

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FIRAT-DİCLE HAVZASINDA GÜNLÜK NEHİR
AKIMLARININ FAKLI YAPAY ZEKÂ YÖNTEMLERİ
İLE TAHMİNİ

YÜKSEK LİSANS TEZİ
Ali GÜNDÜZ

Anabilim Dalı: İnşaat Mühendisliği
Programı: Hidrolik

Danışman: Doç. Dr. M. Emin EMİROĞLU

ŞUBAT-2011

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FIRAT-DİCLE HAVZASINDA GÜNLÜK NEHİR AKIMLARININ
FAKLI YAPAY ZEKÂ YÖNTEMLERİ İLE TAHMİNİ

YÜKSEK LİSANS TEZİ
Ali GÜNDÜZ
(08115103)

Tezin Enstitüye Verildiği Tarih: 24 Ocak 2011

Tezin Savunulduğu Tarih: 10 Şubat 2011

Tez Danışman	:	Doç. Dr. M. Emin EMİROĞLU
Diğer Jüri Üyeleri	:	Doç. Dr. M. Emin EMİROĞLU
	:	Doç. Dr. Haydar EREN
	:	Doç. Dr. Ragıp İNCE

ŞUBAT-2011

ÖNSÖZ

Son yıllarda teknolojik alanda ilerlemelerle birlikte bilimde yaşanan teknolojik gelişmeler de, neredeyse takip edilemeyecek bir hızda ilerlemektedir. Bu ilerleme, insanoğlunun yaratıcılığını kullanmasıyla sınır tanımaz bir duruma gelmiş, daha evvel hiç hayal bile edilemeyen yeni gelişmelerin doğmasına vesile olmuştur. Bu gelişmelerden bir tanesi de Yapay Zeka'dır. Bilim adamları, adına Yapay Zekâ dedikleri, insan beyninin bile nasıl yaptığını çözemedikleri düşünebilme, anlayabilme, öğrenebilme ve yorumlayabilme yeteneklerini, programlama dillerini kullanarak problem çözümlerinde kullanmaktadırlar. Yapay Sinir Ağları (YSA)'da, Yapay Zekâ metotları altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır. YSA'ların örnekler ile öğrenebilme ve genelleme yapabilme özellikleri onlara çok esnek ve güçlü araçlar olma özelliği sağlamaktadır.

Bu çalışmada da YSA teorik olarak anlatılmış ve günlük hayatta kullanılan değişik YSA uygulamalarından kısaca bahsedilmiştir.

Tez çalışmamın seçiminde, yürütülmesinde, sonuçlandırılmasında ve sonuçların değerlendirilmesinde maddi ve manevi desteklerini esirgemeyen değerli hocam sayın Doç. Dr. Muhammet Emin EMİROĞLU'na;

Tez çalışmamın başlangıcından itibaren; yürütülmesinde, sonuçlandırılmasında ve sonuçların değerlendirilmesinde özel zaman ayırarak, desteklerini esirgemeyen değerli hocam sayın Doç. Dr. Özgür KİŞİ'ye;

Yükseklisans eğitimim süresince bana emeği geçen Fırat Üniversitesi İnşaat Mühendisliği bölümünde görev yapan değerli hocalarıma;

Eğitim hayatım boyunca hep yanımda olup desteğini hiçbir zaman esirgemeyen değerli eşim Cennet GÜNDÜZ'e ve Şirinlikleri ile bana huzur veren sevgili kızlarım Safiye GÜNDÜZ ve Şeyma GÜNDÜZ'e teşekkür etmeyi bir borç bilirim.

Ali GÜNDÜZ
ELAZIĞ-2011

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	II
İÇİNDEKİLER	III
ÖZET	IV
SUMMARY	V
ŞEKİLLERİN LİSTESİ	VI
TABLolar LİSTESİ	VIII
KISALTMALAR LİSTESİ	X
SEMBOLLER LİSTESİ	XI
1. GİRİŞ	1
1.1. Yapılan Çalışmalar	2
1.2. Nehir akımları ve Özellikleri.....	5
1.2.1. Akarsu Gözlem İstasyonları	6
1.2.1.1. Akarsu Gözlem İstasyonlarında Seviye ölçümleri	7
1.2.1.2. Akarsu Gözlem İstasyonlarında Akım Ölçümleri	8
2. METARYAL VE METOT	10
2.1. Yapay Sinir Ağları (YSA).....	10
2.1.1. YSA'nın Tanımı ve Özellikleri.....	11
2.1.2. YSA'nın Yapısı.....	13
2.1.3. YSA'nın Çeşitleri.....	17
2.2. Çalışmada Kullanılan YSA Metodları	18
2.2.1. Çok Katmanlı Geri Yayılmalı Yapay Sinir Ağları (ÇKYSA).....	18
2.2.2. Radyal Tabanlı Yapay Sinir Ağları (RTYSA)	20
2.3. Dalgacık Dönüşümü (DD).....	21
2.3.1. Dalgacık Nedir? Sürekli Dalgacık Dönüşümü(SDD)	22
2.3.2. Ayrık Dalgacık Dönüşümü (ADD)	24
2.4. Çoklu Doğrusal Regresyon (ÇDR).....	25
2.5. Modelleme	25
2.5.1. Modellerin Güvenilirlikleri	25
2.5.2. Ortalama Karesel Hatanın Karekökü (OKHK)	26
2.5.3. Ortalama Mutlak Göreceli Hata (OMGH)	26
3. BULGULAR	27
3.1. Çalışmada Kullanılan Veriler	27
3.2. Çalışmanın Yapılış Şekli	30
3.3. Elde Edilen Bulgular ve Grafikler	33
3.4. Genel Değerlendirme	62
4. SONUÇLAR VE ÖNERİLER	63
KAYNAKLAR	64
ÖZGEÇMİŞ	69

ÖZET

Hidrolojik süreçte nehir akımlarının modellenmesi ve akış tahmini; su kaynaklarının etkili planlanması, yönetimi ve sürdürülebilir kullanımı açısından oldukça önemlidir. Bir nehir sistemindeki herhangi bir kesitteki akım; akımın yer ve zamana bağlı olarak değişimi, nehrin fiziksel karakteristikleri ve nehrin havzası gibi birçok değişkenin fonksiyonudur. Yapay sinir ağları (YSA) son zamanlarda hidroloji biliminde başarılı bir şekilde kullanılmaktadır. Son yıllardaki çalışmalarda; su kaynakları ve hidroloji (örneğin akım tahmini, yağış-akış modellemesi, gelen akım, rezervuar işletimi, doğal kanallarda dispersiyon ve suspanse sediment tahmini), alanındaki YSA uygulamalarından umut verici sonuçlar elde edilmiştir.

Bu çalışmanın asıl amacı, Fırat-Dicle havzasındaki nehir akım tahmini yapmak için yapay sinir ağları ve dalgacık dönüşüm modelleri geliştirmektir. Bu çalışmada modelleme için 1968-2006 zaman periyodundaki günlük akım verileri kullanılmıştır. Yapay sinir ağları ve dalgacık dönüşüm modelleri ile elde edilen bulgular, çoklu doğrusal regresyon modelleri ile karşılaştırılmıştır. Modellerden elde edilen sonuçların uygunluğunu test etmek için; karekök ortalama karesel hata (KOKH), ortalama mutlak hata (OMH) ve belirginlik katsayısı (R^2) istatistiklerine göre sonuçlar irdelenmiştir. Karşılaştırma sonuçları, yapay zekâ tekniklerinin nehir akımı tahmininde başarılı bir şekilde kullanılabileceğini göstermiştir.

Anahtar Kelimeler:Dalgacık Dönüşümü, Yapay Sinir Ağı, Radyal Tabanlı Yapay Sinir Ağı, Nehir Akım Tahmini, Akarsu Gözlem İstasyonu

SUMMARY

Prediction of Daily River Flows in Firat-Dicle Basin Using Different Artificial Intelligence Methods

The forecasting and modeling of river flow in hydrological processes is quite important to deliver the sustainable use and effective planning and management of the water resources. The river flow process in any cross section of river system can be characterized as the function of various variables such as, spatial and temporal distribution of rainfall, catchment and river physical characteristics. In order to estimate hydrological processes such as runoff and change of water level using existing methods, parameters such as the physical properties of the catchment and river network and detailed observation data are necessary. The artificial neural network (ANN) has been successfully used in the hydrological sciences during recent years. The recent studies indicated that the ANN offers a promising results in the field of water resources and hydrology, such as streamflow estimation, rainfall–runoff modeling; reservoir inflow forecasting; reservoir operation; longitudinal dispersion in the natural channels; and suspended sediment estimation.

