlenir. Gen ifade programlama için bu oran genellikle 0,1 ile 0,5 arası değerlerdir. Rastgele seçilen 0 ile 1 arasındaki sayı belirlenen P oranından küçük ise kromozomlar arasında çaprazlama işlemi gerçekleştirir. Her bir iterasyonda $P \times N$ kadar bireye çaprazlama işlemi uygulanır. Burada P çaprazlama oranını, N ise birey sayısını ifade etmektedir (Grefenstette, 1986; Ağalday, 2018).

İki Noktada Çaprazlama: Tek noktada çaprazlamaya benzer şekilde kromozomlar üzerinde belirlenen iki adet sırada kromozomlar arası yer değiştirmenin yapıldığı yöntemidir. Seçilen bu iki sıra arasında kalan alt gen dizinler diğer kromozomun alt gen dizinleriyle yer değiştirerek çaprazlama işlemi gerçekleştirilir. Çaprazlamanın yapılacağı noktaların seçimi rastgele olarak yapılır ve çaprazlama noktası; 1 sırası ile kromozomu oluşturan N-1 adet gen arasında herhangi bir sıra seçilebilir (Tomassini, 1996; Ağalday, 2018).

Gen Çaprazlama: Bu çaprazlama yönteminde diğer iki yöntemden ayrı olarak gen grupları değil kromozom üzerinde yer alan genler tek olarak yer değiştirir. Kromozomlar arasından rastgele seçilmiş olan genler birbirleri ile yer değiştirerek genetik çeşitlilik oluşturulamaya çalışılır. Gen çaprazlama işlemi istenilen oranda gerçekleştirilebilir. Genellikle gen çaprazlama oranı 0,1-0,5 arası bir değer seçilir (Çolak 2006).

4.3. İstatiksel Tahmin ve Trend Analizi

İstatistik; matematiksel bir bilim dalıdır. Kullanılacak olan verileri değerlendirme ve yorumlama, bu bilim dalının temel içeriğini oluşturur. Toplanan veriler, geçmiş zamanlara ya da şimdiki zaman ait ölçülmüş verilerdir ve bu verilerin değerlendirilmesi için geliştirilen birkaç teknik sayesinde analiz yapılır. Yapılan analizler sonucu veriler yorumlanır ve bu yorumlamayla birlikte gelecek hakkında tutarlı tahminler ve gerçekçi kararların alınmasını sağlar (Cebe, 2007).

Trend analizi, eldeki mevcut dataların değerlendirilmesi amacıyla geliştirilmiş bir yöntemdir. Bu analiz birden fazla değişkenin arasındaki matematiksel ilişkiyi denklem olarak ifade eder. Bu analiz yönteminin genel amacı bağımlı değişken değerleri, bağımsız değişken değerlerinden faydalanarak tahmin etmektir (Cebe, 2007).

Özellikle nehir akımları için trendlerin bilinmesi, su kaynaklarının kontrolünde ve imale dilecek su yapılarının tasarım esaslarında büyük bir öneme sahiptir. Baraj hazne kapasiteleri, baraj işletimi, taşkınlarla ilgili bilgiler ve alınacak önlemler gibi konularda trendlerin hesaplanması gelecek için verilecek kararları önemli ölçüde etkileyecektir (Bayazıt vd., 2002).

Trend analizi parametrik ve parametrik olmayan testler olmak üzere ikiye ayrılır. Parametrik testlerde normal dağılıma sahip olan veriler kullanılırken parametrik olmayan testlerde bu şart aranmaz. Her iki test yöntemine ait alt yöntemler aşağıdaki şekilde sınıflandırılır (Tanır ve Beşel, 2017):

Parametrik olmayan testler

- Mann-Kendall testi
- Spearman'ın Rho testi
- Sen'in T testi

Parametrik testler

- Regresyon analizi

4.3.1. Parametrik olmayan testler

Parametrik olmayan testler, verilerin gerçek değeri yerine sıralanmış değerlerinden faydalanılarak yapılır. Parametrik test varsayımları bu test için geçerli değildir. Verilerin bağımsızlığı ve rastgele seçimi gibi varsayımları olan bu test yönteminde parametrik test yöntemine göre varsayımlar daha basit ve az sayıdadır (Kayıkçı ve Beşel, 2017).

4.3.1.1. Mann-Kendall testi

Parametrik olmayan Mann-Kendall test yöntemi zaman serilerinde meydana gelebilecek artış ve azalışların istatistiksel olarak önemini belirleyen ve yaygın olarak kullanılan bir testtir (Özfıdaner, 2017). Trendin olup olmadığı, zaman serileri ile kurulan sıfır hipotezine göre hesaplanır. Mevcut $x_1, x_2, \dots, x_n$ veri setinden x_i ve x_j çiftleri ayrılır. Sonra $i < j$ iken x_i ve x_j nin durumuna bakılır. Eğer $x_i < x_j$ şartını sağlayan veri setindeki tüm verilerin sayısı P_m , $x_i > x_j$ şartını sağlayan veri setindeki tüm verilerin sayısı M_m olursa; test istatistiği S_m değeri Eşitlik 4.25 ile hesaplanır (Çoban, 2013).

$$S_M = P_m - M_m \quad (4.25)$$

Örnek veri sayısı 10 ve üzeri olursa varyans (σ_s);

$$\sigma_s = \frac{\sqrt{n(n-1)(2n+5)}}{18} \quad (4.26)$$

Eşitlik 4.26 ile hesaplanır. Varyans (σ_s) hesaplandıktan sonra Z istatistiği belirlenir (Gümüş ve Yenigün 2006).

$$Z = \begin{cases} \frac{S_m - 1}{\sqrt{\sigma_s}}, & S_m > 0 \\ 0, & S_m = 0 \\ \frac{S_m + 1}{\sqrt{\sigma_s}}, & S_m < 0 \end{cases} \quad (4.27)$$

Eşitlik 4.27’de yer alan Z ifadesi, test istatistiği standart normal dağılım değeridir. Eğer veri setinde gözlem sayıları birbirine eşit olursa varyans (σ_s) Eşitlik 4.28 ile hesaplanır (Gümüş ve Yenigün 2006).

$$\sigma_s = \frac{\sqrt{[n(n-1)(2n+5) - \sum_i t_i(t_i-1)(2t_i+5)]}}{18} \quad (4.28)$$

Denklemdede yer alan t_i değeri, eşit olan gözlem verilerinin sayısını göstermektedir (Gümüş ve Yenigün 2006).

Eğer seçilen α_0 önem seviyesinde $|Z| \leq Z_{\alpha/2}$ ise H_0 hipotezi kabul edilir ve zaman serisinde trend olmadığı sonucuna varılırken; $|Z| > Z_{\alpha/2}$ durumunda ise H_0 hipotezi reddedilir ve zaman serisinde trend olduğu sonucuna varılır. Trend olup olmadığı tespit edildikten sonra S_m değeri eğer pozitif ise artan yönde trend, negatif ise azalan yönde trend olduğu sonucuna varılmaktadır (Yue vd., 1993; Büyükyıldız, 2004).

4.3.1.2. Sen’in T testi

Sen tarafından 1968 yılında geliştirilen bu yöntem parametrik olmayan bir testtir. Veriler arasında eğer doğrusal bir gidiş varsa gerçek eğim için veri hataları yüzünden değişmeyen, eksik veri setlerinde uygulanabilen bir yöntemdir (Yue vd., 1993). Burada veri sayısı n olmak üzere önce i ve j zamanlarındaki veriler x_i ve x_j ($i > j$) ise Eşitlik 4.29’dan yararlanılır;

$$N = \frac{n(n-1)}{2} \quad (4.29)$$

Bulunan N değeri ile birlikte Q_t parametresi;

$$Q_t = \frac{x_i - x_j}{i - j}, \quad (t = 1, 2, \dots, N) \quad (4.30)$$

Eşitlik 4.30 ile hesaplanır (Ülke ve Özkoca, 2018). Sen yöntemine göre, hesaplanan N adet Q_t değerinin medyanı Sen'in tahmin eğilimini ortaya koyar ve Eşitlik 4.31 ile hesaplanır (Karakus, 2017).

$$\beta = \begin{cases} Q_{\text{medyan}} = \frac{Q(N+1)}{2} & n(\text{tek}) \\ Q_{\text{medyan}} = \frac{|Q_{N/2} + Q_{(N+2)/2}|}{2} & n(\text{çift}) \end{cases} \quad (4.31)$$

β ifadesinin pozitif bir değer olması artan trendi, negatif bir değer olması ise azalan trendi ifade etmektedir (Jain and Kumar, 2012; Karakus, 2017).

4.3.1.3. Spearman'in rho testi

İki veri seti arasında kolerasyon olup olmadığını belirlemek için kullanılan Spearman Rho testi, lineer trend varlığının belirlenmesinde hızlı ve basit bir testtir. R_{xi} sıra istatistiği değeri verilerin küçükten büyüğe ya da büyükten küçüğe doğru sıralanmasıyla belirlenir ve Spearman'ın Rho testi değeri r_s 4.32 ile hesaplanır (Buyukkaracigan and Kahya, 1997; Çeribaşı ve Doğan, 2015):

$$r_s = 1 - 6 \frac{\sum_{i=1}^n (R_{xi} - i)^2}{(n^3 - n)} \quad (4.32)$$

R_{xi} , i. Gözlemin sıra numarasını, i verilerin gözlem sırasını ve n ise toplam gözlem sayısını ifade eder. r_s 'in test istatistiği değeri (Z) 4.33 ile hesaplanır:

$$Z = r_s \sqrt{n - 1} \quad (4.33)$$

Z'nin mutlak değeri belirlenen α anlamlılık değerine karşı gelen normal dağılımın $Z_{\alpha/2}$ değerinden küçük olması durumunda H_0 hipotezi kabul edilir ve veri setinde trend olmadığı sonucuna varılır. Tam tersi durum söz konusu olduğunda yani; Z'nin mutlak değeri α anlamlılık değerine karşılık gelen normal dağılımın $Z_{\alpha/2}$ değerinden büyük olduğunda H_0 hipotezi reddedilir ve veri setinde trend olduğu sonucuna varılır. Z değeri

pozitif ise trend artan yönde, negatif ise azalan yönde gerçekleşmektedir (Büyükyıldız, 2004).

4.3.2. Parametrik testler

Parametrik testler süreklilik gösteren ve normal dağılım gösterdiği varsayılan veriler üzerinde kullanılır. Bu test yönteminde elde edilen sonuçların geçerli olup olmadığı belirli parametre kontrollerinden sonra belirlenir (Kayıkçı ve Beşel, 2017).

4.3.2.1. Regresyon analizi

Regresyon analizi, debi süreklilik eğrileri ile bir havzada yapılan hidrolojik çalışmalarda sıklıkla kullanılan yöntemlerden biridir. Regresyon analizi, bağımlı bir y sonuç değişkeni ile bu değerden bağımsız bir ya da birden fazla x değeri arasındaki ilişkiyi tanımlama ve bu ilişkinin derecesinin hesaplanmasında kullanılır (Beşiktaş, 2010).

Regresyon analizinde aralarında ilişki kurulacak olan bir ya da birden fazla değişken sayısını belirlemek ve bu değişkenler arasındaki ilişkiyi ifade eden denklemin oluşturulması için kabullerin yapılması gerekir. Bu şartlar göz önüne alındığında regresyon analizi aşağıdaki şekilde sınıflandırılabilir (Gülerce, 2007).

Doğrusal Olmayan Regresyon: İki ya da daha fazla X bağımsız değişken değerleri ile Y bağımlı değişkeni arasında doğrusal olmayan ve önceden seçilen bir denklem ile ifade edilen bir ilişki olduğu kabul edilir (Bayazıt ve Oğuz, 1994; Gülerce 2007).

Basit Doğrusal Regresyon: Basit Doğrusal regresyon analizi Y_i bağımlı değişkeni ile X_i bağımsız değişkeni arasında bulunduğu kabul edilen doğrusal ilişkiyi veren bir yöntemdir. Bu doğrusal ilişki Eşitlik 4.34 ile elde edilir (Balcı ve vd., 2012).

$$Y_i = A + BX_i + e_i \quad (4.34)$$

Doğrusal fonksiyondan A değeri fonksiyonun y eksenine keştiği noktayı, B katsayısı ise doğrunun eğimini ifade eder. Denklemden X_i bağımsız değişken değerine göre Y bağımlı değişken değerlerini e miktarında bir hata değeri ile belirleyecek A ve B parametreleri tahmin edilmektedir (Balcı ve vd., 2012).

Çoklu Doğrusal Regresyon: Çoklu doğrusal regresyon analizi birden fazla bağımsız değişken yardımıyla bağımlı değişkenin tahmin edilmesi ve hangi bağımsız değişkenin, bağımlı değişken üzerinde anlamlı bir etkisi olduğunun tespit edilmesi için

kullanılır. Modelin matematiksel olarak gösterimi Eşitlik 4.35’de verilmiştir (Xu, 2003; Özçınar, 2006).

$$Y_i = A + B_1X_{1i} + B_2X_{2i} + \dots + B_nX_{ni} + e_i \quad (4.35)$$

A değeri doğrunun y eksenini kestiği değerdir. $B_1, B_2, \dots B_n$ değerleri regresyon katsayılarını e ise hata değerini ifade eder (Xu, 2003; Özçınar, 2006).

A, $B_1, B_2, \dots, B_n$ katsayıları basit doğrusal regresyon analizinde olduğu gibi e hata değerinin minimuma indirilmesiyle hesaplanır. Çoklu doğrusal regresyon için bu denklem Eşitlik 4.36’da verilmiştir (Şentürk, 2011).

$$\sum e_i^2 = \sum (Y_i - A - B_1X_{1i} - B_2X_{2i} - B_3X_{3i} - \dots - B_nX_{ni})^2 = \min. \quad (4.36)$$

Yukarıdaki denklemi minimum yapacak regresyon katsayıları birinci dereceden iki bilinmeyenli bir denklem için Eşitlik 4.37a, Eşitlik 4.37b ve Eşitlik 4.37c’den yararlanılır (Şentürk, 2011).

$$nAB_1 \sum_{i=1}^n X_{1i} + B_2 \sum_{i=1}^n X_{2i} = \sum_{i=1}^n Y_i \quad (4.37a)$$

$$A \sum_{i=1}^n X_{1i} + B_1 \sum_{i=1}^n X_{1i}^2 + B_2 \sum_{i=1}^n X_{1i}X_{2i} = \sum_{i=1}^n X_{1i}Y_i \quad (4.37b)$$

$$A \sum_{i=1}^n X_{2i} + B_1 \sum_{i=1}^n X_{2i}^2 + B_2 \sum_{i=1}^n X_{1i}X_{2i} = \sum_{i=1}^n X_{2i}Y_i \quad (4.37c)$$

Yukarıdaki ifadeler sadeleştirilince, Y bağımlı değişken değerinin X_1 ve X_2 gibi iki bağımsız değişken değere göre hazırlanan çoklu doğrusal regresyon denklemi Eşitlik 4.38’deki gibi düzenlenir (Şentürk, 2011):

$$Y = A + B_1X_1 + B_2X_2 \quad (4.38)$$

4.3.3. Regresyon katsayılarının f testi ile anlamlılığını belirleme

Regresyon analizlerinde F testi, model parametrelerinin anlamlılığının belirlenmesinde kullanılan bir yöntemdir. Her bir model için hesaplanan F testi istatistiği, belirlenmiş olan kritik değerden büyük olduğunda; kurulan modelin anlamlı olduğu ya da seçilen bağımsız değişkenler varyansın büyük bir kısmını açıklamaktadır ve bağımlı değişkenin tespiti için modelde yer almalıdır sonucuna varılır (Girginer, 2005; Pamukçu, 2010).

Modelde yer alan değişkenler arasındaki ilişkinin anlamlı olup olmadığını belirlemek için Eşitlik 4.39a ve Eşitlik 4.39b'den yararlanılarak hipotezler hazırlanır:

$$H_0 : A_1 = A_2 = A_3 = \dots = A_n \quad (4.39a)$$

$$H_1 : A_1 \neq A_2 \neq A_3 \neq \dots \neq A_n \quad (4.39b)$$

Burada H_0 tüm parametre değerlerinin sıfır olduğunu kabul eder yani bu hipoteze göre bağımlı değişken bağımsız değişkenler tarafından açıklanamaz ve model istatistiksel açıdan anlamlı olmadığını ifade eder. H_1 ise parametrelerden en az iki tanesinin sıfırdan farklı olduğunu ve modelin istatistiksel açıdan anlamlı olduğunu ifade eder (Girginer, 2005; Pamukçu, 2010).

F anlamlılık testi için belirlilik katsayısı R^2 değeri yardımıyla Eşitlik 4.40'da gösterildiği gibi F değeri hesaplanır;

$$F = \frac{R^2}{(1-R^2)} \cdot \frac{(n-p)}{(p-1)} \quad (4.40)$$

Burada p ; n adet gözlem verisi yardımıyla hazırlanmış regresyon denkleminde tahmin edilen parametre sayısını, $p-1$ ifadesi de bağımsız değişken sayısını ifade etmektedir. Belirlenen bir α anlam düzeyi yardımıyla F tablosundan; $F_{(p-1, n-p)}$ satır ve sütununa karşılık gelen değer ile hesaplanan F değeri ile karşılaştırılır. $F_{(p-1, n-p)} > F$ ise hipotez reddedilir ve modelin istatistiksel olarak anlamlı olduğuna karar verilir (İmir, 1986; Pamukçu, 2010).

5. ARAŞTIRMA BULGULARI ve SONUÇLAR

5.1. Havza Bilgileri

Sakarya Havzası; 29° 16' ile 33° 15' doğu boylamları 37° 57' ile 41° 12' kuzey enlemleri arasında yer alır. Türkiye yüzölçümünün 1/8'lik kısmını oluşturur ve toplamda 63.303 km² lik yağış alanına sahiptir. Havza sınırları içerisinde; Eskişehir İli'nin tamamı, Bilecik İli'nin tamamına yakın bir kısmı, Sakarya İli'nin %92,5 'luk, Ankara İli'nin %70'lik, Bolu İli'nin %52'lik Kütahya İli'nin %36'lık, Afyonkarahisar İli'nin %25, Konya İli'nin %20'lik, Bursa İli'nin %18'lik Kocaeli İli'nin %10'luk ve Uşak İli'nin %2'lik kısmı girmektedir (DSİ 2017). Havza sınırları Şekil 5.1.'de gösterilmiştir.



Şekil 5.1. Sakarya havzası (DSİ, 2017).

Havzayı oluşturan Sakarya Nehri uzunluğu itibariyle Kızılırmak Nehri ve Fırat Nehrinden sonra Türkiye'nin en uzun üçüncü nehridir. Nehir debi değerleri Mart, Nisan ve Mayıs aylarında artarken; Temmuz, Ağustos ve Eylül ayları içerisinde azalır. Nehrin en düşük ölçülmüş debi değeri 30 m³/s en yüksek ölçülmüş debi değeri 996 m³/s ve ortalama debi değeri 171 m³/s 'dir. Nehir İç Anadolu'ya doğru akar ve Polatlı

yakınlarında en büyük kollarından biri olan Porsuk Çayı'nı ve Porsuk Alt Havzasını oluşturur (DSİ, 2017).

Porsuk Alt Havzası, Sakarya Havzası'nın güneybatısında bulunur. 29°38'-31°59' doğu boylamları ile 38°44'- 39°99' kuzey enlemleri arasında yer alır. Porsuk Alt Havzası, doğu – batı yönünde 202 km, kuzey - güney yönünde 135 km genişliğe sahiptir ve 448 km uzunluğu ile Sakarya Nehri'nin en önemli koludur. Yıllık ortalama akımı 256.23 hm³ tüketilen su miktarı ise 231.63 hm³ olarak hesaplanmıştır (DSİ, 2017).

Porsuk Alt Havzasında karasal iklim hakimdir ve yağış rejimi de karasal iklim özellikleri gösterir. Havzanın yağışlı geçen dönemleri kış ve ilkbahar aylarıdır ve doğuya doğru gidildikçe özellikle Konya İli sınırları yakınlarında yağışların azaldığı görülmektedir. Havzanın en uzun süre yağış gözlemi yapmış olan istasyonu 1929 yılında işletmeye açılmış olan Eskişehir ve Kütahya Meteoroloji Gözlem İstasyonlarıdır. Eskişehir Meteoroloji Gözlem İstasyonu'nda yıllık olarak toplam yağış 368,4 mm olarak ölçülmüştür (DSİ, 2017). Porsuk Alt Havzasına ait genel bilgiler Çizelge 5.1.'de verilmiştir.

Çizelge 5.1. Porsuk alt havzası genel bilgileri (DSİ, 2017).

Drenaj Alanı	km ²	10 825
Ortalama Rakım	m	1050.80
Nüfus (2012)	kişi	1 002 397
Nüfus Yoğunluğu	kişi/km ²	93
Belediye Nüfusu (2012)	kişi	930 614
Belediye Nüfusunun Toplam Nüfusa Oranı	%	0.93
Yıllık Ortalama Doğal Akım	hm ³	487.85
Yıllık Ortalama Doğal Akım	m ³ /s	15.47
Yıllık Ortalama Verim	l/s/km ²	1.43
Yıllık Ortalama Yağış Yüksekliği	mm	466.44
Yıllık Ortalama Akış Yüksekliği	mm	45.1
Akış /Yağış Oranı	%	9.7

5.2. İstasyon Bilgileri

5.2.1. D12A033 no'lu istasyon bilgileri

Porsuk Alt Havzası'nın 30°2'0" Doğu boylamlarıyla 39°21'0" Kuzey enlemleri arasında Kütahya-Afyon yolunun 10. km sinden sağa ayrılan Gediz yolunun 1.5 km'sindeki köprü'nün menbasında bulunur. İstasyon 01.12.1960 yılında hizmete açılmış ve hala aktif bir şekilde ölçüm yapmaya devam etmektedir. Çalışmada D12A033 no'lu istasyondan 1991-20015 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 1991-2009 yılları arasında ölçülen akım verileri eğitim; 2010-2015 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verileri ait istatistik parametreler Çizelge 5.2.'de verilmiştir.

Çizelge 5.2. D12A033 no'lu İstasyona ait veri bilgileri.

İstatistik Parametreler	D12A033 TÜM VERİLER	D12A033 EĞİTİM VERİLERİ	D12A033 TEST VERİLERİ
Veri Sayısı	8766	6576	2190
Toplam	21665,17	155575,98	6089,19
En Büyük Debi	104	104	0,182
En Küçük Debi	0,04	0,04	46,20
Ortalama	2,471	2,369	2,777
Standart Sapma	4,726	4,847	4,331

5.2.2. D12A049 No'lu İstasyon Bilgileri

Porsuk Alt Havzası'nın 29°51'0" Doğu boylamlarıyla 39°18'0" Kuzey enlemleri arasında Kütahya-Gediz yolunun 33. km'sindeki Saray köyünden sağa ayrılan yolun 4 km'sindeki Kureyşler köyüne 300 metre uzaklıkta bulunur. İstasyon 01.06.1963 yılında hizmete açılmış ve 30.09.2013 yılına kadar ölçüm yapmaya devam etmiştir. Çalışmada D12A049 no'lu istasyondan 2003-20013 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2003-2011 yılları arasında ölçülen akım verileri eğitim; 2012-2013 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verileri ait istatistik parametreler Çizelge 5.3.'de verilmiştir.

Çizelge 5.3. D12A049 no'lu İstasyona ait veri bilgileri.

İstatistik Parametreler	D12A049 TÜM VERİLER	D12A049 EĞİTİM VERİLERİ	D12A049 TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	955,885	632,662	323,223
En Büyük Debi	3,2	2,64	3,2
En Küçük Debi	0,052	0,052	0,12
Ortalama	0,262	0,216	0,442
Standart Sapma	0,261	0,186	0,404

5.2.3. D12A063 No'lu İstasyon Bilgileri

D12A063 No'lu istasyon; Porsuk Alt Havzası'nın 30°24'0" Doğu boylamlarıyla 39°38'0" Kuzey enlemleri arasında, Porsuk Baraj yolunun 20. km sindeki Gökçek Işık köyünden sola ayrılan Yörük Kırkaköy yolunun 3 km sindeki Uluçayır köyünde bulunmaktadır. İstasyon 01.05.1964 yılında hizmete açılmış ve hala ölçüm yapmaya devam etmektedir. Çalışmada D12A063 no'lu istasyondan 1984-2000 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 1984-1991 yılları arasında ölçülen akım verileri eğitim; 1998-2000 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verilere ait istatistik parametreler Çizelge 5.4.'de verilmiştir.

Çizelge 5.4. D12A063 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A063 TÜM VERİLER	D12A063 EĞİTİM VERİLERİ	D12A063 TEST VERİLERİ
Veri Sayısı	3653	2923	730
Toplam	2317,272	1843,994	473,278
En Büyük Debi	26,00	26,00	3,2
En Küçük Debi	0,001	0,03	0,001
Ortalama	0,634	0,631	0,649
Standart Sapma	1,22	1,291	0,896

5.2.4. D12A173 no'lu İstasyon Bilgileri

D12A173 No'lu İstasyon; Porsuk Alt Havzası'nın 30°24'0" Doğu boylamlarıyla 39°39'0" Kuzey enlemleri arasında, Eskişehir-Kütahya yolunun 8. km'sinden sola ayrılan yolun 13. km'deki Gökçeışık köyünde bulunur. İstasyon 01.10.1983 yılında hizmete açılmış ve 30.01.2013 tarihinde kapatılmıştır. İstasyondaki bazı tahribatlar sebebiyle sağlıklı debi verisi ölçümleri 2000 yılına kadar yapılabilmektedir. Çalışmada D12A173 no'lu istasyondan 1984-2000 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 1984-1991 yılları arasında ölçülen akım verileri eğitim; 1998-2000 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verilere ait istatistik parametreler Çizelge 5.5.'de verilmiştir.

Çizelge 5.5. D12A173 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A173 TÜM VERİLER	D12A173 EĞİTİM VERİLERİ	D12A173 TEST VERİLERİ
Veri Sayısı	3653	2923	730
Toplam	31992,17	25100,31	6891,68
En Büyük Debi (m ³ /sn)	33,90	33	33,90
En Küçük Debi (m ³ /sn)	0	0	0,91
Ortalama	8,76	8,59	9,44
Standart Sapma	6,61	6,44	7,16

5.2.5. 17126 No'lu istasyon bilgileri

17126 No'lu yağış gözlem istasyonu; 39°76'56" Kuzey enlemleri ve 30°55'02" Doğu boylamları arasında, Yenidoğan Mahallesi, Buluş Sokak Odunpazarı / Eskişehir'de Meteoroloji III. Bölge Müdürlüğü binası yanında ölçüm yapmaktadır. İstasyon 1929 yılında hizmete açılmış ve hala aktif bir şekilde ölçüm yapmaya devam etmektedir. Rasat türü mm'dir. Çalışmada 17126 no'lu istasyondan 2006-2015 yılları arasındaki günlük yağış verileri temin edilmiş ve kullanılmıştır. 2006-2013 yılları arasında ölçülen akım verileri eğitim; 2013-2015 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verilere ait istatistik parametreler Çizelge 5.6.'da verilmiştir.

Çizelge 5.6. 17126 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	17126 TÜM VERİLER	17126 EĞİTİM VERİLERİ	17126TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	3463,4	2655,8	807,6
En Az Yağış (mm)	0	0	0
En Çok Yağış (mm)	39,5	29,4	39,5
Ortalama	0,948	0,908	1,106
Standart Sapma	2,85	2,598	3,68

5.2.6. D12A054 no'lu istasyon bilgileri

D12A054 No'lu istasyon; Porsuk Alt Havzası'nın 30°24'0" Doğu boylamlarıyla 39°38'0" Kuzey enlemleri arasında, Eskişehir Porsuk Barajı yolunun 18. km'sindedir. Yağış alanı 5169,0 km² ve yaklaşık kotu 807 m'dir. İstasyon 01.07.1963 yılında hizmete açılmış ve hala ölçüm yapmaya devam etmektedir. Çalışmada D12A054 no'lu istasyondan 2006-2015 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2006-2013 yılları arasında ölçülen akım verileri eğitim; 2013-2015 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verilere ait istatistik parametreler Çizelge 5.7.'de verilmiştir.