The main aim of this study is to develop a suitable ANN and Wavelet Transform models for river flow forecasting in the Firat-Dicle Catchment, Turkey. In this study, daily river flow at the time period 1968-2006 was used for modeling. The performance of the ANN and Wavelet Transform models were compared with multi-linear regression models. Root mean square errors (RMSE), mean absolute errors (MAE) and deterministic coefficient (R^2) statistics were used for the evaluation of the models' performances. Comparison results indicated that the neural computing techniques could be employed successfully in modeling river forecasting.

Key Words: Wavelet Transform, Artificial Neural Networks, Radial Basis Neural Networks, River Flow Forecasting

ŞEKİLLERİN LİSTESİ

Sayfa No

Şekil 1.1	Anahtar eğrisi (H-Q)	7
Şekil 1.2	Akarsu enkesiti	8
Şekil 2.1	Sinir hücrelerinin bağlantılarının basitleştirilmiş şematik yapısı	12
Şekil 2.2	Sinir sisteminin blok diyagramı	14
Şekil 2.3	Yapay sinir hücresi modeli	15
Şekil 2.4	İleri beslemeli ve geri beslemeli ağ yapıları	18
Şekil 2.5	Üç tabakalı yapay sinir ağı	19
Şekil 2.6	Morlet dalgacığı	23
Şekil 3.1	Fırat-Dicle havzasının lokasyonu	27
Şekil 3.2	Fırat Havzası (yukarı fırat bölümü)	28
Şekil 3.3	Fırat Havzası (orta fırat bölümü)	29
Şekil 3.4	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2119-2156)	36
Şekil 3.5	ÇDR, DDÇDR, ÇKYSA ve RTYSA m metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2119-2162)	38
Şekil 3.6	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2162-2156)	40
Şekil 3.7	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2151-2119)	42
Şekil 3.8	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2176-2119)	44
Şekil 3.9	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2164-2102)	47
Şekil 3.10	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2178-2164)	49
Şekil 3.11	ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları_(2158-2174)	51

Şekil 3.12 ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları _(2177-2174)	53
Şekil 3.13 ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları _(2181-2122)	55
Şekil 3.14 ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları _(2178-2102)	57
Şekil 3.15 ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları _(2124-2145)	59
Şekil 3.16 ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları _(2194-2115)	61

TABLoların LİSTESİ

Sayfa No

Tablo 3.1	Çalışmada kullanılan akarsu gözlem istasyonları hakkında genel bilgiler.....	30
Tablo 2.2	Giriş verilerine ait özel istatistik parametreler	31
Tablo 2.2	(Devam) Giriş verilerine ait özel istatistik parametreler	32
Tablo 3.3	Bağıstaş (2156) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	35
Tablo 3.4	Bağıstaş (2156) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	36
Tablo 3.5	Eriç (2156) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	37
Tablo 3.6	Eriç (2156) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	38
Tablo 3.7	Bağıstaş (2156) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	39
Tablo 3.8	Bağıstaş (2156) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	40
Tablo 3.9	Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri	41
Tablo 3.10	Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	42
Tablo 3.11	Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri	43
Tablo 3.12	Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	44
Tablo 3.13	Palu(2102) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	46
Tablo 3.14	Palu(2102) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	47
Tablo 3.15	Çayağzı (2164) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	48

Tablo 3.16	Çayağzı (2164) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	49
Tablo 3.17	Akkonak(2174) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	50
Tablo 3.18	Akkonak(2174) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	51
Tablo 3.19	Akkonak(2174) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	52
Tablo 3.20	Akkonak(2174) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	53
Tablo 3.21	Murat Nehri-Tutak(2122) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	54
Tablo 3.22	Murat Nehri-Tutak(2122) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri	55
Tablo 3.23	Palu(2102) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	56
Tablo 3.24	Palu(2102) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	57
Tablo 3.25	Hisarcık(2145) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	58
Tablo 3.26	Hisarcık(2145) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	59
Tablo 3.27	Malpınarı(2115) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri.....	60
Tablo 3.28	Malpınarı(2115) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri.....	61

KISALTMALAR LİSTESİ

AE	:Anahtar Eğrisi
AGİ	:Akarsu Gözlem İstasyonu
AAGİ	:Aylık Akarsu Gözlem İstasyonu
YAGİ	:Yıllık akarsu Gözlem İstasyonu
GGİ	:Göl Gözlem İstasyonu
KGİ	:Kar Gözlem İstasyonu
EİE	:Elektrik İşleri Etüt İdaresi
RTYSA	:Radyal Tabanlı Yapay Sinir Ağları
ÇKYSA	:Çok Katmanlı Yapay Sinir Ağları
DDÇDR	:Dalgacık Dönüşümü Çoklu Doğrusal Regresyon
SDD	:Sürekli Dalgacık Dönüşümüm
ADD	:Ayrık Dalgacık Dönüşümü
R²	:Benzerlik Katsayısı
OMH	:Ortalama Mutlak Hata
KOKH	:Karekök Ortalama Karesel Hata
WMO	:Dünya Meteoroloji Örgütü

SEMBOLLER LİSTESİ

ψ	Dalgacık fonksiyonu
ω	YSA da ağırlık katsayıları
a,b	YSA da eşik katsayısı
$f(.)$	YSA da giriş ile çıkış arasında yaklaşım kalitesini veren fonksiyon(Aktivasyon fonksiyonu).
Σ	Toplama fonksiyonu
χ	YSA'nın öğrenmesinde hedef çıkışlar
α	YSA da öğrenme oranı
w	Ağırlık
W_{ij}	Önceki tabaka ile sonraki tabaka arasındaki ağırlık
X_i	Giriş değerleri
x_i	Önceki tabakada i. Sinir hücresinin çıktısı
i	Girdi tabakası
k	Çıktı tabakası
j	Gizli tabaka
A_{ij}	Hücre tabakaları arasındaki bağlantı ağırlığı
Q_j	Tarafllılık sabiti
ζ_p	Çıktı hücresi
H_p	Toplam hata
N	İterasyon sayısı
G_{pk}	p için gerçek çıktı değeri
ζ_{pk}	p için tahmin edilen çıktı değeri
J	Jacobian matrisi
J^T	Jacobian matrisinin transpozesi

1.GİRİŞ

Canlıların hayatını devam ettirmesinde en önemli faktörlerin başında su gelmektedir. Dünyada yaklaşık olarak $1.4 \times 10^9 \text{ km}^3$ su bulunmakla beraber bu suyun %97.5'i okyanuslarda ve denizlerdeki tuzlu sudur. Dünyadaki insan yaşamı için kullanılabilir tatlı suyun oranı ise %2.5 ($35 \times 10^6 \text{ km}^3$) civarında olduğu belirlenmiştir. Tatlı sularında yaklaşık olarak %70'i kutuplardaki buzulları içermekte olup geriye kalan kısmı ise akiferlerdeki yer altı suyu ve yüzeysel akış şeklinde nehirlerden oluşmaktadır. Ülkemizdeki akarsularımızın uzun yıllar ortalama yüzeysel akım miktarı 180.5 milyar m^3 olarak tespit edilmiştir [1, 2].

Su, diğer doğal kaynaklardan farklı olarak yaşamın ana unsurunu oluşturduğundan ekonomik değeri yanında sosyal bir nitelik taşımaktadır. İleriki yüzyıllarında en önemli konularından birisinin su olacağı, buna bağlı olarak ekonomik açıdan da en değerli hale geleceği konusunda değişik görüşler ileriye sürülmektedir. Doğada canlıların yaşaması için suyu kullanmak ve kontrol altına almak gerektiğinden insanoğlu suyun özelliklerini tanımaya, hareketini belirten kanunları belirlemeye, olası oluşturacağı tehlikeleri sezinlemeye ve önlemeye dolayısı ile sudan en iyi şekilde yararlanmaya çalışmıştır. Su kaynaklarının planlanması ve yönetimi, gittikçe zorlaşan çevre şartları, artan nüfus yoğunluğu gibi faktörlerin etkisiyle artan su talebine paralel olarak önemini daha da arttırmıştır.