Çizelge 5.7. D12A054 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A054 TÜM VERİLER	D12A054 EĞİTİM VERİLERİ	D12A054 TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	25907,939	20552,939	5355
En Büyük Debi (m ³ /sn)	42,8	42,8	21,3
En Küçük Debi (m ³ /sn)	0,765	0,765	1,6
Ortalama	7,094	7,033	7,335
Standart Sapma	6,559	6,821	5,377

5.2.7. D12A171 no'lu istasyon bilgileri

D12A171 No'lu istasyon; Porsuk Alt Havzası'nın 29°55'0" Doğu boylamlarıyla 39°46'0" Kuzey enlemleri arasında, Eskişehir Bozüyük kazasından sola dönülen asfalt yolun 25. km'sindeki Dodurga köyündedir. Yağış alanı 121 km² ve yaklaşık kotu 1070 m'dir. İstasyon 01.10.1983 yılında hizmete açılmış ve 2003 yılına kadar hizmet vermiştir. Çalışmada D12A171 no'lu istasyondan 1992-2003 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 1992-1999 yılları arasında ölçülen akım verileri eğitim; 2002-2003 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. İstasyon verilere ait istatistik parametreler Çizelge 5.8.'de verilmiştir.

Çizelge 5.8. D12A171 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A171 TÜM VERİLER	E12A003 EĞİTİM VERİLERİ	E12A003 TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	787,16	571,708	215,452
En Büyük Debi (m ³ /sn)	8,3	8,3	2,73
En Küçük Debi (m ³ /sn)	0	0	0,019
Ortalama	0,215	0,195	0,295
Standart Sapma	0,389	0,402	0,317

5.2.8. E12A003 no'lu istasyon bilgileri

Elektrik İşleri Etüt İdaresi Genel Müdürlüğü'ne ait E12A003 No'lu istasyon; Porsuk Alt Havzası'nın 30°2'56" Doğu boylamlarıyla 39°31'43" Kuzey enlemleri arasında, Eskişehir Kütahya kara yolunda Kütahya'ya 17 km uzaklıktaki Beşdeğirmenler yakınındadır. Yağış alanı 3938,4 km² ve yaklaşık kotu 855 m'dir. İstasyon 19.12.1935 yılında hizmete açılmış ve 30.09.2011 yılına kadar ölçümlerini sürdürmüştür. Çalışmada E12A003 no'lu istasyon verilerinden 2 kez faydalanılmıştır. İlkinde 1987-2011 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 1987-2006 yılları arasında ölçülen akım verileri eğitim; 2006-2011 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. Bu verilere ait istatistik parametreler Çizelge 5.9.'da verilmiştir.

Çizelge 5.9. E12A003 no'lu istasyona ait ilk veri bilgileri.

İstatistik Parametreler	E12A003 TÜM VERİLER	E12A003 EĞİTİM VERİLERİ	E12A003 TEST VERİLERİ
Veri Sayısı	9128	6938	2190
Toplam	2141,03	1473,083	667,947
En Büyük Debi (m ³ /sn)	6,12	6,12	3,2
En Küçük Debi (m ³ /sn)	0,014	0,014	0,052
Ortalama	0,234	0,213	0,304
Standart Sapma	0,306	0,303	0,303

Bir diğer yöntemde ise E12A003 no lu istasyon verileri yardımıyla D12A181 no'lu istasyon verileri tahmin edilmiştir. E12A003 no'lu istasyondan 2000-2009 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2000-2007 yılları arasında ölçülen akım verileri eğitim; 2008-2009 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. İstasyon verilere ait istatistik parametreler Çizelge 5.10.'da verilmiştir.

Çizelge 5.10. E12A003 no'lu istasyona ait ikinci veri bilgileri.

İstatistik Parametreler	D12A181 TÜM VERİLER	D12A181 EĞİTİM VERİLERİ	D12A181 TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	19375,9	16119,2	3256,7
En Büyük Debi (m ³ /sn)	27,3	27,3	22,9
En Küçük Debi (m ³ /sn)	1,02	1,08	1,02
Ortalama	5,31	5,52	4,46
Standart Sapma	4,85	4,86	4,76

5.2.9. D12A181 No'lu İstasyon Bilgileri

D12A181 No'lu istasyon; Porsuk Alt Havzası'nın 30°08'0" Doğu boylamlarıyla 39°28'0" Kuzey enlemleri arasında, Kütahya Eskişehir karayolunun 10. km'sindeki azot fabrikasından sağa dönülen yolun 1km ilerisindeki Saraybosna Köyündedir. Yağış alanı 3810,5 km² ve yaklaşık kotu 912 m'dir. İstasyon 01.10.1985 yılında hizmete açılmış ve

günümüzde hala hizmet vermeye devam etmektedir. Çalışmada D12A181 no'lu istasyondan 2000-2009 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2000-2007 yılları arasında ölçülen akım verileri eğitim; 2008-2009 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. İstasyon verilere ait istatistik parametreler Çizelge 5.11.'da verilmiştir.

Çizelge 5.11. D12A181 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A181 TÜM VERİLER	D12A181 EĞİTİM VERİLERİ	D12A181 TEST VERİLERİ
Veri Sayısı	3652	2922	730
Toplam	23329,8	19129,6	4200,2
En Büyük Debi (m ³ /sn)	54,8	54,8	39,6
En Küçük Debi (m ³ /sn)	0,564	0,564	2,15
Ortalama	6,39	6,54	5,75
Standart Sapma	7,09	7,51	5,49

5.2.10. D12A152 No'lu İstasyon Bilgileri

D12A152 No'lu istasyon; Porsuk Alt Havzası'nın 30°08'0" Doğu boylamlarıyla 38°58'0" Kuzey enlemleri arasında, Kütahya İli Beşkarış köyüne 5 km uzaklıktadır. Yağış alanı 214,8 km² ve yaklaşık kotu 1075 m'dir. İstasyon 01.10.1979 yılında hizmete açılmış ve günümüzde hala hizmet vermeye devam etmektedir. Çalışmada D12A152 no'lu istasyondan 2003-2010 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2003-2008 yılları arasında ölçülen akım verileri eğitim; 2009-2010 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. İstasyon verilere ait istatistik parametreler Çizelge 5.12.'de verilmiştir.

Çizelge 5.12. D12A152 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A152 TÜM VERİLER	D12A152 EĞİTİM VERİLERİ	D12A152 TEST VERİLERİ
Veri Sayısı	2922	2192	730
Toplam	2105,98	1429,79	4200,2
En Büyük Debi (m ³ /sn)	10,8	10,3	10,8
En Küçük Debi (m ³ /sn)	0,0	0,13	0,0
Ortalama	0,72	0,65	0,93
Standart Sapma	0,99	0,85	1,31

5.2.11. D12A093 no'lu istasyon bilgileri

D12A093 No'lu istasyon; Porsuk Alt Havzası'nın 30°10'0" Doğu boylamlarıyla 38°52'0" Kuzey enlemleri arasında, Altıntaş 20 km uzaklıktaki Çalköy-Sincanlı yollarının 5. km'sindeki Eyice köyündedir. Yağış alanı 153,1 km² ve yaklaşık kotu 1130 m'dir. İstasyon 01.10.1966 yılında hizmete açılmış ve günümüzde hala hizmet vermeye devam etmektedir. Çalışmada D12A093 no'lu istasyondan 2003-2010 yılları arasındaki günlük akım verileri temin edilmiş ve kullanılmıştır. 2003-2008 yılları arasında ölçülen akım verileri eğitim; 2009-2010 yılları arasında ölçülmüş akım verileri ise test amacıyla kullanılmıştır. İstasyon verilere ait istatistik parametreler Çizelge 5.13.'de verilmiştir.

Çizelge 5.13. D12A093 no'lu istasyona ait veri bilgileri.

İstatistik Parametreler	D12A093 TÜM VERİLER	D12A093 EĞİTİM VERİLERİ	D12A093 TEST VERİLERİ
Veri Sayısı	2922	2192	730
Toplam	1641,11	991,77	649,34
En Büyük Debi (m ³ /sn)	10,1	10,1	8,55
En Küçük Debi (m ³ /sn)	0,0	0,0	0,0
Ortalama	0,56	0,45	0,89
Standart Sapma	1,11	0,92	1,51

5.3. Yöntemlere Ait Parametrelerin Düzenlenmesi

Bu çalışmada kullanılan 3 farklı analiz tahmin yönteminden en iyi tahmin sonuçlarının alınabilmesi için bazı düzenlemeler yapılmıştır. Belirli denemelerden sonra en uygun parametreler belirlenmiş ve istasyonlardan temin edilen debi ve yağış verileri; en uygun parametrelere ayarlanmış yöntemlerle modellenmiştir. Çalışmada kullanılan tüm veriler 0-1 değeri arasında normalize edilmiş ve modelleme işleminden sonra normalize işleminin tersi uygulanarak gerçek değerler elde edilmiştir. En uygun modeller belirlendikten sonra her istasyona ait verilerin tahminleri yapılarak eksik akım verileri üretilmiştir.

5.3.1 Yapay sinir ağları ileri beslemeli geri yayılım yöntemi için belirlenen parametreler

İleri beslemeli geri yayılım ağında kullanılmak üzere 4 farklı girdi katmanı hazırlanmıştır. Hazırlanan bu katmanlar günlük akım verisinin sırasıyla 4 gün, 3 gün, 2 gün ve 1 gün ötelenmesiyle oluşturulmuştur. Her istasyon akım verilerinin tahmin modellerinin oluşturulması için farklı girdi verileri denenmiş ve içlerinden en iyi sonuçları verenler seçilerek veriler üretilmiştir. Girdi verileri belirlendikten sonra gizli katman nöron sayısı üzerinde denemeler yapılmıştır. Gizli nöron sayısı 1'den başlanarak 25'e kadar artırılarak modelin performansındaki değişim incelenmiştir. Bir dizi sıralı denemenin sonunda; D12A049 no'lu istasyon için 6 nöron, D12A152 no'lu istasyon için, 8 nöron, D12A181 no'lu istasyon için 12 nöron ve diğer istasyon verileriyle hazırlanan tahmin modelleri için ise 15 nöron seçilmiştir. Momentum katsayısı 0,9 ve öğrenme katsayısı ise 0,1 olarak seçilmiştir. İterasyon sayısı 5000 ve 10000 yapılarak denendikten sonra daha iyi sonuçlar verdiği için 10000 olmasına karar verilmiştir.

5.3.2. Evrimsel algoritmalar gen ifade programlama yöntemi için belirlenen parametreler

Çalışmada performansın artırılması için yöntemin algoritmalarında çeşitli değişiklikler yapılmıştır. Çalışmada gen miktarı 5 olarak belirlenmiş ve bunun yanında programın önerdiği 8 gen başlık sayısı da değiştirilmeden kullanılmıştır. Kromozom sayıları 5 değerinden başlatılarak 50 değerine kadar değiştirilmiş ve analiz sonuçlarını pozitif yönde etkilediği görülerek kromozom sayısı 50 seçilmiştir. Mutasyon oranı 0,044 olarak belirlenmiştir. IS ve RIS transfer katsayıları 0,1 olarak seçilmiştir. Tek ve iki

noktada çaprazlama oranı değiştirilmemiş ve programın önerdiği 0.3 değeri kullanılmıştır. Gen çaprazlama değeri 0,1 olarak ayarlanmıştır. Programlamanın kullandığı matematiksel ifadeler “+,-,*,./,sqrt,x²,x³,x⁴,x⁵,sin,cos,tan,cot” olarak belirlenmiş ve çok fazla matematiksel ifade seti kullanılabilir hale getirildiğinde programın başarısını olumsuz etkilediğinden diğer işlemler dahil edilmemiştir.

5.3.3. Parametrik trend analizi çoklu doğrusal regresyon yöntemi için belirlenen parametreler

Çalışmada kullanılan ve trend analizinin parametrik yöntemi olan çoklu regresyon analizi için herhangi bir ön hazırlık ya da düzenleme gerekmemektedir. Eğitim verileri yardımıyla analiz yapılmış ve diğer iki yöntemde olduğu gibi alınan en başarılı sonuçlar karşılaştırma amacıyla çalışmada verilmiştir.

5.4. İstasyon Akım Tahmini Sonuçları

İstasyon verileri ile tahmin modelleri oluşturulurken normalizasyon işlemi yapılmıştır. Akım değerleri 0-1 değerleri arasına indirgenmiştir ve 3 farklı analiz tahmin yöntemi ile modellemeler yapılmıştır.

5.4.1. D12A033 no’lu istasyonun analiz sonuçları

D12A033 no’lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün öncesine ait debi verileri girdi verisi olarak kullanılmıştır. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 6576 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 2190 adet test verisi yardımıyla yapılan analizinden alınan R^2 , MSE VE RMSE değerleri Çizelge 5.14.’de verilmiştir.

Çizelge 5.14. D12A033 no'lu istasyona ait analiz sonuçları.


Yöntemler	Girdi Verisi	R^2	MSE	RMSE
İBGY	Q033-4gün, Q033-3gün, Q033-2gün, Q033-1gün	0,90	1,82	1,35
GEP	Q033-4gün, Q033-3gün, Q033-2gün, Q033-1gün	0,83	3,03	1,74
ÇDR	Q033-4gün, Q033-3gün, Q033-2gün, Q033-1gün	0,77	4,28	2,07

Çizelge 5.14. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,90 R^2 değeriyle en başarılı sonuç elde edilmiş bu değeri 0,83 R^2 değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,77 R^2 değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.15.'de verilmiştir.