Gelecekteki belli bir tarihte görülecek akımın (debi, seviye, akış hacmi) tahmini; taşkın uyarılarının yapılması, taşkın kontrolü maksatlı haznelerin işletilmesi, akarsuyun su potansiyelinin belirlenmesi, kurak dönemlerde hidroelektrik üretiminin, şehir suyu ve sulama suyunun dağıtımı ve akarsularda ulaşımın planlanması açısından önem taşımakla beraber zaman serilerinin kullanımında önemli girdilerden birisidir. Uygulamalarda, bu serilerdeki süreklilik ve homojenlik farklı nedenlerle bozulmalara uğrayabilir. Eksik verilerin tamamlanmasında, serinin homojenliğinin test edilmesinde ve serilerin uzatılmasında genellikle değişkenler arasında doğrusal ilişki varsayımı ile basit ve çoklu regresyon teknikleri veya istatistik yöntemler kullanılmaktadır. Akış serilerinin stokastik karakteri nedeniyle seriye en uygun modelin veya dağılımın seçilmesi için serinin yapısı hakkında yeterli bilgi ve deneyime sahip olmak gerekir. Bu ise oldukça zaman alıcı farklı model ve dağılımların denenmesi ile mümkündür [2, 3].

Son derece karmaşık yapıya sahip günlük akış serilerinin geleneksel yöntemlerle tahmininde yanılma payı, serinin yapısına bağlı olarak bazı durumlarda kabul edilebilir sınırlarda olurken bazı serilerde yanılma payı oldukça büyük olabilmektedir. Özellikle, zaman serisindeki anlık değişimler, doğrusal modellerin yetersiz kalmasına sebep olmaktadır. Bu nedenle, pratikte karşılaşılan problemlerin çözümünde incelenen olayın doğasına uygun olan doğrusal olmayan modellerin kullanılması gerekmektedir [2].

Parametrik modeller özellikle kapalı kutu modellerin kullanılmadığı, havzanın özelliklerinin değiştirilmesinin etkilerini incelemek istenen durumlarda yararlı olur. Ancak bunun için de modelin parametrelerinin havza üzerinde değişimini hesaba katmak gerekebilir. Modelde havza sistemi ne kadar çok sayıda elemana ayrılırsa o ölçüde ayrıntılı bir model geliştirilmiş olur. Ancak böyle bir modelde kalibrasyon için gerekli veri miktarı artacaktır. Kullanılacak modelin ölçeği eldeki verilere bağlı olarak seçilmelidir. Pratikte çoğu zaman parametrelerin havza üzerinde sabit kaldığı kabul edilen toplu modeller kullanmak gerekir [3, 4].

Nehir akımlarının tahmini, eksik verilerin tamamlanması gibi birçok hidrolojik değişken üzerine başarılı uygulamaları olan yapay sinir ağları (YSA), modelin fiziksel yapısı ile ilgilenmeyen bir tür kapalı-kutu modelidir. Yapay sinir ağları tahmininde kullanıcının etkisi daha çok modelin girdileri üzerindedir. Girdi seçimi yapay sinir ağları modellerinin en önemli aşamasıdır. Verileri zaman ve frekans ortamında ayrıştırarak ayrıntılı bir sunumunu veren dalgacık dönüşümü bu yeteneği ile tahmin için önemli avantajlar sağlar. Dalgacık dönüşümünün hidrolojik ve meteorolojik sahalarda uygulanışı yenidir [5].

Literatürde nehir akımlarının tahmini, eksik verilerin tamamlanması üzerine YSA ile yapılmış pek çok çalışma bulunmaktadır. Bununla birlikte son yıllarda dalgacık dönüşüm tekniği ve yapay sinir ağlarının birlikte uygulanması ile ilgili bazı çalışmalarda görülmektedir. YSA ile yapılmış çalışmalarda genellikle gizli tabakalardaki nöronların, ileri/geri besleme durumlarının, transfer fonksiyonlarının veya girdi değişkenlerinin modele etkisi incelenmiştir. Konu ile ilgili yapılan çalışmaların bazıları verilmiştir..

1.1. Yapılan Çalışmalar

Alp ve Cıgızoglu [3], yapay sinir ağı metodları ve regresyon analizi ile akım tahminleri yapmışlardır. A.B.D. Jeolojik Araştırma Kurumu'nun internet sitesinde

yayınlanmış olduđu *Pennsylvania* eyaletindeki Juniata Nehri'ne ait günlük akım deęerleri kullanılmıştır. İleri beslemeli geriye yayılım metodunun genelleştirilmiş regresyon sinir ağı yöntemine göre daha iyi sonuç verdięi görölmüştür.

Karahan ve dię. [2], genetik algoritma (GA) ve YSA kullanarak günlük eksik akımların tahmini ile ilgili çalışma yapmışlar. GA ile eksik verilerin tamamlanması için doğrusal, üssel ve doğrusal olmayan beş ayrı matematik model kullanılmış ve bu modellerin katsayıları GA ile belirlenmiştir.

Kişi ve Öztürk [6], günlük nehir akımlarının tahmini ve eksik verilerin tamamlanması için bulanık mantık ve yapay sinir ağılarına dayalı modeller geliştirilmiş ve YSA modelinin en uygun ara tabaka hücre sayısının 3 olduđu tespit edilmiştir.

Yurdusev ve dię. [4], bir akarsudaki akımların, o akarsuyun havzasındaki yağış ve önceki akım gözlemlerinden tahmin edilmesinde YSA yöntemi kullanılarak bulunan sonuçlar regresyon analizi sonuçlarıyla kıyaslanmış ve YSA ile akım tahmininin daha iyi sonuç verdięi görölmüştür.

Cıgızoęlu ve Kişi [7], YSA ile akım tahmin performansının veri uzunluęuna baęlı olabileceğini göz önüne alarak, verinin YSA ile eğitim aşamasında k-bölüm parçalanması (*k-fold partitioning*) olarak adlandırılan istatistiksel bir metodu ele almışlardır. Metodun ileri beslemeli yayılma algoritmasında faydalı olacağını bulmuşlardır. Bu faydanın verinin tamamı yerine bir kısmının ele alınmasıyla ortaya çıktığını belirtmişlerdir. Levenberg-Marquardt, birleşmiş eğim (*conjugate gradient*) ve eğim azalması (*gradient descent*) gibi üç farklı geri yayılma algoritması arasında tahmin performansı ve yakınsama hızı kıyaslaması sonucunda Levenberg-Marquardt teknięinin üstün olduęunu ifade etmişlerdir.

Hsu ve dię. [8], çeşitli hidrolojik işlemlerin özelliklerini fiziksel denklemler kullanarak tanımlamanın güç olduđu problemlerde, YSA modellerinin faydalı ve etkili olduęunu belirtmişlerdir. Çalışmada, üç tabakalı ileri yayımlı YSA modellerin yapısının ve parametrelerinin belirlenmesi için en küçük kareler Simplex metodunu kullanmışlar ve havzaların lineer olmayan davranışını simüle etmek için böyle modellerin potansiyelini göstermişlerdir. Bir YSA modelinin orta ölçekteki bir havzanın yağış-akış baęıntısının lineer dış kaynak girdili otoregressif (ARMAX) model ile kavramsal SAC-SMA modelinden daha iyi olduęunu belirtmişler ve YSA modelinin dięer modellere göre alternatif olabileceğini ifade etmişlerdir.

Minns ve Hall [9], ileri beslemeli ve geriye yayılım metodu kullanarak sentetik olarak üretilmiş verilerden yağış-akış modellemesi yapmışlardır.

Kumar ve Foufoula [10], dalgacık dönüşümü ile ilgili ilk çalışmayı yağış verilerinin analizi ile ilgili olarak yapmışlardır. Yağış verileri çok çözünürlüklü analiz ile bileşenlerine ayrılmış ve ayrılan her bileşen analiz edilmiştir.

Kumar ve diğ. [11], sigmoid transfer fonksiyonlu çoklu tabaka nöron ağı (MLP) üzerindeki çalışmaların bazı sınırlamalara sahip olduğunu belirtmişler. Ayrıca, radyal tabanlı fonksiyonun (RBF) MLP'den daha üstün olduğu yolunda bir inanışın olduğunu belirtmiştir. Bu nedenlerle, çalışmada MLP ve RBF'ye dayalı YSA modellerinin performansı Hindistan'daki iki nehir arasında değerlendirilmiştir. Ağ tipi seçiminin model tahmin doğruluğunda önemli bir etkiye sahip olduğu belirlenmiş, MLP'nin optimum gizli noktalarının sayısını sabitlemek için uzun bir deneme-yanılma yönteminin gerektirdiğini, RBF'nin ise ağ yapısının uygun eğitim algoritması kullanılarak sabitlendiğini ifade etmişlerdir. Sonuç olarak bunlar arasında bir üstünlüğün belirlenmesinin zor olduğu vurgulanmıştır.

Wang ve Ding [12], hidrolojide YSA ve dalgacık tekniğinin birlikte kullanılması ile ilgili ilk çalışmalardan birinde YSA ve dalgacık analizinin kombinasyonundan oluşan bir modeli günlük akım tahmini ve yer altı suyu seviyesinin tahmini olmak üzere iki ayrı uygulama ile denemişlerdir.

Partal ve diğ. [5], yağış tahmininde yapay sinir ağları ve dalgacık dönüşümü modellerini birlikte kullanmışlar ve dalgacık dönüşümünün kullanılmasıyla yapılan tahminlerin oldukça başarılı olduğu gözlenmiş bu yöntemle maksimum yağışlarda daha başarılı sonuçların elde edildiğini belirtmişlerdir.

Bu çalışmada, membadaki akım gözlem istasyonunun ortalama günlük akımlarını kullanarak mansaptaki bir akım gözlem istasyonunun günlük akımlarının tahmin edilmesi ele alınmıştır. Son yıllarda benzer tahmin çalışmalarında sıkça kullanılan yapay sinir ağları ve dalgacık dönüşümü seçilmiştir. Modellerle ilgili teorik altyapı verildikten sonra seçilen Fırat-Dicle havzası içerisinde bulunan Fırat Nehri ve kollarından Murat kolu ile Tohma kolu üzerinde yapılan uygulama verilmiştir. Fırat havzasında mevcut bulunan Akım Gözlem İstasyonlarının (AGİ) günlük ortalama akım değerlerini içeren girdi kombinezonları denenerek, çalışma kapsamında MATLAB programında; çoklu doğrusal regresyon (ÇDR), çok katmanlı yapay sinir ağları (ÇKYSA), radyal tabanlı yapay sinir ağları (RTYSA) ve Dalgacık dönüşümü çoklu doğrusal regresyona (DDÇDR) dayalı modeller geliştirilmiş elde edilen sonuçlar karesel, mutlak hata ve belirginlik katsayısı istatistiklerine göre incelenmiştir.

1.2. Nehir Akımları ve Özellikleri

Bu bölümde çalışmamızın ana konusu olan nehir akımlarının tahmin edilmesi için değişik modeller uygulanmasına geçmeden önce Ülkemizdeki akarsuların kısaca genel özellikleri ve hidrolojik çalışmaların başında gelen nehir akımı ölçümlerinin yapılış şekilleri ve EİE'deki uygulaması hakkında bilgi içermektedir.

Türkiye, iklim koşulları ve yer şekillerinin çeşitliliğine bağlı olarak sık bir akarsu ağına sahiptir. Bunların büyük bir kısmı dağlardan, bazıları da ova ve yaylalardan doğarak çeşitli havzalara yönelir. Akarsu havzalarının dar oluşu, Türkiye'nin büyük bir bölümünün yarı kurak iklimin etkisinde olması nedeniyle az yağış alması ve akarsu boylarının kısa olması akarsularımızın taşıdıkları su miktarının az olmasını sağlamaktadır. Akarsularımızın en büyük özelliğinden birisi de yataklarının fazla eğimli oluşudur. Akarsularımızın hidroelektrik enerji üretimine çok elverişli olmaları da dar ve derin vadiler oluşturmalarının bir sonucudur. Akarsularımızın büyük bir kısmında su seviyesinin en yüksek düzeyde olduğu dönem, ilkbahara rastlamaktadır. Bu dönemde yağışların artması ve kar erimeleri nedeniyle akarsuların su seviyeleri oldukça yükselir. Akarsularımızın akış seyri ile kullanılış seyri arasında ters bir orantı vardır. Yani su ihtiyacının fazla olduğu aylarda su verimi az, su ihtiyacının az olduğu aylarda su verimi çoktur. Bu durum zaman zaman taşkınlar ve uzun süreli kuraklıkların meydana gelmesine, neticesinde can ve maddi kayıplara sebep olmaktadır. Akarsuların akış rejimindeki bu düzensizlik, akarsuların regülasyonunu ve kontrolü düşüncesini doğurmuştur. Bu da akarsu üzerine yapılan baraj, sedde, regülatör, kanal gibi tesislerin yapılması ile mümkün olmaktadır. Bu tesislerin yapılabilmesi, yapılacak inşaatların plan ve projelerinin hazırlanabilmesi içinse akarsuyun akış rejiminin uzun yıllar etüt edilmesi gerekmektedir. Özellikle enerji, sulama, su ve toprak kaynaklarının geliştirilmesi, suyun zarar ve tehlikelerinden korunmak amacı ile yapılan inşaatların plan ve projelerinin hazırlanabilmesi için sistematik bir şekilde hidrometrik verilere ve hidrolojik çalışmalara ihtiyaç vardır. Hidrolojik çalışmaların başında da hidrometrik verilerin toplanması için ölçmelerin yapılması gelir.

Ülke genelinde yer alan akarsu ve göllerde mevcut su potansiyelinin tam olarak belirlenebilmesini ve yıl boyunca su miktarındaki dağılımın incelenmesini mümkün kılan akım verilerinin süreklilik arz eden bir bütün içerisinde üretilmesini sağlamak için küçük ve büyük akarsularımızda sistematik bir şekilde hidrometrik ölçümlerin yapılması gerekliliği oluşmuştur. Bu amaçla Ülkemizde ilk Akarsu Gözlem İstasyonu (AGİ) 1935 yılında Elektrik İşleri Etüt İdaresi tarafından baraj proje yerlerinde kurulmuş ve 1936

yılından itibaren de sistematik olarak akım ölçümlerine başlanmıştır. 1962 yılında yeni bir anlayışla, gözlem ve değerlendirmeler teknik yönden ele alınmıştır. Bu yaklaşımla oluşturulan gözlem ağı; Baz Akarsu Gözlem İstasyonları (AGİ), Aylık Akarsu Gözlem İstasyonları (AAGİ), Yıllık Akarsu Gözlem İstasyonları (YAGİ), Göl Gözlem İstasyonları (GGİ), Kar Gözlem İstasyonlarından (KGİ) oluşturulmuştur [13].

1.2.1. Akarsu Gözlem İstasyonları

Akarsularda akarsu gözlem istasyonu dediğimiz gözlem istasyonları kurulmuştur. Akarsu Gözlem İstasyonu; günlük su seviyesi gözlemlerinin yapılması için uygun hidrometrik aletlerle donatılmış ve belirli zamanlarda debi ölçümlerinin yapılmasını mümkün kılan yardımcı tesislerle desteklenmiş akarsu en-kesitleridir. Kurulan AGİ'lerinde yapılan gözlem ve ölçümlerle akarsu hakkında hidrometrik veriler toplanmaktadır. Bir akarsu gözlem istasyonunun çalıştırılmasındaki esas amaç o akarsuyun, istasyonun bulunduğu kesitten geçirdiği su miktarının tespitidir [13].

Akarsu gözlem istasyonlarında;

- Seviye ölçüm tesisleri (eşel, limnigraf, ultrasonik veya basınçlı sensör...)
- Akım ölçüm tesisleri (Teleferik, donav, akım ölçüm köprüsü...)
- Kontrol kesitleri (suni veya Doğal eşikler, kurb, boğaz...) bulunan ögelerdir.

Ülkemizde EİE tarafından işletilen gözlem ağını oluşturan istasyonlarda aşağıda sıralanan parametrelerin tespiti yapılmaktadır [13].


- Akarsularda seviye ölçümü,
- Akarsularda akım ölçüsü,
- Akarsulardan sediment örneği alma,
- Su kalitesi örneği alma,
- Hava sıcaklığı ve su sıcaklığı,
- Yüzeysel sularda buzlanma durumu,
- Hava durumu (Açıklık, kapalılık, yağış vb.),
- Su durumu (Berraklık, bulanıklık vb.),
- Akarsu yatağı durumu (Oyulma, dolma vb.)

1.2.1.1. Akarsu Gözlem İstasyonlarında Seviye Ölçümü

Akarsulardaki seviye ölçümünün yapılmasının amacı, o kesitten geçen debiyi ve debinin zaman içindeki değişimini tespit etmektir. Yapılan debi ölçümlerinde ölçüm anında geçen debi ölçülebilmektedir. Suyu sürekli ölçmemiz mümkün olmadığına göre geçen su miktarı hakkında yaklaşık bir değeri söyleyebilmemiz için bilinmesi gereken ilk olay suyun seviyesindeki değişimdir. Debi seviyenin bir fonksiyonudur. Doğru bir debinin elde edilmesi seviyelerin doğru elde edilmesi ile mümkündür [13].

İstenilen bir zaman periyodunda, akarsu kesitinden ne kadar debi geçtiğini tespit edebilmek için, belirli zamanlarda alınan debi ölçümleri neticesinde Seviye-Debi (H-Q) ilişkisini gösteren Şekil 1.1'deki gibi anahtar eğrileri oluşturulmaktadır.