Çizelge 5.15. D12A033 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2015	1,26	1,45	2,16	2,58
2 Eylül 2015	1,19	1,38	2,12	2,53
3 Eylül 2015	1,26	1,34	2,08	2,49
4 Eylül 2015	1,07	1,35	2,08	2,47
5 Eylül 2015	1,07	1,27	2,06	2,44
6 Eylül 2015	1,01	1,27	2,04	2,43
7 Eylül 2015	1,07	1,25	2,03	2,42
8 Eylül 2015	1,01	1,25	2,02	2,40
9 Eylül 2015	1,07	1,23	2,02	2,39
10 Eylül 2015	1,07	1,25	2,02	2,39
11 Eylül 2015	1,01	1,25	2,03	2,40
12 Eylül 2015	1,01	1,23	2,02	2,39
13 Eylül 2015	1,01	1,23	2,02	2,39
14 Eylül 2015	1,07	1,23	2,02	2,39
15 Eylül 2015	1,13	1,25	2,02	2,39
16 Eylül 2015	1,13	1,27	2,04	2,39
17 Eylül 2015	1,13	1,27	2,05	2,40
18 Eylül 2015	1,01	1,28	2,05	2,41
19 Eylül 2015	1,01	1,24	2,03	2,41
20 Eylül 2015	1,07	1,24	2,02	2,40
21 Eylül 2015	1,13	1,26	2,03	2,40
22 Eylül 2015	1,19	1,27	2,04	2,39
23 Eylül 2015	1,26	1,29	2,05	2,40
24 Eylül 2015	1,26	1,32	2,07	2,42
25 Eylül 2015	1,26	1,33	2,08	2,44
26 Eylül 2015	1,19	1,34	2,08	2,45
27 Eylül 2015	1,19	1,32	2,08	2,45
28 Eylül 2015	1,19	1,32	2,07	2,45
29 Eylül 2015	1,19	1,31	2,07	2,44
30 Eylül 2015	1,26	1,31	2,07	2,44

D12A033 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.2. ve Şekil 5.3.'de verilmiştir.




Şekil 5.2. D12A033 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sınır ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.3. D12A033 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sınır ağı ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.2. ve 5.3. incelendiğinde tahmin verilerinin gözlenen verilere yakın olduğu görülmektedir. Tahmin verileri; 25 m³/s - 45 m³/s değerleri arasında gözlenen akım değerlerini tahmin etmede bir miktar başarısız olmuştur. Fakat 5 m³/s - 15 m³/s gözlenen akım değerleri aralığında model oldukça başarılı sonuçlar üretmiştir.

D12A033 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.4. ve Şekil 5.5.'de verilmiştir.




Şekil 5.4. D12A033 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.5. D12A033 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.4. ve 5.5. incelendiğinde model; 30 m³/s - 45 m³/s değerleri arasında gözlenen akım değerlerini tahmin etmede başarısız olmuştur. Fakat 2.5 m³/s - 10 m³/s gözlenen akım değerleri aralığında model daha başarılı sonuçlar üretmiştir.

D12A033 istasyonuna ait çoklu doğrusal regresyon yöntemi sonuçlarını gösteren grafikler Şekil 5.6. ve Şekil 5.7.'da verilmiştir.



Şekil 5.6. D12A033 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.7. D12A033 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.6. ve 5.7. incelendiğinde model; 25 m³/s – 40 m³/s değerleri arasında gözlenen akım değerlerini tahmin etmede çok başarısız olmuştur. Fakat 2.5 m³/s - 7.5 m³/s gözlenen akım değerleri aralığında model bir miktar başarılı sonuçlar üretmiştir.

5.4.2. E12A003 no’lu istasyonun analiz sonuçları

E12A003 no’lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün öncesine ait debi verileri girdi verisi olarak kullanılmıştır. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 6938 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 2190 adet test verisi yardımıyla yapılan analizinden alınan R², MSE VE RMSE değerleri Çizelge 5.18’de verilmiştir.

Çizelge 5.16. E12A003 no’lu istasyona ait analiz sonuçları.


Yöntemler	Girdi Verisi	R ²	MSE	RMSE
İBGY	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,97	0,94	0,97
GEP	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,86	6,97	2,64
ÇDR	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,81	3,50	1,87

Çizelge 5.16. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,97 R² değeriyle en başarılı sonuç elde edilmiş bu değeri 0,86 R² değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,81 R² değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.17.’de verilmiştir.


Çizelge 5.17. E12A003 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2011	2,38	2,62	3,72	3,39
2 Eylül 2011	2,38	2,60	3,72	3,39
3 Eylül 2011	2,00	2,60	3,68	3,35
4 Eylül 2011	1,80	2,49	3,61	3,32
5 Eylül 2011	1,70	2,33	3,58	3,30
6 Eylül 2011	1,70	2,28	3,49	3,21
7 Eylül 2011	1,65	2,25	3,50	3,22
8 Eylül 2011	1,65	2,24	3,50	3,23
9 Eylül 2011	1,65	2,22	3,51	3,24
10 Eylül 2011	1,65	2,22	3,50	3,23
11 Eylül 2011	1,60	2,22	3,51	3,24
12 Eylül 2011	1,65	2,21	3,50	3,24
13 Eylül 2011	1,70	2,21	3,51	3,24
14 Eylül 2011	1,65	2,24	3,51	3,23
15 Eylül 2011	1,70	2,23	3,52	3,25
16 Eylül 2011	1,75	2,23	3,52	3,25
17 Eylül 2011	1,75	2,26	3,52	3,24
18 Eylül 2011	1,80	2,27	3,53	3,26
19 Eylül 2011	1,80	2,28	3,54	3,26
20 Eylül 2011	2,16	2,29	3,54	3,26
21 Eylül 2011	2,21	2,38	3,60	3,29
22 Eylül 2011	2,95	2,50	3,61	3,30
23 Eylül 2011	3,32	2,72	3,81	3,42
24 Eylül 2011	2,83	3,13	3,86	3,43
25 Eylül 2011	2,77	3,01	3,94	3,56
26 Eylül 2011	2,83	2,83	3,87	3,50
27 Eylül 2011	2,83	2,89	3,72	3,35
28 Eylül 2011	2,83	2,89	3,78	3,41
29 Eylül 2011	2,77	2,88	3,80	3,43
30 Eylül 2011	2,77	2,86	3,78	3,42

E12A003 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.8. ve Şekil 5.9.'da verilmiştir.




Şekil 5.8. E12A003 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.9. E12A003 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.8. ve 5.9. incelendiğinde model; 20 m³/s - 25 m³/s değerleri arasında gözlenen birkaç akım değerlerini tahmin etmede bir miktar başarısız olmuştur. Bunun dışında modelin genel performansının oldukça başarılı olduğu görülmüştür.

E12A003 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.10. ve Şekil 5.11.'de verilmiştir.




Şekil 5.10. E12A003 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.11. E12A003 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.10. ve 5.11. incelendiğinde modelden; 10 m³/s - 20 m³/s gözlenen akım değerleri aralığında başarılı sonuçlar elde edilmiştir. 7 m³/s - 15 m³/s gözlenen akım değerleri aralığında model başarısı bir miktar azalmıştır. Model; 20 m³/s - 30 m³/s değerleri arasında gözlenen akım değerlerini tahmin etmede başarısız olmuştur.

E12A003 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.12. ve Şekil 5.13.'de verilmiştir.



Şekil 5.12. E12A003 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.13. E12A003 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.12. ve 5.13. incelendiğinde tahmin modelinden; 5 m³/s - 15 m³/s gözlenen akım değerleri aralığında bir miktar başarılı sonuçlar elde edilmiştir. Özellikle 20 m³/s - 25 m³/s gözlenen akım değerleri aralığında model tahmin performansı oldukça düşmüştür.

5.4.3. D12A171 no'lu istasyonun analiz sonuçları

D12A171 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün öncesine ait debi verileri girdi verisi olarak kullanılmıştır. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 2922 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 730 adet test verisi yardımıyla yapılan analizinden alınan R², MSE VE RMSE değerleri Çizelge 5.18.'de verilmiştir.

Çizelge 5.18. D12A171 no'lu istasyona ait analiz sonuçları.


Yöntemler	Girdi Verisi	R ²	MSE	RMSE
İBGY	Q _{171-4gün} , Q _{003-3gün} , Q _{003-2gün} , Q _{003-1gün}	0,87	0,075	0,273
GEP	Q _{171-4gün} , Q _{003-3gün} , Q _{003-2gün} , Q _{003-1gün}	0,75	0,144	0,379
ÇDR	Q _{171-4gün} , Q _{003-3gün} , Q _{003-2gün} , Q _{003-1gün}	0,71	0,165	0,379

Çizelge 5.18. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,87 R² değeriyle en başarılı sonuç elde edilmiş bu değeri 0,75 R² değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,71 R² değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.19.'da verilmiştir.


Çizelge 5.19. D12A171 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2003	0,051	0,103	0,112	0,424
2 Eylül 2003	0,051	0,103	0,112	0,424
3 Eylül 2003	0,035	0,103	0,112	0,424
4 Eylül 2003	0,035	0,098	0,111	0,415
5 Eylül 2003	0,051	0,099	0,109	0,412
6 Eylül 2003	0,051	0,102	0,110	0,427
7 Eylül 2003	0,051	0,101	0,112	0,426
8 Eylül 2003	0,051	0,103	0,112	0,420
9 Eylül 2003	0,051	0,103	0,112	0,424
10 Eylül 2003	0,051	0,103	0,112	0,424
11 Eylül 2003	0,076	0,103	0,112	0,424
12 Eylül 2003	0,076	0,112	0,114	0,440
13 Eylül 2003	0,051	0,110	0,118	0,445
14 Eylül 2003	0,051	0,105	0,116	0,419
15 Eylül 2003	0,051	0,107	0,113	0,422
16 Eylül 2003	0,051	0,104	0,114	0,432
17 Eylül 2003	0,076	0,103	0,112	0,424
18 Eylül 2003	0,076	0,112	0,114	0,440
19 Eylül 2003	0,051	0,110	0,118	0,445
20 Eylül 2003	0,051	0,105	0,116	0,419
21 Eylül 2003	0,051	0,107	0,113	0,422
22 Eylül 2003	0,051	0,104	0,114	0,432
23 Eylül 2003	0,051	0,103	0,112	0,424
24 Eylül 2003	0,051	0,103	0,112	0,424
25 Eylül 2003	0,051	0,103	0,112	0,424
26 Eylül 2003	0,051	0,103	0,112	0,424
27 Eylül 2003	0,051	0,103	0,112	0,424
28 Eylül 2003	0,051	0,103	0,112	0,424
29 Eylül 2003	0,051	0,103	0,112	0,424
30 Eylül 2003	0,051	0,103	0,112	0,424

D12A054 istasyonuna ait ileri beslemeli geri yayılım yöntemi sonuçlarını gösteren grafikler Şekil 5.14. ve Şekil 5.15.'de verilmiştir.




Şekil 5.14. D12A171 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.15. D12A171 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.14. ve 5.15. incelendiğinde tahmin verilerinin gözlenen verilere yakın olduğu görülmektedir. Tahmin verileri; $4 \text{ m}^3/\text{s}$ - $5 \text{ m}^3/\text{s}$ değerleri arasında gözlenen verilerde akım değerlerini tahmin etmede bir miktar başarısız olmuştur. Bunun dışında modelin performansının genel olarak başarılı olduğu görülmüştür.

D12A171 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.16. ve Şekil 5.17.'de verilmiştir




Şekil 5.16. D12A171 no'lu akım gözlem istasyonu için gen ifade programlama yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.17. D12A171 no'lu akım gözlem istasyonu için gen ifade programlama yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.16. ve 5.17. incelendiğinde modelden; $0.2 \text{ m}^3/\text{s} - 2 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında başarılı sonuçlar elde edilmiştir. Özellikle $3 \text{ m}^3/\text{s} - 4 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında model tahmin performansı düşmüştür.

D12A171 istasyonuna ait çoklu doğrusal regresyon yöntemi sonuçlarını gösteren grafikler Şekil 5.18. ve Şekil 5.19.'da verilmiştir.



Şekil 5.18. D12A171 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.19. D12A171 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.18. ve 5.19. incelendiğinde modelden; $0.2 \text{ m}^3/\text{s} - 2 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında başarılı sonuçlar elde edilmiştir. Özellikle $3 \text{ m}^3/\text{s} - 4 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında model tahmin performansı düşmüştür. Tahmin modeli bazı anlarda gözlenen akım değerlerine çok uzak veriler üretmiştir.

5.4.4. D12A049 no'lu istasyonun analiz sonuçları

D12A049 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün öncesine ait debi verileri girdi verisi olarak kullanılmıştır. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 3652 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 2922 adet test verisi yardımıyla yapılan analizinden alınan R^2 , MSE VE RMSE değerleri Çizelge 5.20.'de verilmiştir.

Çizelge 5.20. D12A049 no'lu istasyona ait analiz sonuçları.


Yöntemler	Girdi Verisi	R^2	MSE	RMSE
İBGY	Q _{049-4gün} , Q _{049-3gün} , Q _{049-2gün} , Q _{049-1gün}	0,85	0,025	0,159
GEP	Q _{049-4gün} , Q _{049-3gün} , Q _{049-2gün} , Q _{049-1gün}	0,75	0,040	0,200
ÇDR	Q _{049-4gün} , Q _{049-3gün} , Q _{049-2gün} , Q _{049-1gün}	0,71	0,046	0,215

Çizelge 5.16. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. $0,86 R^2$ değeriyle en başarılı sonuç elde edilmiş bu değeri $0,75 R^2$ değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve $0,61 R^2$ değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.21.'de verilmiştir.