Seviye-debi ilişkisini ifade eden bu eğriler vasıtasıyla, istasyonda sürekli kaydı tutulan seviyelere karşılık gelen akım değerleri belirlenir. Akım ölçüsü yapılmayan zamanlarda, seviye gözlemleri yapılarak ortalama seviyeyi yani 24 saatlik (günlük) ortalama seviyeyi hesaplamak ve buradan da akarsu en kesitinde ne kadar debi geçtiğini anahtar eğrileri yardımıyla bulmak mümkündür.




Şekil 1.1. Anahtar eğrisi

Akarsu Gözlem istasyonlarında eşel ve limnigraflarla sürekli seviye değerleri alınmaktadır. Ayrıca birçok istasyonda da yerel gözetleyici yükleniciler tarafından her gün saat 08⁰⁰ ve 16⁰⁰'da eşel seviyesi okunmaktadır. Seviye oynamalarının fazla olduğu zamanlarda gözetleme yüklenicileri ve arazi ekiplerince ek seviye gözlemleri

yapılmaktadır. Gözetleme yüklenicilerin arazi seviye okumaları, limnigraflı AGİ'lerinde limnigrafın değişik nedenlerle çalışmadığı zamanlarda seviye gözlemlerinin devamlılığını ve tesislerin güvenliğini sağlamak için de yararlı olmaktadır [13].

1.2.1.2. Akarsu Gözlem İstasyonlarında Akım Ölçümleri

Akarsu debisi, seçilen kesitten bir saniyede geçen suyun metreküp olarak miktarıdır. Uygulanan yöntem bir akarsuyun enine kesitinin yeterli sıklıkta parçalara ayırıp derinlik ve ara mesafelerinin alanlarını hesaplamak ve bu alanların ortalama hızlarını ölçerek bu alanlardan geçen debileri hesaplamak ve bunları toplayarak kesitten geçen toplam debiyi bulmaktır. Şekil 1.2'de akarsu en kesiti verilmiştir. En güvenilir ölçüm şekli mulinelerle yapılanıdır. Muline olmadığı zamanlarda flatörlerle, boya ve tuz metodları ile ölçüm yapılmaktadır. Bu ölçümlerin yapılması için en uygun kesitin seçilmesi ölçünün güvenilirliği bakımından önemlidir. Derinlik ölçümleri sapla veya çıkırıklar vasıtasıyla yapılmaktadır. Akarsularda akım ölçümleri girerek sapla, kayıkla ve askıdan teleferikle veya otokrenle yapılır.



Şekil 1.2. Akarsu en kesiti [55].

EİE Genel Müdürlüğü'nde Dünya Meteoroloji Örgütü (*World Meteorology Organization*, WMO) standartlarına uygun akım ölçümleri yapılmaktadır. Akarsu genişliği $b < (1/20).B$ ve $q < (1/10).Q$ olacak şekilde kesitlere ayrılıp her dilimden hızlar alınmaktadır. Girilerek yapılan akım ölçümlerinde 30 cm ye kadar olan su derinliklerinde hız alma

derinliđi %50'dir. Yani suyun orta yerinden hız alınır. 30-60 cm arası derinliklerde su yüzeyinden %60 derinlikte hız alınır, derinliđin 60 cmyi geçtiđi yerlerde ise su yüzeyinden %20 ve %80'inden çift sinyal denilen iki hız alınıp ortalaması alınıp su diliminin ortalama hızı bulunur. Bu hızların kesitlerdeki ortalama hızlara eşit olduđu kabul edilmektedir [13].

Kendisinden sulama suyu temini, tarımsal sulama ve enerji üretiminde büyük hizmetler beklenen baraj v.b yapıların ideal bir şekilde gerçekleşmesi, böyle yapılara hidrolojik hataların oluşturacağı zararlar çok büyük maddi kayıpların yanında telafisi hiçbir şeyle mümkün olmayan can kayıplarına sebebiyet verebilmektedir. Bu nedenle hidrometrik verilerin önemi çok büyüktür. Gelecekteki tahminleri, geçmişteki rasatları kullanarak yapmamız, mevcut istasyonlardaki deđişik nedenlerden dolayı ölçülemeyen, eksik bulunan verileri dođru olarak tamamlayabilmek için yapılan rasıtların önemi oldukça fazladır.

2. MATERYAL VE METOT

2.1 Yapay Sinir Ağları

Çalışmamızın temel konusunu oluşturan yapay sinir ağları teknolojisine ait temel ve teorik bilgiler bu bölümde ele alınmıştır. Çağımızdaki teknolojik gelişmelerin çok hızlı bir şekilde ilerlemesi insanlara birçok alanda hızlilik, zaman, ekonomiklik ve hızlı bilgi üretme vb. gibi kolaylıklar sağlamıştır. Bunun temelinde bilgisayarların kendileri için hazırlanmış komut sistemlerinin çok hızlı bir şekilde işleme konulup ve aynı hızla çözülebilmesi yatmaktadır. İnsanoğlu bulunduğu dönemin teknolojik şartlarını kullanarak doğada meydana gelen olayları anlamaya çalışmış, sebep-sonuç ilişkilerini irdeleyebilmek için birtakım yöntemler geliştirmiştir. Geliştirilen yöntemlerin bazıları canlı organizmalardan esinlenerek ortaya çıkmıştır. Bu organizmaların işleyişlerinin matematikle ifade edilmeye çalışılması ile ortaya çıkan yöntemlere verilebilecek en güzel örneklerden birisi de yapay sinir ağlarıdır [14].

Yapay Sinir Ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler üretebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemi ile gerçekleştirmek oldukça zor veya imkânsızdır. Bu nedenle, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğunu söyleyebiliriz [15].

YSA üzerindeki ilk çalışmanın 1943 yılında başladığı kabul edilir. McCulloch ve Pitts [16] ilk olarak yapay sinir tanımını yaparak hücre modelini geliştirdiler. Yapılan bu çalışmada sinir hücreleri sabit eşik değerli mantıksal elemanlar olarak modellenmiştir. Yapısında ∓ 1 sabit bağlantı ağırlıklarına sahip olan bu model aritmetik mantık hesaplama elemanları olarak da adlandırılmıştır. Öğrenme üzerine çalışmaların yoğunlaştığı 1949'lu yıllarda bilim adamları insan öğrenme sürecini modellemeye uğraşmaları ile artmıştır. Hebb [17], YSA'daki öğrenme için başlangıç noktası sayılabilecek bir kuralı geliştirmiştir. Ortaya atılan bu öğrenme kuralı, o dönemde bir sinir ağının öğrenme işini nasıl gerçekleştirebileceği konusunda fikir vermekle birlikte bu gün halen geçerli olan öğrenme kurallarından birçoğunun da temelini teşkil etmiştir [14, 18].

1958'de Rosenblatt [19], algılayıcı (*perceptron*) modelini ve öğrenme kuralını geliştirmiştir. Bu çalışma bugün kullanılan kuralların temellerini oluşturmaktadır. Minsky

ve Papert [20], 1969 yılında, algılayıcının kesin analizini yapmışlar ve algılayıcının karmaşık mantık fonksiyonlar için kullanılamayacağını ispatlamışlardır [21].

Kronolojik gelişmelere bakıldığında YSA için 1970 yılının bir dönüm noktası olduğu görülmektedir. Bu tarihten önce birçok araştırmanın yapıldığı ve 1969 yılında XOR probleminin çözülmemesi nedeni ile araştırmaların durduğu görülmektedir. 1970 yılından sonra sınırlı sayıda araştırmacının çalışmaları sürdürmeleri ve XOR problemini çözmeleri sonucunda YSA'ya olan ilgi yeniden alevlenmiştir. İzleyen 10 yılda birbirinden farklı 30 civarında yeni model geliştirilmiştir. 1976'da Grossberg [22], Adaptif Rezonans Teorisi (ART), 1982'de Hopfield [23], optimizasyon gibi teknik problemleri çözmek için lineer olmayan dinamik Hopfield Ağını ve 1984'te Kohonen [25], eğitimci öğrenen bir ağı geliştirmişlerdir. 1986 yılında, Rumelhart ve diğ. [26], tarafından çok katmanlı algılayıcı tipi ağlar için “*geriye yayılma algoritması*” denen bir eğitim algoritması geliştirmiştir. Bu algoritma güçlü olmakla birlikte oldukça karmaşık matematik esaslara dayanmaktaydı. Ayrıca bu algoritmanın etkin bir öğrenmeyi mümkün kılma yeteneği dikkatleri tamamen üzerine çekti. Bu çalışmayla, YSA alanında bir çığır açılmış bugün halen en çok kullanılan algoritma olan geriye yayılım algoritması hatayı minimize etmeye yönelik ağırlıkların çıkıştan girişe doğru ayarlanması esasına dayanmaktadır. Her geçen gün değişik öğrenme algoritmaları ve ağ mimarileri hakkında yeni önemeler yapılmaktadır [14, 18, 21, 27].

İnsan beyninin temel işlem elemanı olan nöronu (*neuron*) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA'lar, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneme yanılma yöntemi ile öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine girdi veriden öğrenme yeteneği sağlamaktadır ve birçok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknoloji, günümüzde birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (*Universal Function Approximators*)” olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar.


2.1.1. YSA'nın Tanımı ve Özellikleri

YSA, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve

veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve gözlemleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir. Kısaca YSA, insanlar gibi öğrenir, yani problemleri çözmek için mevcut örnekleri (verileri) kullanır. Yapay sinir ağları kendisine verilen örnekler üzerinde kendini eğiterek bir çözüm sistemi geliştirmektedir. Bu metot, modelin nasıl bir yapıya sahip olacağı ya da çalışacağı konusunda önceden belirlenmiş bazı fikirleri içermemektedir. Modelleyicinin veri girdileri üzerinde kontrolü bulunmakta olup ilgisiz değişkenler belirlenebilmekte veya model oluşma sürecinde ayıklanabilmektedir [5].

YSA'lar girdilere karşılık çıktılar üreten bir kara kutu olarak ele alınabilir. Beynin zor işlemleri yapabilme ve karmaşık örnekleri kavrayabilme yeteneği ve özellikle ilgili fiziksel ilişkileri bilmeden yalnızca denemeyle bazı şeyleri öğrenebilmesi bilim adamlarına Yapay Sinir Ağları metodunun geliştirilmesi için ilham vermiştir [3].

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (*synaptic*) bağlantıların ayarlanması ile olur. Şekil 2.1'de sinir ağlarının bağlantılarının basitleştirilmiş şekli gösterilmiştir.



Şekil 2.1. Sinir hücrelerinin bağlantılarının basitleştirilmiş şematik yapısı

İnsanlar doğumlarından itibaren bir “*yaşayarak öğrenme*” süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu

durum YSA için de geçerlidir. Öğrenme, eğitime yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi-çıkı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak bağlantı ağırlıklarını (*weights of the synapses*) bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur.

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır [18, 21].

YSA'lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün birçok endüstride başarılı şekilde kullanılmaktadırlar. Uygulama alanları için bir sınır yoktur fakat öngörü, modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. YSA'lar 1950'li yıllarda ortaya çıkmalarına rağmen ancak 1980'li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir. Bugün, YSA'lar birçok ciddi problem üzerinde uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır. Verideki trend veya yapıyı (pattern) en iyi tanımlayan yöntem olmaları dolayısıyla, tahmin (prediction) ve öngörü işlemleri için çok uygundurlar. YSA'ların gerçek hayattaki yaygın uygulama alanları, Kalite Kontrol, Finansal ve Ekonomik Öngörü, Kredi Derecelendirme, Konuşma ve Yapı Tanımlama, İşlem Modelleme ve Yönetimi, Laboratuvar Araştırmaları, İflas Tahmini, Petrol ve Gaz Arama, Çeşitli Mühendislik Alanlarında veri Tahmini ve Tıbbi Alanda Data Değerlendirme ve Tanı Konulması v.b. gibi sıralanabilir.


YSA'lar yoğun bağlantılı ve karmaşık işlem yapıları nedeniyle çalışabilecekleri özel ortamlara ihtiyaç duymaktadırlar. Bu yüzden YSA'lar bu amaca yönelik olarak hazırlanmış özel yazılımlar ile bilgisayarlarda çalıştırılmaktadırlar. Günümüzde ise gittikçe artan oranda yoğun ve karmaşık sinir ağlarını çalıştırabilmek ve daha hızlı işlem yapabilmek için özel donanımlar geliştirilmektedir [18, 21].

2.1.2. YSA'nın Yapısı

Çalışmamızın başında da belirttiğimiz gibi yapay sinir ağları insan beyninden esinlenilmiş yapılardır. Bu nedenle YSA'ların yapısını anlamak için insan beyninin

yapısını ve çalışma seklini anlamak önemlidir. Bununla birlikte, tahmin edilebileceği gibi insan beyni, karmaşık yapısı ile anlaşılması ve anlatılması zor bir konudur. Hatta beynin çalışma sekli hala tam olarak anlaşılammıştır. Burada bu bilginin verilmesi gereksizmiş gibi gözükse de konunun özünün anlaşılması açısından yararlı bilgiler verebileceği, düşüncesi ile genel bir açıklama yapılmaktadır.

İnsan beyni, sinir sisteminin merkezini oluşturan temel elemandır. En basit şekilde, sürekli olarak iletilen bilgiyi alır, idrak eder (işler) ve uygun kararları vererek gerekli yerlere iletir. Çok basit görünmekle birlikte aslında oldukça karmaşık olan bu yapının Haykin [28], tarafından kullanılan basit bir gösterimi Şekil 2.2’de sunulmaktadır.




Şekil 2.2. Sinir sisteminin blok diyagramı

Şekilden takip edilebileceği gibi, dışarıdan veya başka bir organdan gelen sinyaller (uyarı) alıcılar yoluyla sinir ağına iletilir. Sinyaller burada işleminden geçirilerek çıktı sinyaller oluşturulur. Oluşturulan çıktı sinyaller ise ileticiler yoluyla dış ortama veya diğer organlara iletilirler. Şekil 2.2’de sinir ağı olarak gösterilen ortadaki bölüm, yani beyin, sinir sisteminin merkezi konumundadır. Beynin temel yapı taşları ise sinir hücreleri, diğer bir ifadeyle nöronlardır [29].

Beyin, işlevini birbirleri arasında yoğun bağlantılar bulunan bu yapı taşları ile yerine getirir. Nöronların en belirgin özelliği, vücudun diğer bölümlerinin tersine yeniden üretilmeyen belirli bir hücre türü olmasıdır. Beynin diğer temel yapısal ve fonksiyonel birimleri olan bağlantılar (*synapses*) nöronlar arası etkileşimi sağlarlar. Dolayısıyla beynin yapısında bu bağlantılar da önemli bir yer tutmaktadır. Zaten beynin oldukça etkin çalışan bir organ olmasının temel sebebi de bu yoğun bağlantılı yapıdır. Bu yapı sayesinde beyin bugünkü bilgisayar teknolojisinden kat kat daha etkin bir şekilde çalışabilmektedir. Beynin bu yapısı etkinlik açısından olduğu kadar bir diğer önemli özellik açısından da önem taşımaktadır. Bu yoğun bağlantılı yapı beynin plastiklik (yenilenebilme) özelliğini de beraberinde getirmektedir. Plastiklik özelliği, gelişmekte olan sinir sisteminin kendisini kuşatan çevreye adapte olmasını sağlamaktadır. Gelişmiş bir beyinde, plastiklik iki mekanizma ile izah edilebilmektedir. Bunlar, nöronlar arasında yeni bağlantıların

oluşturulması ve var olan bağlantıların modifiye edilmesidir. Ayrıca, bu özellik öğrenme kavramı açısından da çok büyük önem taşımaktadır. Plastikliğin, nöronların işlem yapabilmeleri için gerekli bir özellik olduğu görülmektedir. Çünkü öğrenme süreci bağlantı ağırlıklarının değiştirilmesi veya yeni bağlantıların oluşturulması (hatta bazı bağlantıların iptal edilmesi) sayesinde gerçekleşmektedir. Bu ilişki, yapay nöronlar kullanarak beyinden esinlenilmiş sinir ağları oluşturulabilmesini sağlamaktadır [18, 21].



Şekil 2.3. Yapay sinir hücresi modeli (X_i , giriş değerleri; W_i bağlantı ağırlığıdır.).

Yapay sinir ağlarında da, girdiler ve çıktılar arasında pek çok hücre ve çok sayıda bağ vardır. Sinir hücreleri arasındaki bu bağlar ilişkiye göre bir aktarım değeri almaktadır ve bu değere ağırlık denmektedir. Ağırlıklar girilen tüm yeni veriler için yenilenebilmektedir. Mevcut bir veri tabanı öğretimi yapıldıktan sonra, ileride elde edilecek verilerle sistem kolayca güncellenebilmektedir. Basit bir yapay sinir hücresi Şekil 2.3’de de görüldüğü gibi; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş ana kısımdan oluşmaktadır. Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye girilen bilgilerdir. Ağırlıklar, girdi seti veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplama fonksiyonu girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar [30, 31].