Çizelge 5.21. D12A049 No’lu İstasyona Ait 30 Günlük Tahmin Değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2013	0,31	0,29	0,26	0,26
2 Eylül 2013	0,31	0,29	0,26	0,26
3 Eylül 2013	0,31	0,29	0,26	0,26
4 Eylül 2013	0,31	0,29	0,26	0,26
5 Eylül 2013	0,31	0,29	0,26	0,26
6 Eylül 2013	0,31	0,29	0,26	0,26
7 Eylül 2013	0,26	0,29	0,26	0,26
8 Eylül 2013	0,26	0,24	0,24	0,24
9 Eylül 2013	0,26	0,25	0,24	0,24
10 Eylül 2013	0,26	0,25	0,24	0,24
11 Eylül 2013	0,26	0,25	0,23	0,22
12 Eylül 2013	0,26	0,25	0,23	0,22
13 Eylül 2013	0,26	0,25	0,23	0,22
14 Eylül 2013	0,26	0,25	0,23	0,22
15 Eylül 2013	0,26	0,25	0,23	0,22
16 Eylül 2013	0,26	0,25	0,23	0,22
17 Eylül 2013	0,26	0,25	0,23	0,23
18 Eylül 2013	0,26	0,25	0,23	0,23
19 Eylül 2013	0,26	0,25	0,23	0,23
20 Eylül 2013	0,26	0,25	0,23	0,23
21 Eylül 2013	0,26	0,25	0,23	0,23
21 Eylül 2013	0,26	0,25	0,23	0,23
22 Eylül 2013	0,26	0,25	0,23	0,23
23 Eylül 2013	0,26	0,25	0,23	0,23
24 Eylül 2013	0,26	0,25	0,23	0,23
25 Eylül 2013	0,26	0,25	0,23	0,23
26 Eylül 2013	0,26	0,25	0,23	0,23
27 Eylül 2013	0,26	0,25	0,23	0,23
28 Eylül 2013	0,26	0,25	0,23	0,23
29 Eylül 2013	0,26	0,25	0,23	0,23
30 Eylül 2013	0,26	0,25	0,23	0,23

D12A049 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.20. ve Şekil 5.21’de verilmiştir.



Şekil 5.20. D12A049 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.21. D12A049 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri.


Şekil 5.20. ve 5.21. incelendiğinde tahmin verilerinin gözlenen verilere yakın olduğu görülmektedir. Tahmin modelinden $0.25 \text{ m}^3/\text{s}$ – $1.5 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında kısmen başarılı sonuçlar elde edilmiştir. Özellikle $1.5 \text{ m}^3/\text{s}$ – $2.5 \text{ m}^3/\text{s}$ gözlenen

akım değerleri aralığında model tahmin değerleri gerçek değerlere çok uzak tahmin edilmiştir ve model performansı düşmüştür.

D12A049 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.22. ve Şekil 5.23.'de verilmiştir.




Şekil 5.22. D12A049 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.23. D12A049 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.22. ve 5.23. incelendiğinde tahmin verilerinin gözlenen verilere yakın olduğu görülmektedir. Tahmin modelinden $0.15 \text{ m}^3/\text{s} - 0.4 \text{ m}^3/\text{s}$ ve $0.6 \text{ m}^3/\text{s} - 0.8 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında kısmen başarılı sonuçlar elde edilmiştir. Özellikle $1.2 \text{ m}^3/\text{s} - 1.6 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında model tahmin değerleri gerçek değerlere çok uzak tahmin edilmiştir ve model performansı düşmüştür.

D12A049 istasyonuna ait çoklu doğrusal regresyon yöntemi sonuçlarını gösteren grafikler Şekil 5.24. ve Şekil 5.25.'de verilmiştir.



Şekil 5.24. D12A049 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.25. D12A049 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.24. ve 5.25. incelendiğinde tahmin modelinden $0.18 \text{ m}^3/\text{s} - 0.38 \text{ m}^3/\text{s}$ ve $0.5 \text{ m}^3/\text{s} - 0.6 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında kısmen başarılı sonuçlar elde edildiği görülmektedir. Özellikle $1.0 \text{ m}^3/\text{s} - 1.8 \text{ m}^3/\text{s}$ gözlenen akım değerleri aralığında model tahmin değerleri gerçek değerlere çok uzak tahmin edilmiştir ve model performansı çok düşmüştür.

5.4.5. D12A173 no'lu istasyonun analiz sonuçları

D12A173 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyona ek D12A063 no'lu istasyon verileri de kullanılmıştır. Diğer yöntemlerde olduğu gibi D12A173 no'lu istasyon verileri 1 gün ötelenmiş bu verilere ek D12A063 no'lu istasyonun o güne ait akım verisi ile girdi verisi oluşturulmuştur. 3 günlük ve 4 günlük öteleme verileri modellerin performansını düşürdüğünden D12A063 no'lu istasyona ait veriler 2 gün ve 1 gün ötelenerek girdi verilerine dahil edilmiştir. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 2923 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 730 adet test verisi yardımıyla yapılan analizinden alınan R^2 , MSE ve RMSE değerleri Çizelge 5.22.'de verilmiştir.

Çizelge 5.22. D12A173 no'lu istasyona ait analiz sonuçları.

Yöntemler	Girdi Verisi	R^2	MSE	RMSE
İBGY	$Q_{063-2\text{gün}}, Q_{163-1\text{gün}}, Q_{063}, Q_{173-1\text{gün}}$	0,97	1,54	1,24
GEP	$Q_{063-2\text{gün}}, Q_{163-1\text{gün}}, Q_{063}, Q_{173-1\text{gün}}$	0,85	7,84	2,80
ÇDR	$Q_{063-2\text{gün}}, Q_{163-1\text{gün}}, Q_{063}, Q_{173-1\text{gün}}$	0,79	10,56	3,25


Çizelge 5.22. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,97 R^2 değeriyle en başarılı sonuç elde edilmiş bu

değeri 0,85 R^2 değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,79 R^2 değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.23.'de verilmiştir.


Çizelge 5.23. D12A173 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2000	12,50	12,70	12,70	12,57
2 Eylül 2000	12,50	12,70	12,70	12,57
3 Eylül 2000	12,50	12,70	12,70	12,57
4 Eylül 2000	12,50	12,70	12,70	12,57
5 Eylül 2000	12,50	12,70	12,70	12,57
6 Eylül 2000	12,50	12,70	12,70	12,57
7 Eylül 2000	12,50	12,70	12,70	12,57
8 Eylül 2000	12,50	12,70	12,70	12,57
9 Eylül 2000	12,80	12,70	12,70	12,57
10 Eylül 2000	12,80	12,70	12,97	12,78
11 Eylül 2000	12,80	12,70	12,97	12,78
12 Eylül 2000	12,80	12,97	12,97	12,78
13 Eylül 2000	13,00	12,97	12,97	12,78
14 Eylül 2000	13,30	12,97	13,14	12,92
15 Eylül 2000	13,30	12,97	13,39	13,12
16 Eylül 2000	13,30	13,15	13,39	13,12
17 Eylül 2000	13,50	13,42	13,39	13,12
18 Eylül 2000	13,50	13,42	13,55	13,24
19 Eylül 2000	13,50	13,42	13,55	13,24
20 Eylül 2000	13,50	13,60	13,55	13,24
21 Eylül 2000	13,50	13,60	13,55	13,24
22 Eylül 2000	13,00	13,60	13,55	13,24
23 Eylül 2000	13,00	13,60	13,14	12,92
24 Eylül 2000	13,00	13,60	13,14	12,92
25 Eylül 2000	13,00	13,15	13,14	12,92
26 Eylül 2000	13,00	13,15	13,14	12,92
27 Eylül 2000	13,00	13,15	13,14	12,92
28 Eylül 2000	13,00	13,15	13,14	12,92
29 Eylül 2000	13,00	13,15	13,14	12,92
30 Eylül 2000	13,00	13,15	13,14	12,92

D12A173 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.26. ve Şekil 5.27.'de verilmiştir.




Şekil 5.26. D12A173 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.27. D12A173 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.26. ve 5.27. incelendiğinde tahmin verilerinin; $20 \text{ m}^3/\text{s}$ - $30 \text{ m}^3/\text{s}$ değerleri arasında gözlenen birkaç veride akım değerlerini tahmin etmede bir miktar başarısız olduğu görülmektedir. Bunun dışında modelin genel performansı oldukça başarılıdır.

D12A173 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.28. ve Şekil 5.29.'da verilmiştir.




Şekil 5.28. D12A173 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.29. D12A173 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.28. ve 5.29. incelendiğinde $1.8 \text{ m}^3/\text{s}$ - $7 \text{ m}^3/\text{s}$ ve $12 \text{ m}^3/\text{s}$ - $18 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında başarılı tahmin verileri ürettiği görülmektedir. Model; $10 \text{ m}^3/\text{s}$ - $15 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek değerlere çok uzak birtakım veriler üreterek performansında düşüş yaşamıştır.

D12A173 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.30. ve Şekil 5.31.'de verilmiştir.



Şekil 5.30. D12A173 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.31. D12A173 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.30. ve 5.31. incelendiğinde $2.5 \text{ m}^3/\text{s}$ - $7 \text{ m}^3/\text{s}$ ve $12 \text{ m}^3/\text{s}$ - $15 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında başarılı tahmin verileri ürettiği görülmektedir. Model; $10 \text{ m}^3/\text{s}$ - $15 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek değerlere çok uzak birtakım veriler üreterek performansında düşüş yaşamıştır. Ayrıca $15 \text{ m}^3/\text{s}$ - $22 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında model tahmin performansının oldukça düştüğü görülmektedir.

5.4.6. D12A054 no'lu istasyonun analiz sonuçları

D12A054 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyona ek 17126 no'lu istasyon yağış gözlem istasyonu verileri de kullanılmıştır. Diğer yöntemlerde olduğu gibi D12A054 no'lu istasyon verileri 1 gün ötelenmiş bu verilere ek 17126 no'lu yağış gözlem istasyonun o güne ait yağış verisi ile birlikte sırasıyla 3 gün, 2 gün ve 1 gün ötelenmiş verileri ile girdi verisi oluşturulmuştur. 1 gün ve 2 gün ötelenmiş yağış verileri sırasıyla denenmiş ama en anlamlı ilişki 3 gün ötelenmiş yağış verileri de girdi verisine eklenince kurulmuştur. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 6937 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 2192 adet test verisi yardımıyla yapılan analizinden alınan R^2 , MSE VE RMSE değerleri Çizelge 5.24.'de verilmiştir.

Çizelge 5.24. D12A054 no'lu istasyona ait Analiz sonuçları.


Yöntemler	Girdi Verisi	R^2	MSE	RMSE
İBGY	$Y_{17126}, Q_{173-4\text{gün}}, Q_{173-3\text{gün}}, Q_{173-2\text{gün}}, Q_{173-1\text{gün}}$	0,92	2,31	1,52
GEP	$Y_{17126}, Q_{173-4\text{gün}}, Q_{173-3\text{gün}}, Q_{173-2\text{gün}}, Q_{173-1\text{gün}}$	0,86	4,12	2,03
ÇDR	$Y_{17126}, Q_{173-4\text{gün}}, Q_{173-3\text{gün}}, Q_{173-2\text{gün}}, Q_{173-1\text{gün}}$	0,77	6,55	2,56

Çizelge 5.22. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. $0,92 R^2$ değeriyle en başarılı sonuç elde edilmiş bu değeri $0,86 R^2$ değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve $0,77 R^2$ değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.25.'de verilmiştir.


Çizelge 5.25. D12A054 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2015	10,5	11,75	10,83	11,30
2 Eylül 2015	9,92	10,43	9,45	9,86
3 Eylül 2015	9,62	9,77	8,82	9,19
4 Eylül 2015	9,62	9,42	8,51	8,86
5 Eylül 2015	9,62	9,42	8,51	8,86
6 Eylül 2015	9,62	9,42	8,51	8,86
7 Eylül 2015	9,62	9,42	8,51	8,86
8 Eylül 2015	9,62	9,42	8,51	8,86
9 Eylül 2015	10,2	9,42	8,51	8,86
10 Eylül 2015	10,2	10,09	9,12	9,52
11 Eylül 2015	10,2	10,09	9,12	9,52
12 Eylül 2015	10,2	10,09	9,12	9,52
13 Eylül 2015	10,8	10,13	9,29	9,54
14 Eylül 2015	10,8	10,76	9,73	10,20
15 Eylül 2015	10,8	10,74	9,52	10,06
16 Eylül 2015	10,8	10,79	9,50	10,05
17 Eylül 2015	10,8	10,76	9,79	10,22
18 Eylül 2015	10,8	10,76	9,79	10,22
19 Eylül 2015	10,8	10,76	9,79	10,22
20 Eylül 2015	10,8	10,76	9,79	10,22
21 Eylül 2015	10,8	10,76	9,79	10,22
21 Eylül 2015	10,8	10,76	9,79	10,22
22 Eylül 2015	6,85	10,76	9,79	10,22
23 Eylül 2015	5,42	6,39	8,87	7,25
24 Eylül 2015	5,42	4,66	4,63	4,78
25 Eylül 2015	5,19	4,56	3,09	3,27
26 Eylül 2015	5,19	4,27	3,09	3,22
27 Eylül 2015	4,95	4,61	4,84	4,79
28 Eylül 2015	4,95	4,43	4,91	4,72
29 Eylül 2015	4,95	4,41	4,72	4,61
30 Eylül 2015	4,95	4,48	6,28	5,23

D12A054 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.32. ve Şekil 5.33.'de verilmiştir.




Şekil 5.32. D12A054 No'lu Akım Gözlem İstasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.33. D12A054 no'lu akım gözlem İstasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.32. ve 5.33. incelendiğinde model tahmin verilerinin gerçek akım değerlerine kısmen yakın olduğu görülmektedir. Herhangi bir veri aralığında özellikle başarılı ya da başarısız olmamış; model kısmen gerçek akım değerlerine yakın veriler üretmiştir.

D12A054 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.34. ve Şekil 5.35.'de verilmiştir.




Şekil 5.34. D12A054 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.35. D12A054 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.34. ve 5.35. incelendiğinde $5 \text{ m}^3/\text{s}$ – $15 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek akım verilerine uzak tahmin değerleri üretildiği görülmektedir. Model özellikle $15 \text{ m}^3/\text{s}$ - $20 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçeğe yakın tahmin verileri üretmiştir.

D12A054 istasyonuna ait çoklu doğrusal regresyon yöntemi sonuçlarını gösteren grafikler Şekil 5.36. ve Şekil 5.37.'de verilmiştir.