Girdi bileşenlerindeki ağırlıkların tümü $(net)_j$ aşağıdaki Eşitlik (2.1) kullanılarak toplanır [32, 33-36].

$$(net)_j = \sum_{i=1}^n w_{ij} x_i + b \quad (2.1)$$

burada; $(net)_j$, n sinir hücresi ile önceki tabakadan alınan girdinin j. sinir hücresinin toplam ağırlığı, w_{ij} önceki tabakadaki i. sinir hücresi ve j. sinir hücresi arasındaki ağırlık, x_i önceki tabakadaki i. sinir hücresinin çıktısıdır [32]. b içsel katkı olarak sabit bir değeri ve Σ toplama fonksiyonudur. Aktivasyon fonksiyonu ise toplama fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen bir fonksiyondur. Genel olarak çok tabakalı algılayıcı modellerde aktivasyon fonksiyonu **(f(.))** olarak Sigmoid fonksiyonu kullanılır. Sigmoid aktivasyon fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı Eşitlik (2.2)'deki gibi gösterilmektedir [30, 37, 38, 39]

$$Çıktı_j = F(net)_j = \frac{1}{1 + e^{-\alpha(net)_j}} \quad (2.2)$$

burada; α yarı doğrusal bölgenin eğimini kontrol etmek için kullanılan bir sabittir. Sigmoid doğrusal olmayan aktivasyon her tabakayı girdi tabakasından ayırmaktadır [32,40]. Sinir hücresinden elde edilen çıktılar dış dünyaya veya başka bir hücreye gönderilir. Eşitlik (2.2) şeklinde ifade edilen Sigmoid fonksiyonu (0, 1) arasında çıkışlar verir. İstenildiği takdirde fonksiyonun çıkışları (-1, 1) arasına düşecek biçimde ayarlanabilir. Sigmoid işlemcisi sürekli bir fonksiyonu gösterdiğinden dolayı özellikle doğrusal olmayan tasvirlerde kullanılır. Bunun nedeni $(net)_j$ değişkeni bünyesinde bulunan parametrelere göre türevinin kolayca alınabilmesidir [33, 41, 29]. Burada, $(çıkı)_{j_1}$ çıktıları ile hedeflenen çıktılar arasındaki farklar hata olarak belirlenir ve bu hatanın istenen sınırlardan daha küçük olmaması durumunda, hatalar geriye doğru her bağlantıya geri yayılma ile dağıtılır. Benzer işlemler ile YSA modelinin eğitimine istenen hata sınırları elde edilinceye kadar devam edilir.


2.1.3. YSA'nın Çeşitleri

YSA'ların çok sayıda farklı çeşitleri vardır. Bu farklılıkların kaynağı mimarisi, öğrenme yöntemi, bağlantı yapısı vb. olabilmektedir. Genel olarak, YSA'lar üç ana kritere göre sınıflandırılmaktadırlar.


Bu kriterlerden birincisi öğrenme yöntemidir. İki çeşit öğrenme algoritması vardır: yönlendirmeli öğrenme ve yönlendirmesiz öğrenme. Her yöntemin kullandığı öğrenme kuralı değişebilmekteyse de, YSA'lar bu iki algoritmaya göre sınıflandırılırlar.

İkinci kriter, ağıın kullandığı veriye göre yapılmaktadır. Temel olarak, kalitatif ve kantitatif olmak üzere iki tür veri vardır. Kalitatif verilerle çalışan ağlar, ister yönlendirmeli ister yönlendirmesiz öğrenme kullansın, sınıflandırma ağları olarak bilinirler. Kantitatif veriler kullanan yönlendirmeli eğitime ise regresyon olarak adlandırılmaktadır.

Son sınıflandırma kriteri ise ağıın yapısıdır. Bazı ağlar ileri besleme şeklinde yapılandırılırken, bazı ağlar ise geri besleme yapısı içermektedir. İleri besleme sinir ağlarında, işlem elemanları arasındaki bağlantılar bir döngü oluşturmazlar ve bu ağlar girdi veriye genellikle hızlı bir şekilde karşılık üretirler. Geri beslemeli ağlarda (*Recurrent networks*) ise bağlantılar döngü içerirler ve hatta her seferinde yeni veri kullanabilmektedirler. Bu ağlar, döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden, bu tür ağların eğitime süreci daha uzun olmaktadır. Ayrıca, hem ileri besleme hem de geri yayılma olarak tanımlanabilecek ağ yapıları da mevcuttur. Şekil 2.4'te bir kıyaslamaya imkân tanıyabilmek için, çok tabakalı ileri besleme ağ yapısı ile birlikte çok tabakalı geri besleme ağ yapısı örneklenmektedir.



(a) Çok tabakalı ileri besleme ağ




Şekil 2.4 İleri Beslemeli ve Geri Beslemeli Ağ Yapıları.

Bu çok geniş YSA çeşitleri yelpazesinde en çok bilinen ve kullanılan ağlar arasında hata algoritması genellikle geri yayılma ile eğitilen çok tabakalı perceptron (Geri-Yayılma Ağ – *Backpropagation Network*), radyal tabanlı fonksiyon (*Radial Basis Function*), Hopfield ve Kohonen sayılabilir. Çok fazla çeşit ve yoğun bir literatür olması nedeniyle, burada tüm ağ çeşitleri hakkında bilgi verilmemektedir. Bunun yerine çalışmada kullanılan YSA çeşitleri olarak Çok Katmanlı Yapay sinir ağları (ÇKYSA) ve Radyal Tabanlı Yapay Sinir Ağı (RTYSA) hakkında bilgi verilmiştir [21].

2.2. Çalışmada Kullanılan YSA Metodları

2.2.1. Çok Katmanlı Geri Yayılmalı Yapay Sinir Ağları (ÇKYSA)

YSA metotları içerisinde en çok kullanılanı hataların geriye yayılma (back-propagation) ilkesine göre çalışandır [42]. Şekil 2.5, bu çalışmada kullanılan üç tabakalı bir yapay sinir ağını göstermektedir. Burada i girdi tabakası, j gizli tabaka ve k çıktı tabakası, A_{ij} ve A_{jk} ise hücre tabakaları arasındaki bağlantı ağırlıklarıdır. Başlangıçta rastgele atanan ağırlık değerleri, eğitim sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değiştirilir ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru (Şekil 2.5'te sağdan sola) yayılır. Burada ağırlıkları ayarlamak için kullanılan metot, Levenberg-Marquardt metodudur [43].



Şekil 2.5. Üç tabakalı yapay sinir ağı modeli

Şekil 2.4'te j ve k tabakalarındaki her bir hücre, önceki tabakadan NET ağırlıklı toplam çıktıları girdi olarak alır. NET değeri (2.3) eşitliği ile hesaplanır.

$$NET_{pj} = \sum_{i=1}^D A_{ij} C_{pi} + \theta_j \quad (2.3)$$

burada D girdi vektörünün boyutu, θ_j taraflılık sabiti(bias), A_{ij} i ve j tabakaları arasındaki ağırlıklar kümesi, C_{pi} p örneği için i tabakasının çıktı kümesidir. j ve k tabakalarındaki her bir hücre, NET değerini doğrusal olmayan bir tasvir fonksiyonundan geçirerek $f(NET)$ çıktısını üretir. Yaygın şekilde kullanılan bu tasvir fonksiyonu,

$$f(NET) = \frac{1}{1 + e^{-NET}} \quad (2.4)$$

şeklinde ifade edilir. Eğitim aşamasında, p örneği için toplam hata H_p , tahmin edilen ve gerçek çıktılar arasında kareler farkına bağlı olarak (2.5) eşitliğiyle hesaplanır.

$$H_p = \sum_{k=1}^N (G_{pk} - C_{pk})^2 \quad (2.5)$$

burada N iterasyon sayısı olmak üzere G_{pk} ve C_{pk} sırası ile p örneği için gerçek ve tahmin edilen çıktı değerleridir. Her bir bağlantı ağırlığı, A_{ij} , (2.6) eşitliği ile yenilenir.

$$A_{ij}^{yeni} = A_{ij}^{eski} - \left[J^T J + \mu I \right] J^T H_p \quad (2.6)$$

burada J , hataların ağırlıklara göre türevlerini içeren Jacobian matrisini; J^T , Jacobian matrisinin transpozisini; I , birim matrisi ve μ ise yakınsama hızını etkileyen bir parametreyi ifade etmektedir. μ , değeri büyüdüğünde eşitlik eğim azaltma algoritmasına, küçüldüğünde ise eşitlik Gauss-Newton algoritmasına dönüşür [36].