Şekil 5.36. D12A054 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.37. D12A054 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.36. ve 5.37. incelendiğinde $5 \text{ m}^3/\text{s}$ - $14 \text{ m}^3/\text{s}$ ve $16 \text{ m}^3/\text{s}$ - $20 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek akım verilerine uzak tahmin değerleri üretildiği görülmektedir. Modelin genel performansı gen ifade programlama yöntemiyle hazırlanan

model başarısına yakındır ama gerçek verilere uzak tahmin verileri bu modelde daha fazla üretilmiştir.

5.4.7. D12A181 no'lu istasyonun analiz sonuçları

D12A181 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyona ek E12A003 no'lu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün ve o güne ait debi verisi girdi verisi olarak kullanılmıştır. D12A181 no'lu istasyonun hiçbir verisi girdi verisine dahil edilmemiştir. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 2922 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 730 adet test verisi yardımıyla yapılan analizinden alınan R^2 , MSE ve RMSE değerleri Çizelge 5.26.'da verilmiştir.

Çizelge 5.26. E12A003 no'lu istasyona ait analiz sonuçları.


Yöntemler	Girdi Verisi	R^2	MSE	RMSE
İBGY	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,84	4,26	2,06
GEP	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,73	7,02	2,65
ÇDR	Q003-4gün, Q003-3gün, Q003-2gün, Q003-1gün	0,61	10,18	3,19

Çizelge 5.26. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,84 R^2 değeriyle en başarılı sonuç elde edilmiş bu değeri 0,73 R^2 değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,61 R^2 değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.27.'de verilmiştir.


Çizelge 5.27. D12A181 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2011	5,9	2,10	0,76	4,41
2 Eylül 2011	5,64	2,02	0,76	4,44
3 Eylül 2011	5,77	2,08	0,75	4,49
4 Eylül 2011	5,77	2,07	0,76	4,38
5 Eylül 2011	5,9	2,11	0,76	4,44
6 Eylül 2011	5,64	2,08	0,76	4,45
7 Eylül 2011	5,64	2,07	0,76	4,47
8 Eylül 2011	6,63	2,25	0,76	4,41
9 Eylül 2011	6,74	2,60	0,77	4,35
10 Eylül 2011	6,41	2,34	0,77	4,46
11 Eylül 2011	6,63	2,56	0,76	4,72
12 Eylül 2011	6,63	2,65	0,80	4,38
13 Eylül 2011	6,41	2,50	0,79	4,54
14 Eylül 2011	6,15	2,57	0,78	4,68
15 Eylül 2011	6,28	2,51	0,80	4,49
16 Eylül 2011	6,15	2,55	0,79	4,55
17 Eylül 2011	6,03	2,50	0,79	4,54
18 Eylül 2011	5,9	2,49	0,79	4,57
19 Eylül 2011	5,64	2,41	0,79	4,55
20 Eylül 2011	5,64	2,42	0,78	4,54
21 Eylül 2011	5,51	2,39	0,78	4,50
22 Eylül 2011	5,64	2,43	0,78	4,52
23 Eylül 2011	5,64	2,45	0,78	4,50
24 Eylül 2011	5,51	2,46	0,78	4,53
25 Eylül 2011	5,51	2,44	0,78	4,54
26 Eylül 2011	5,39	2,44	0,78	4,54
27 Eylül 2011	5,51	2,43	0,78	4,52
28 Eylül 2011	5,51	2,47	0,78	4,53
29 Eylül 2011	4,91	2,33	0,78	4,53
30 Eylül 2011	5,02	2,41	0,78	4,57

D12A181 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.38. ve Şekil 5.39.'da verilmiştir.




Şekil 5.38. D12A181 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sınır ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.39. D12A181 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sınır ağı ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.38 ve Şekil 5.39 incelendiğinde $12 \text{ m}^3/\text{s}$ - $20 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında oldukça başarılı tahmin verilerinin üretildiği görülmektedir. Model $25 \text{ m}^3/\text{s}$ - $35 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek değerlere uzak çok sayıda veri üreterek performansında düşüş yaşamıştır.

D12A181 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.40. ve Şekil 5.41.'da verilmiştir.



Şekil 5.40. D12A181 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.41. D12A181 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.


Şekil 5.40 ve Şekil 5.41 incelendiğinde model tahminlerinin çok başarılı olmadığı görülmektedir. Özellikle $2 \text{ m}^3/\text{s}$ - $3 \text{ m}^3/\text{s}$ gözlenen akım değer aralığında model

performansı çok ciddi şekilde düşmüştür. Benzer şekilde $30 \text{ m}^3/\text{s}$ - $34 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında da model performansı düşmüştür.

D12A181 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.42. ve Şekil 5.43.'de verilmiştir.



Şekil 5.42. D12A181 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.43. D12A181 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.42 ve Şekil 5.43 incelendiğinde model tahminlerinin çok başarılı olmadığı görülmektedir. Özellikle $4 \text{ m}^3/\text{s}$ - $8 \text{ m}^3/\text{s}$ gözlenen akım değer aralığında model

performansı çok ciddi şekilde düşmüştür. Benzer şekilde 20 m³/s - 35 m³/s gözlenen akım değerleri arasında da model performansı düşmüştür. Genel olarak incelendiğinde model performansının hidrolik veri tahmin modeli olarak kullanılmaya uygun olmadığı görülmüştür.

5.4.8. D12A152 no'lu istasyonun analiz sonuçları

D12A152 no'lu istasyona ait verilerle modelleme için hazırlanan girdi verilerinde bu istasyona ek D12A093 no'lu istasyondan temin edilen; 4 gün, 3 gün, 2 gün, 1 gün ve o güne ait debi verisi girdi verisi olarak kullanılmıştır. D12A152 no'lu istasyonun hiçbir verisi girdi verisine dahil edilmemiştir. 3 farklı tahmin yöntemiyle yapılan çalışma sonucunda en iyi tahmin parametreleri ayarlanarak; 2922 adet eğitim verisi yardımıyla eğitilen ileri beslemeli geri yayılım ağı modellerinin 2192 adet test verisi yardımıyla yapılan analizinden alınan R², MSE VE RMSE değerleri Çizelge 5.28.'de verilmiştir.

Çizelge 5.28. D12A152 No'lu İstasyona Ait Analiz Sonuçları

Yöntemler	Girdi Verisi	R ²	MSE	RMSE
İBGY	Q _{093-4gün} , Q _{093-3gün} , Q _{093-2gün} , Q _{093-1gün}	0,65	0,605	0,778
GEP	Q _{093-4gün} , Q _{093-3gün} , Q _{093-2gün} , Q _{093-1gün}	0,55	0,774	0,880
ÇDR	Q _{093-4gün} , Q _{093-3gün} , Q _{093-2gün} , Q _{093-1gün}	0,41	1,002	1,001


Çizelge 5.28. incelendiğinde en başarılı sonuçları ileri beslemeli geri yayılım yönteminin verdiği görülmektedir. 0,65 R² değeriyle en başarılı sonuç elde edilmiş bu değeri 0,55 R² değeri elde edilmiş gen ifade programlama yöntemi takip etmiştir. İstasyon verilerinin tahmininde en başarısız sonucu çoklu doğrusal regresyon yöntemi vermiş ve 0,41 R² değerine ulaşabilmiştir. Her tahmin yöntemine ait grafikler Her tahmin yöntemine

ait test tahmin verileri ve gerçek veriler 30 günlük olarak karşılaştırma amacıyla Çizelge 5.29.'da verilmiştir.


Çizelge 5.29. D12A152 no'lu istasyona ait 30 günlük tahmin değerleri.

Veri Tarihi	Gerçek Değer	İBGY	GEP	ÇDR
1 Eylül 2011	0,31	0,31	0,55	0,51
2 Eylül 2011	0,31	0,31	0,55	0,51
3 Eylül 2011	0,31	0,31	0,54	0,51
4 Eylül 2011	0,31	0,31	0,55	0,51
5 Eylül 2011	0,31	0,31	0,55	0,51
6 Eylül 2011	0,31	0,31	0,55	0,51
7 Eylül 2011	0,31	0,31	0,55	0,51
8 Eylül 2011	0,31	0,31	0,55	0,51
9 Eylül 2011	0,31	0,31	0,55	0,51
10 Eylül 2011	0,31	0,31	0,55	0,51
11 Eylül 2011	0,31	0,31	0,55	0,51
12 Eylül 2011	0,31	0,31	0,55	0,51
13 Eylül 2011	0,31	0,31	0,55	0,51
14 Eylül 2011	0,31	0,31	0,55	0,51
15 Eylül 2011	0,31	0,31	0,55	0,51
16 Eylül 2011	0,31	0,31	0,55	0,51
17 Eylül 2011	0,31	0,31	0,55	0,51
18 Eylül 2011	0,31	0,31	0,55	0,51
19 Eylül 2011	0,31	0,31	0,55	0,51
20 Eylül 2011	0,31	0,31	0,55	0,51
21 Eylül 2011	0,31	0,31	0,55	0,51
21 Eylül 2011	0,28	0,31	0,55	0,51
22 Eylül 2011	0,28	0,31	0,55	0,51
23 Eylül 2011	0,26	0,31	0,55	0,51
24 Eylül 2011	0,26	0,31	0,55	0,51
25 Eylül 2011	0,26	0,31	0,55	0,51
26 Eylül 2011	0,26	0,31	0,55	0,51
27 Eylül 2011	0,26	0,31	0,55	0,51
28 Eylül 2011	0,26	0,31	0,55	0,51
29 Eylül 2011	0,26	0,32	0,55	0,51
30 Eylül 2011	0,26	0,32	0,55	0,51

D12A152 istasyonuna ait ileri beslemeli geri yayılım sinir ağı yöntemi sonuçlarını gösteren grafikler Şekil 5.44. ve Şekil 5.45.'de verilmiştir.



Şekil 5.44. D12A152 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.45. D12A152 no'lu akım gözlem istasyonu için ileri beslemeli geri yayılım sinir ağı ile tahmin edilen akım verileri ve gerçek akım verileri.


Şekil 5.44 ve Şekil 5.45 incelendiğinde $10 \text{ m}^3/\text{s}$ - $20 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında gerçek değerlere yakın veriler üretildiği görülmektedir. Model $2 \text{ m}^3/\text{s}$ - $10 \text{ m}^3/\text{s}$

gözlenen akım değerleri arasında ise çok başarısız olmuş ve gerçek değerlerden uzak tahmin verileri üretmiştir.

D12A152 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.46. ve Şekil 5.47.'de verilmiştir.



Şekil 5.46. D12A152 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.




Şekil 5.47. D12A152 no'lu akım gözlem istasyonu için gen ifade programlama ile tahmin edilen akım verileri ve gerçek akım verileri.


Şekil 5.44 ve Şekil 5.45 incelendiğinde model performansının genel olarak başarısız olduğu görülmektedir. Model $2 \text{ m}^3/\text{s}$ - $4 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında

ise çok başarısız olarak gerçek değerlerden uzak tahmin verileri üretmiştir. 15 m³/s - 34 m³/s gözlenen akım değer aralığında ise modelden kısmen başarısız sonuçlar elde edilmiştir ve modelin bu haliyle hidrolik veri tahminlerinde kullanılamayacağı sonucuna ulaşılmıştır.

D12A152 istasyonuna ait gen ifade programlama yöntemi sonuçlarını gösteren grafikler Şekil 5.48. ve Şekil 5.49.'da verilmiştir.



Şekil 5.48. D12A152 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verilerine ait saçılım diyagramı.



Şekil 5.49. D12A152 no'lu akım gözlem istasyonu için çoklu regresyon yöntemi ile tahmin edilen akım verileri ve gerçek akım verileri.

Şekil 5.48 ve Şekil 5.49. incelendiğinde model performansının oldukça düşük olduğu görülmektedir. Model $4 \text{ m}^3/\text{s}$ - $7 \text{ m}^3/\text{s}$ gözlenen akım değerleri arasında çok kötü bir performans sergilemiştir ve bu haliyle hidrolik veri tahminlerinde kullanılamayacağını sonucuna ulaşmıştır.



6. SONUÇLAR

Çalışmada toplamda 10 adet akım gözlem istasyonu ile 1 adet yağış gözlem istasyonundan temin edilen veriler kullanılarak akım tahmin modelleri geliştirilmiştir. Tahmin modelleri geliştirilmesi için 3 farklı yöntem kullanılmıştır ve alınan sonuçlar karşılaştırılarak yöntemlerin tahmin modelleri oluşturma performansları kıyaslanmıştır. Farklı veri setleri ve farklı model parametreleri ile yapılan tahmin analizlerinden alınan sonuçlar karşılaştırma amacıyla çalışmada verilmiştir.

D12A033 no'lu istasyonda 24 senelik veri seti kullanılmış ve modellerin eğitimi için tüm girdi verileri aynı istasyonun ötelenmiş akım verilerinden elde edilmiştir. Bu bağlamda modeller istasyon verilerine tam bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,90 R^2 ve 1.82 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur ve ileri beslemeli geri yayılım ağının bu istasyonun günlük eksik veri tahminlerinde kullanılabileceği sonucuna ulaşılmıştır.

E12A003 no'lu istasyonda 25 senelik veri seti kullanılmış ve modellerin eğitimi için tüm girdi verileri aynı istasyonun ötelenmiş akım verilerinden elde edilmiştir. Bu bağlamda modeller istasyon verilerine tam bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,97 R^2 ve 0,94 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur ve ileri beslemeli geri yayılım ağının bu istasyonun günlük eksik veri tahminlerinde kullanılabileceği sonucuna ulaşılmıştır.

D12A171 no'lu istasyonda 10 senelik veri seti kullanılmış ve tahmin modelleri geliştirilmiştir. Modellerin eğitimi için tüm girdi verileri aynı istasyonun ötelenmiş verilerinden elde edilmiştir. Bu bağlamda modeller istasyon verilerine tam bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,87 R^2 ve 0,075 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur. Buradan alınan sonuçlar D12A033 ve E12A003 no'lu istasyonlara göre daha düşüktür. Bunun başlıca nedeni D12A171 no'lu istasyon verilerinin maksimum ve minimum akım gözlem değerleri arasında çok fazla farkın olmasıdır. Normalizasyon işlemi sırasında bu fark sebebiyle veri değerleri sayısal olarak çok küçülmüş ve veriler arasında ilişki kurulmada zorluklar yaşanmıştır. Bir diğer sebep de mevcut veri sayısının yüksek performans elde edilebilmesinde yetersiz kalmasıdır. Bu sebeple D12A171 no'lu istasyonda günlük veri tahmini için daha başarılı veri elde edebilmek için kullanılan veri setini artırmak gerektiği sonucuna ulaşılmıştır.

D12A049 no'lu istasyonda benzer şekilde 10 senelik veri seti kullanılmıştır. Modellerin eğitimi için tüm girdi verileri aynı istasyonun ötelenmiş verilerinden elde edilmiştir. Bu bağlamda modeller istasyon verilerine tam bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,85 R^2 ve 0,025 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur. Bu istasyonda yaşanan model performans sıkıntısı veri yetersizliği ve ölçülen akım değerlerinin çok küçük olmasıdır. Veri ölçümlerinin çok küçük olması 3 modelleme yönteminin de performansını olumsuz yönde etkilemiştir. Her 3 modelleme yönteminde yüksek debili istasyonlardan daha başarılı sonuçlar elde edilirken; düşük debi değerlerine sahip istasyonlardan alınan sonuçların daha başarısız olduğu sonucuna ulaşılmıştır.

D12A173 no'lu istasyonda 10 senelik veri seti kullanılmıştır. Modellerin eğitiminde bu istasyona ait bir gün önceki akım değeriyle D12A063 no'lu komşu istasyonun ötelenmiş verilerinden yararlanılmıştır. Bu bağlamda modeller mevcut istasyon verilerine kısmen bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,97 R^2 ve 1,54 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerini üretmiş yöntem olmuştur. D12A049 ve D12A171 no'lu istasyonlarda veri eksikliği sebebiyle yaşanan performans düşüklüğü bu istasyon için geçerli olmamıştır. Bunun başlıca sebebi mevcut istasyondan bağımsız başka bir istasyon verisinin kullanılmasıdır. Bununla birlikte D12A173 no'lu istasyona ait akım gözlem değerleri yüksek ve maksimum değer ile minimum değer arasındaki fark düşüktür. Bu sebeple model performanslarının olumlu yönde etkilendiği sonucuna ulaşılmıştır.

D12A054 no'lu istasyonda 10 senelik veri seti kullanılmıştır. Modellerin eğitiminde bu istasyona ait bir gün önceki akım değeriyle 17126 no'lu yağış gözlem istasyonunun ötelenmiş verilerinden yararlanılmıştır. Bu bağlamda modeller mevcut istasyon verilerine kısmen bağımlı olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; 0,92 R^2 ve 2,31 MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur. Modellerin D12A054 no'lu istasyon tahmin verileri oluşturmada D12A173 no'lu istasyona göre daha başarısız olmasının nedeni; yağış verilerinde yaşanan kayıpların ve akıma dönüşen miktarının çok daha farklı parametrelere bağlı olmasıdır. Bununla beraber yağışın akım akıma gecikmeli olarak etki etmesinden dolayı tam değişim anının kestirilememesi de tahmin modelleri oluşturmada bir başka problem olarak karşımıza çıkmaktadır. Fakat yine de yüksek model performansı elde

edilmiş ve ileri beslemeli geri yayılım sinir ağının yağış-akım modellemede başarılı sonuçlar verdiği görülmüştür.

D12A181 no'lu istasyonda 10 senelik veri seti kullanılmıştır. Modellerin eğitiminde bu istasyon değerlerinde hiç faydalanılmamış ve eğitim veri seti komşu E12A003 no'lu istasyondan temin edilmiştir. Bu bağlamda modeller mevcut istasyon verilerinden tamamen bağımsız olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; $0,84 R^2$ ve $4,26$ MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur. Sonuçlar diğer modellere göre başarılı sonuçlar vermese de; ölçüm değerleri yüksek oranda eksik istasyonların akım verilerinin tahmininde yakınlardaki istasyonların kullanılabileceği ve kısmen de olsa başarılı sonuçlar elde edilebileceği görülmüştür.

D12A152 no'lu istasyonda ölçümlerin eksik olması sebebiyle 8 senelik veri seti kullanılmıştır. Modellerin eğitiminde bu istasyon değerlerinde hiç faydalanılmamış ve eğitim veri seti komşu D12A093 no'lu istasyondan temin edilmiştir. Bu bağlamda modeller mevcut istasyon verilerinden tamamen bağımsız olarak geliştirilmiştir. Alınan sonuçlar incelendiğinde; $0,65 R^2$ ve $0,605$ MSE değerleriyle ileri beslemeli geri yayılım sinir ağı en başarılı tahmin verilerine üretmiş yöntem olmuştur. Model performanslarındaki düşüşün veri eksikliği yüzünden kaynaklandığı sonucuna ulaşılmıştır.

Alınan tüm sonuçlarda ileri beslemeli geri yayılım sinir ağı en iyi performansı sergilemiştir ve bu yöntemin eksik akım verilerinin tahmininde kullanılabilir bir yöntem olduğu görülmüştür. Gen ifade programlama ortalama bir başarı göstererek ileri beslemeli geri yayılım sinir ağına alternatif bir yöntem olarak değerlendirilmiştir. Çoklu doğrusal regresyon yönteminin ise tüm veri tahminlerinde başarısız olduğu fakat alınan sonuçlar incelendiğinde tam bağımlı verilerle hazırlanan modellerde yapay zeka yöntemlerine alternatif bir yöntem olarak kullanılabileceği sonucuna ulaşılmıştır.

KAYNAKLAR

- Ağalday, M. F., (2018). *Genetik algoritma ile merkezi sınavlarda tek ve çok boyutlu yakınlığa göre en iyi oturum planının oluşturulması* Yüksek Lisans Tezi, Fatih Sultan Mehmet Vakıf Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, İstanbul.
- Alp, M., (2003). *Akarsulardaki Askı Maddesi Miktarının Kara Kutu Modeliyle Belirlenmesi*, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Altınışik, U., (2015). *Doğu Karadeniz Havzası Akımlarının İncelenmesi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- Aydın, B. D. (2017). *Meteorolojik Değişkenlerin Elektrik Tüketimi Üzerindeki Etkisi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- Aydoğan, E., (2014). *Genetik Programlama Kullanılarak Mobil Zararlı Yazılımların Otomatik Olarak Üretilmesi*. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Azamathulla, H. M., Ghani, A. A., Leow, C. S., Chang, C. K., & Zakaria, N. A. (2011). Gene-expression programming for the development of a stage-discharge curve of the Pahang River. *Water resources management*, 25(11), 2901-2916.
- Balcı, H., Esener, İ. I. & Kurban, M. (2012). *Regresyon Analizi Kullanılarak Kısa Dönem Yük Tahmini*. Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu. Bursa.
- Baratti, R., Cannas, B., Fanni, A., Pintus, M., Sechi, G. M., & Toreno, N., (2003). River flow forecast for reservoir management through neural networks. *Neurocomputing*, 55(3-4), 421-437.
- Bayazıt, M., (1998). *Hidrolojik Modeller*, İstanbul Teknik Üniversitesi İnşaat Fakültesi Matbaası, İstanbul, 228.
- Bayazıt, M., (2013). *Hidroloji*, Birsen Yayınevi, İstanbul, 219.
- Bayazıt M., Oğuz B., (1994). *Mühendisler İçin İstatistik*, Birsen Yayınevi, İstanbul, 197.
- Bayır, F., (2006). *Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama*. Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Beşiktaş, M., (2010). *Doğu karadeniz 'de debi süreklilik eğrilerinin regresyon analizi ile belirlenmesi ve akım tahmini*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Biethahn, J., and Nissen, V., (1995). An introduction to evolutionary algorithms, in *Evolutionary Algorithms in Management Applications*. Springer, 3-39.

KAYNAKLAR (Devam Ediyor)

- Bolat, S., (2003). *Yapay Sinir Ağı ile Elektrot Ve İzolatör Biçim Optimizasyonu*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Buyukkaracigan, N., & Kahya, E. (1997). *The Dependency Analysis of Annual Peak Flows of Streams in Konya Basin*. In International Conference on Water Problems in the Mediterranean Countries. Ankara.
- Büyükyıldız, M., (2004). *Sakarya havzası yağışlarının trend analizi ve stokastik modellemesi*. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Can, M., (2012). *Yapay sinir ağları ile akım tahmini: Mahmudiye göleti örneği*. Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Canan, S., (2006). *Yapay sinir ağları ile GPS destekli navigasyon sistemi*. Doktora Tezi, T.C. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Candan, G., (2010). *Esnek Üretim Çizelgeleme Probleminin Genetik Algoritma ve Bulanık Mantık Yöntemleri İle Çözülmesi*. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Cebe, E. N. (2007). *Türkiye Akarsularında Mevsimsel Trend Analizi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Civalek, Ö., & Çatal, H. H., (2004). GERİYE YAYILMA YAPAY SİNİR AĞI KULLANILARAK ELASTİK KİRİŞLERİN STATİK VE DİNAMİK ANALİZİ. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 6(1), 1-16.
- Coley, D. A. (1999). *An introduction to genetic algorithms for scientists and engineers*. World Scientific Publishing Company, London, 244.
- Cosun, F., & Karabulut, M. (2009). Kahramanmaraş'ta ortalama, minimum ve maksimum sıcaklıkların trend analizi. *Türk Coğrafya Dergisi*, (53), 41-50.
- Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). *Applied hydrology*. McGraw-Hill, California, 522.
- Cüceloğlu, G., (2013). *Darlık Havzasının Model Destekli Hidrolojik Analizi*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Çeribaşı, G., & Doğan, E., (2015). TREND ANALİZİ YÖNTEMİ KULLANILARAK BATI VE DOĞU KARADENİZ İLE SAKARYA HAVZASI AKIM MİKTARLARININ DEĞERLENDİRİLMESİ. *Uluslararası Teknolojik Bilimler Dergisi*, 7(2), 1-12.
- Çoban, E., (2013). *İklim değişikliğinin Türkiye genelindeki yağış eğilimlerine etkisinin araştırılması*, Yüksek Lisans Tezi, T.C. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.

KAYNAKLAR (Devam Ediyor)

- Çolak, O., (2006). *CNC freze tezgahı için kesme parametrelerinin akıllı yöntemlerle elektronik ortamda optimizasyonu*, Doktora Tezi, T.C. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- Dawson, C. W., Harpham, C., Wilby, R. L., & Chen, Y. (2002). Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China. *Hydrology and Earth System Sciences Discussions*, 6(4), 619-626.
- Devlet Su İşleri 3. Bölge Müdürlüğü (2017). *Porsuk Alt Havzası Master Plan Nihai Raporu*, DSİ, Eskişehir.
- Dipankar, D. and Zbigniew, M., (1997). *Evolutionary Algorithms In Engineering Applications*. Springer, Germany
- Doğan, G. (2010). Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Efe Ö. ve Kaynak, O., (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul Boğaziçi Üniversitesi Yayınları, İstanbul.
- Engelbrecht, A.P., (2007). *Computational Intelligence: An Introduction*. John Wiley & Sons, New York, 628.
- Elmas, Ç., (2003). *Yapay Sinir Ağları*, Seçkin Yayınevi, Ankara, 192.
- Elmas, Ç., (2011). *Yapay Zeka Uygulamaları*, Seçkin Yayıncılık, Ankara, 479.
- Ergin, Z., (2012). *Temel Bileşenler Faktör Analizine Dayalı Yapay Sinir Ağları Modelleri ile İMBK 100 Endeks Getirilerinin Tahmini*. Yüksek Lisans Tezi, Türkiye Cumhuriyeti Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü, Adana (2012).
- Es, H., (2013). *Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini*. Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Ferreira, C. (2001). Gene expression programming: a new adaptive algorithm for solving problems. *Advances in Complex Systems*, 13(2), 87-129.
- Ferreira, C. (2002a). Genetic representation and genetic neutrality in gene expression programming. *Advances in Complex Systems*, 5(04), 389-408.
- Ferreira, C. (2002b). Analyzing the Founder Effect in Simulated Evolutionary Processes Using Gene Expression Programming. Netherlands *IOS Press*, 153-162.
- Ferreira, C. (2006). Gene expression programming: mathematical modeling by an artificial intelligence. *Springer-Verlag*, Berlin, 29-54.
- Genel, H. (2004). *Genetik algoritmalarla portföy optimizasyonu*. Yüksek Lisans Tezi, Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.

KAYNAKLAR (Devam Ediyor)

- Gençer, M., Özcan, H., Uğurlu, A., Kesim, A., Kacar, M. ve Aydın, B., (2005). *Hidrometeoroloji*. <https://www.mgm.gov.tr/genel/kutuphane.aspx>.
- Girginer, N., & Yenilmez, F. (2005). *Türkiyede Enflasyonun Ekonometrik Olarak İncelenmesi*. Yüksek Lisans Tezi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- Grefenstette, J. J., (1986). Optimization of control parameters for genetic algorithms. *IEEE Transactions on systems, man, and cybernetics*, 16(1), 122-128.
- Grefenstette, J.J., (1992). Optimization of control parameters for genetic algorithms, in Genetic Algorithms. *IEEE Computer Society Pres*, California 5-11.
- Güçlü, A., (2004). *Yüksek Gerilim Tekniğinde Genetik Algoritma Uygulamaları*. Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Gülerce, M. (2007). *Eğitim ve sağlık yapılarında regresyon analizi ile maliyet modellemesi*. Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Gümüş, V., Soydan, N. G., Simsek, O., Aköz, M. S., & Kırkgöz, M. S., (2013). Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 28(1), 37-50.
- Gümüş, V. ve Yenigün, K., (2006). Aşağı Fırat Havzası akımlarının trend analizi ile değerlendirilmesi. *Yedinci Uluslararası İnşaat Mühendisliğinde Gelişmeler Kongresi*, 11 Ekim, Şanlıurfa.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Macmillan College Publishing Comp. Inc., New York, 768.
- http://jeoloji.kocaeli.edu.tr/dosyalar/dersNotlari/hidrojeoloji_ders%20notlari_prof_dr_irfan_yolcubal.pdf (Ziyaret Edilme Tarihi: 18.04.2019).
- <http://www.oyder-tr.org/Content/document/duyuru/22-mart-dunya-su-gunu.pdf> (Ziyaret Edilme Tarihi: 18.04.2019).
- Holland, J. H., (1975). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*, University of Michigan Press, Michigan, 211.
- İcan, Ö., (2013). *Finansal Zaman Serilerinin Fonksiyonel Yapısının Genetik Öğrenmeyle Belirlenmesi*. Doktora Tezi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.

KAYNAKLAR (Devam Ediyor)

- İmir, E. (1986). *Çoklu bağıntılı doğrusal modellerde Ridge regresyon yöntemiyle parametre kestirimi: Türkiye'de (1963-1983) enflasyon analizi*. Yüksek Lisans Tezi, Anadolu Üniversitesi, Fen-Edebiyat Fakültesi, Eskişehir.
- Jain, S. K., & Kumar, V. (2012). Trend analysis of rainfall and temperature data for India. *Current Science (Bangalore)*, 102(1), 37-49.
- Karakus, C. B., (2017). Trend Analysis Methods for Hydro-Meteorological Parameters. *International Journal of Scientific and Technological Research*, 3(2), 22-32.
- Kayıkçı, E. T. ve Beşel, C., (2017). IGS İstasyonlarından Elde Edilen Zenit Troposferik Gecikme (ZTD) Parametresi Zaman Serilerinde Trend Analizi, 16. *Harita Bilimsel ve Teknik Kurultayı*, 3-6 Mayıs, Trabzon.
- Keskenler, M. F. ve Keskenler, E. F., (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Kızılaslan, M., Sağın, F., Doğan, E., & Sönmez, O., (2014). Aşağı Sakarya Nehri akımlarının yapay sinir ağları ile tahmin edilmesi. *Sakarya University Journal of Science*, 18(2), 99-103.
- Kırbaş, İ. (2018). İstatistiksel metotlar ve yapay sinir ağları kullanarak kısa dönem çok adımlı rüzgâr hızı tahmini. *Sakarya University Journal of Science*, 22(1), 24-38.
- Koza, J. R., & Koza, J. R. (1992). *Genetic programming: on the programming of computers by means of natural selection*. MIT press, Cambridge, 819.
- Kriesel, D., (2009). *A Brief Introduction to Neural Networks*. http://www.dkriesel.com/en/science/neural_networks.
- Kurt, M. ve Semetay, C., (2004). *Genetik Algoritma ve Uygulama Alanları*. http://www.mmo.org.tr/muhendismakina/arsiv/2001/ekim/Genetik_Algoritma.htm
- Levent, V. E., & Diri, B., (2014). Türkçe Dokümanlarda Yapay Sinir Ağları İle Yazar Tanıma. *Akademik Bilişim*, 14, 5-7.
- Kaynar, L., (2005). *Doğu Karadeniz Bölgesi yıllık maksimum akımlarının istatistik metodlarla analizi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü. İstanbul.
- Lutton, E., Foster, J. A., Miller, J. F., Ryan, C. and Tezzamanzi, A. G. B., (2002). Discovery of The Boolean Functions To The Best Density-Classification Rules Using Gene Expression Programming. *Lecture Notes in Computer Science*, 2278, 51-60.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.

KAYNAKLAR (Devam Ediyor)

- Michell, M., (1998). *An Introduction to Genetic Algorithm*. <http://books.google.com.tr/books?id=0eznlz0TF-IC>.
- Mohamoud, Y. M., (2008). Prediction of daily flow duration curves and streamflow for ungauged catchments using regional flow duration curves. *Hydrological Sciences Journal*, 53(4), 706-724.
- Okkan, U., & Mollamahmutoğlu, A., (2010). YİĞİTLER ÇAYI GÜNLÜK AKIMLARININ YAPAY SİNİR AĞLARI VE REGRESYON ANALİZİ İLE MODELLENMESİ. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23, 33-48.
- Öğücü, M. O., (2006). *Yapay sinir ağları ile sistem tanıma*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Özlü, H., (2006). Su Kullanımı ve Yönetiminde Katılımcı Yaklaşım. *Tmmob Su Politikaları Kongresi*, Ankara.
- Önal, S., (2009). *Yapay sinir ağları metodu ile Kızılırmak Nehri'nin akım tahmini*. Yüksek Lisans Tezi, T.C Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü. Isparta.
- Özcan, O., (2007). *Sakarya Nehri Alt Havzası'nın Taşkın Riski Analizinin Uzaktan Algılama ve CBS ile Belirlenmesi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, İstanbul.
- Özçalıcı, M., (2015). *Hisse Senedi Fiyat Tahminlerinde Bilgi İşlemsel Zeka Yöntemleri: Uzman Bir Sistem Aracılığıyla BIST Uygulaması*. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Sosyal Bilimler Enstitüsü, Kahramanmaraş.
- Özçınar, H., (2006). *KPSS sonuçlarının veri madenciliği yöntemleriyle tahmin edilmesi*. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Özel, O., (2011). *Hurma (Antalya) Atıksu Arıtma Tesisi Performansının Modellenmesi*. Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Özfidaner, M., Şapolyo, D., Topaloğlu, F. ve Baydar, A., (2017). Adana İlinde Buharlaştırma Serilerinde Gidişlerin Yeni Bir Gidiş Analiz Yöntemi ile Belirlenmesi. *Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi*, 34, 59-66
- Özsoy. S., (2009). *Su ve yaşam: Suyun toplumsal önemi*. Yüksek Lisans Tezi, T.C. Ankara Üniversitesi, Sosyal Bilimleri Enstitüsü, Ankara.
- Öztemel, E., (2006). *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul, 232.
- Pamukçu, E., (2010). *Sistolik Kan Basıncını Etkileyebilecek Faktörlerin Ridge Regresyon Analizi ile İncelenmesi ve Çoklu Doğrusal Bağlantı Problemi*. Yüksek Lisans Tezi, T.C. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.

KAYNAKLAR (Devam Ediyor)

- Parker, D. B., (1987). Optimal algorithms for adaptive networks: Second order backpropagation, second order direct backpropagation, and second order hebbing learning. In *IEEE International Joint Conference on Neural Networks*, San Diego, 953-960.
- Pitts, W., And McCulloch, W. S., (1947). How we know universals the perception of auditory and visual forms. *Bulletin of Mathematical Biology*, 9(3), 127–147.
- Rojas, R., (1996). *Neural networks-a systematic introduction*. Springer-Verlag, New York, 502.
- Sakawa, M., & Kato, K. (2002). An interactive fuzzy satisficing method for general multiobjective 0–1 programming problems through genetic algorithms with double strings based on a reference solution. *Fuzzy Sets and Systems*, 125(3), 289-300.
- Sancakdar, T., (2002). *Ysa Destekli Kalman Filtresi İle Hedef İzleme*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Saraç, E. (2012). *Yapay sinir ağları metodu ile gayrimenkul değerlendirme*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Sarı, M., (2016). *Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini*. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Shamseldin, A. Y., (1997). Application of a neural network technique to rainfall-runoff modelling. *Journal of hydrology*, 199(3-4), 272-294.
- Shiri, J., Marti, P., & Singh, V. P. (2014). Evaluation of gene expression programming approaches for estimating daily evaporation through spatial and temporal data scanning. *Hydrological Processes*, 28(3), 1215-1225.
- Singh, V. P., & Fiorentino, M. (1996). *Hydrologic modeling with GIS*. In *Geographical Information Systems in Hydrology*, Springer, 1-13.
- Sudheer, K. P., & Jain, S. K. (2003). Radial basis function neural network for modeling rating curves. *Journal of Hydrologic Engineering*, 8(3), 161-164.
- Şahin, Ş. Ö., (2002). *Yapay sinir ağları yardımı ile dinamik bir senaryo analizi*. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Şentürk, K., (2011). *Akım Gözlem İstasyonu Olmayan Havzalarda Su Potansiyelinin Belirlenmesi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü. İstanbul.
- Taşkın, Ç., & Emel, G. G., (2009). *Sayısal yöntemlerde genetik algoritmalar*. Alfa Aktüel, Bursa, 153.
- Terzi, Ö., (2013). Daily pan evaporation estimation using gene expression programming and adaptive neural-based fuzzy inference system. *Neural Computing and Applications*, 23(3-4), 1035-1044.

KAYNAKLAR (Devam Ediyor)

- Terzi, Ö. ve Barak, M., (2015). Dalgacık-Sinir Ağı Yaklaşımı ile Yağış-Akış Tahmini: Kızılırmak Nehri Örneği. *Journal of Agricultural Sciences*, 21(4), 546-557.
- Terzi, Ö., Özcanoglu, O., (2017). GEN İFADE PROGRAMLAMA İLE GÖKSU NEHRİ'NİN AKIM TAHMİNİ. *Journal of Engineering Sciences*, 5(3), 483-488.
- Tokar, A. S., & Johnson, P. A., (1999). Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4(3), 232-239.
- Tomassini, M. (1996). Evolutionary algorithms. In *Towards Evolvable Hardware*. Springer, Heidelberg, 19-47.
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: öğrenci başarıları üzerine bir uygulama*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Traore, S., & Guven, A. (2013). New algebraic formulations of evapotranspiration extracted from gene-expression programming in the tropical seasonally dry regions of West Africa. *Irrigation science*, 31(1), 1-10.
- Turfan, D. (2014). *Tabakalı Rastgele Örneklemde Örneklem Büyüklüklerinin Genetik Algoritma ile Belirlenmesi*. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Tuğ, E. (2005). *Genetik algoritmalar ile tıbbi veri madenciliği*. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Turhan, E., & Çağatay, H. Ö., (2016). Eksik Akım Verilerinin Tahmin Modelinin Oluşturulmasında Yapay Sinir Ağlarının Kullanımı: Asi Nehri-Demirköprü Akım Gözlem İstasyonu Örneği. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 31(1), 93-106.
- Ulusoy, K., (2007). *Küresel Ticaretin Son Hedefi: Su Pazarı*, Kristal Kitaplar Yayınevi, Ankara, 320.
- Uğurluoğlu, A., (2017). *Su Havzalarında Hidrolojik Modelleme: Manyas Gölü Yukarı Havzası Uygulaması*. Uzmanlık Tezi, T.C. Orman ve Su İşleri Bakanlığı Genel Müdürlüğü, Ankara.
- Uslu, H. ve İçağa, Y., (2010). Yapay Sinir Ağları İle Akarçay Akımının Modellenmesi. *Yapı Teknolojileri Elektronik Dergisi*, 6(2), 31-41.
- Uslu, N., (2013). *Mühendislik Hidrolojisi*. ODTÜ Yayıncılık, Ankara, 418.
- Ülke, A. ve Özkoca, T., (2018). Sinop, Ordu ve Samsun İllerinin Sıcaklık Verilerinde Trend Analizi. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(2), 455-463.
- Vural, M., (2005). *Genetik Algoritma Yöntemi ile Toplu Üretim Planlama*. Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

KAYNAKLAR (Devam Ediyor)

- Wheater, H., Sorooshian, S., and Sharma, K., (2007). *Hydrological Modelling in Arid and Semi-Arid Areas*. Cambridge University Press, Cambridge, 1-20.
- Xu, Y., (2003). *Using Data Mining In Educational Research: A Comparison of Bayesian Network With Multiple Regression in Prediction*. Doctoral Thesis, Department of Educational Psychology, The University of Arizona, Arizona.
- Yalçın, N., (2012). *Sezgisel Algoritma Öğrenmeli Yapay Sinir Ağları ile Epilepsi Hastalığının Teşhisi*. Yüksek Lisans Tezi, T.C. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Yaşar, M., (2004). *Günlük Akışlardaki Boşlukların Yapay Sinir Ağları Kullanılarak Tamamlanması*. Yüksek Lisans Tezi, T.C. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Yavuz, S., (2009). Regresyon Analizinde Doğrusala Dönüştürme Yöntemleri ve Bir Uygulama. *İktisadi İdari Bilimler Dergisi*, 23(1): 165-179.
- Yazıcı, Ü., (2010). *Yapay Sinir Ağları İle Banka Müşterisi Bekleme Süresi Tahmini*. Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.
- Yetkin, M., (2014). *Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Yılmaz, B., (2015). *Akarçay Havzasında Çözünmüş Oksijen Değerlerinin Yapay Sinir Ağları İle Belirlenmesi*”, Uzmanlık Tezi, T.C. Orman ve Su İşleri Bakanlığı, Ankara.
- Yılmaz, D., (2012). *Taşkın Yapıları Tasarımı ve Kayı Deresi Örneği*. Yüksek Lisans Tezi, T.C. Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Tekirdağ.
- Yue, S., Zou, S., ve Whittemore, D., (1993). Nonparametric Trend Analysis of Water Quality Data of Rivers in Kansas, *Journal of Hydrology*, 150(1), 61-80.
- Yurdusev, M. A., Acı, M., Turan M. E., İçağa, Y., (2008). Akarçay Nehri Akımlarının Yapay Sinir Ağları ile Tahmini. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi*, 4(1): 73-88.
- Yurtoğlu, H., (2005). *Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*. Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara.

ÖZ GEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Ali YILDIRAN
Doğum Yeri ve Tarihi : 24.09.1994 / ZONGULDAK



Eğitim Durumu

Lisans Öğrenimi : Bilecik Şeyh Edebali Üniversitesi İnşaat Mühendisliği
Bildiği Yabancı Diller : İngilizce

İş Deneyimi

Stajlar : BADEL İnşaat 30 gün yapı stajı
: Eskişehir Su ve Kanalizasyon İdaresi 30 gün hidrolik stajı
Çalıştığı Kurumlar : LİA Mimarlık Şantiye Şefliği

İletişim

Adres : Sümer Mahallesi Bahriyeli Sokak no:2/4 ESKİŞEHİR
ODUNPAZARI

E-Posta Adresi : yildirannali@gmail.com

Akademik Çalışmaları

- Porsuk Çayı Akım Verilerinin Değerlendirilmesi / Makale
- Yağış Miktarının Yapay Sinir Ağları ile Tahmini /Makale

Tarih:05/08/2019