2.2.2. Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

RTYSA çok boyutlu problemler için en uyumlu sonuç veren Yapay Sinir Ağı tekniklerinden birisidir. RTYSA mimarisinde, girdi katmanından gizli katmana (radyal tabanlı katman) doğrusal olmayan ve gizli katmandan çıktı katmanına doğrusal bir dönüşüm uygulanır. İnterpolasyon özelliği çok iyi olması nedeniyle RTYSA'lar, eğitim için kullanılan verilerin arasında ve yakın civarında arama yapmak için uygundur. Bu nedenle eniyileme çalışmalarında RTYSA tercih edilmektedir [44].

RTYSA'da, m adet örnek içeren eğitim seti ve her örnekteki n adet parametreden oluşan girdi verilerine (x) bağlı olarak,

$$u_i^k = \sum_{j=1}^n (x_j^k - x_j^i)^2 \quad (i=1,m \text{ ve } k=1,m) \quad (2.7)$$

$$h_i^k = \phi(u_i^k) \quad (2.8)$$

$$\left[\begin{matrix} h_1 & h_2 & \dots & h_m \end{matrix} \right] \quad (2.9)$$

eşitlikleriyle, her bir girdi grubu için önce m adet radyal taban (h) ve sonra çıktı değerlerine (f) bağlı olarak, gizli katman ile çıktı katmanı arasındaki ağırlıklar w_j hesaplanır. Eğitim setindeki m adet örneğin tamamı radyal merkez olarak kullanıldığında, $[h]$ matrisi $m \times m$ boyutunda kare matris olur. Burada (2.8) denklemlerindeki ϕ radyal fonksiyondur ve değişik şekillerde tanımlanmaktadır. Bu çalışmada yapılacak uygulamalarda Gauss formunda,

$$\phi(u) = e^{\frac{u}{rs}} \quad (2.10)$$

ve kuadratik formda,

$$\phi(u) = \frac{1}{\sqrt{rk^2 + u}} \quad (2.11)$$

bağıntıları kullanılacaktır (rs ve rk kullanıcının belirlediği reel sayılardır). Eğitim sonunda (2.9) eşitliğiyle w_j ağırlıkları belirlendikten sonra,

$$f(x) = \sum_{j=1}^m w_j h_j \quad (2.12)$$

bağıntısı ile herhangi bir x girdisi için, (2.7) ve (2.8) denklemleriyle u ve h değerleri hesaplandıktan sonra, $f(x)$ çıktısı tahmin edilebilir.

2.3. Dalgacık Dönüşümü

Dalgacık dönüşümü; verilerin hem zaman hem de frekans ortamında işaretin incelenmesine imkân tanıyan çok yararlı bir yöntemdir. Bu alanda adı sıkça geçen Princeton Üniversitesinden I. Daubechies dalgacık dönüşümlerini şu şekilde tariflemiştir: "Dalgacık dönüşümü, verileri fonksiyonları veya operatörleri farklı frekanstaki bileşenlere ayıran bir araçtır ve böylece her bir bileşen ile kendi ölçek değerine uygun bir çözünürlükte çalışılabilir [45, 46]. Dalgacık dönüşümlerinin su kaynakları sahasında isaret isleme yöntemlerinin kullanımı son derece yenidir. Kısa süreli Fourier dönüşümünde kullanılan pencere fonksiyonunun, tarama sırasında sabit genişlikte olması, işaretin hızlı değişen yüksek frekanslı değişimlerin zaman uzayında tam olarak bölgelendirilememesine neden olur. Bu soruna çözüm olarak, sabit genişlikteki pencereler yerine, işaretteki yavaş değişimleri yakalamak üzere geniş pencere fonksiyonları ve hızlı değişimlerin olduğu yerlerde ise dar pencere fonksiyonlarının kullanımı düşünülmüş ve sonuçta, dalgacık dönüşümü konusu ortaya çıkmıştır.

Dalgacık fonksiyonları ve dönüşümü, ilk olarak, kuantum mekaniği ve istatistiksel mekanik alanlarında kullanılmıştır. Dalgacık analizinin uygulamalı matematik alanında

kullanımı 1980'li senelerde başlamıştır. Grossman ve Morlet [47], sismik işaretleri, dalgacık "wavelet" adı verilen sonlu süreli ve titreşimli bir işaretin çeşitli zamanlardaki uygun şekilleriyle birleştirerek modellemeye çalışmışlar ve sürekli dalgacık dönüşümünü (SDD) uygulama alanına geçirmiş oldular. Dalgacık dönüşümünün ilk uygulama alanları, fonksiyonel gösterimler, kuantum mekaniği ve işaret islemede olmuştur. Dönüşümünün işaret isleme alanında uygulamaları, I. Daubechies ve S. Mallat [48] ile başlamıştır. Araştırmacılar, dalgacık ayrıştırması konusunda birçok teoriler geliştirerek ayrık dalgacık dönüşümünün (*Discrete Wavelet Transform*, DWT) temelini attılar. Dönüşümün işaret isleme alanında uygulamaları, Daubechies [45, 46] ile başlamıştır. Araştırmacı, dalgacık ayrıştırması konusunda birçok teori geliştirerek ayrık dalgacık dönüşümünün temelini atmıştır. Sonraki yıllarda, dalgacık dönüşümünde büyük gelişmeler olmuştur.

Bayan Matematikçi I. Daubechies, Daubechies fonksiyonları (tabanları) olarak bilinen, düzgün, yoğun olarak destekli ve ortonormal dalgacık tabanlarını geliştirdi.

Fransız işaret analizcilerinden Mallat [48] ve Meyer [49], dalgacık tabanlı genel bir metot önerdiler. Çok çözünürlüklü analiz (*Multiresolution analysis*, MRA) olarak bilinen metot, işaret analizinde, yan bant kodlaması (Sub-band Coding) olarak uygulanmaktadır.

Sonuç olarak, yeni bir zaman-frekans analizi (time-frequency analysis) metodu yapılandırılmış oldu. Bu yolla işaret, öz uyumlu olarak, aynı anda, hem zaman ve hem de frekans uzaylarında incelenebilir oldu.


Örüntü tanıma (*Pattern recognition*) alanında uygulaması fazla yaygın olmamakla birlikte, dalgacık teorisi işaret isleme (örneğin, veri sıkıştırma), görüntü analizi (örneğin, kenar bulunması), haberleşme sistemleri, biyomedikal görüntüleme, radar, akustik, teorik matematik ve kontrol sistemleri gibi alanlarda kullanılmaktadır [38].

2.3.1. Dalgacık Nedir? Sürekli Dalgacık Dönüşümü (SDD)

Dalgacık (*Wavelet*), dalga'nın küçük bir parçası olarak tanımlanabilir. Bu anlamda dalgacık, süresi sınırlı bir titreşim işaretidir ve bu nedenle zamanda bölgeleşmeye (yerselleşmeye) sahiptir [46].

İşaret, sürekli dalgacık dönüşümünde dalgacık adı verilen zamanda ötelenebilen, genişliği değiştirilebilen bir fonksiyonla çarpılır. Analiz boyunca, adım adım öteleme sağlanarak her adımda o adımdaki dalgacık ve sinyalin çarpılmasıyla katsayılar elde

edilmiş olur [5]. Aşağıda, dalgacık dönüşümlerinde kullanılan dalgacık tiplerinden biri olan Morlet dalgacığı görölmektedir (Şekil 2.5).



Şekil 2.6. Morlet dalgacığı

Sürekli dalgacık dönüşümü işlemi (SDD) şu şekilde ifade edilir edilir.

$$SDD_x^\psi(\tau, s) = \psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (2.13)$$

$$\psi_{\tau, s} = \frac{1}{\sqrt{s}} \psi \left(\frac{t - \tau}{s} \right) \quad (2.14)$$

burada SSD, τ (öteleme) ve s (ölçek) parametrelerinin bir fonksiyonudur. $\psi(t)$, dönüşüm fonksiyonudur ve ana dalgacık fonksiyonu olarak adlandırılır. $x(t)$ ise analiz edilecek işarettir. Dönüşümde kullanılan farklı genişliğe sahip alt pencere fonksiyonları da ana dalgacıktan ölçekleme yoluyla türetilir. Öteleme terimi, Kısa Süreli Fourier Dağılımında (KSFD) kullanılan pencerenin zamandaki yerini ifade etmektedir. Pencere, işaret üzerinde gezdirilir. Zaman bilgisi, dönüşümden ötelemeye sağlanır. Ölçek parametresi (s), 1/frekans olarak tanımlanır. Dalgacık fonksiyonunun işaretle ötelenerek çarpımı ile dalgacık dönüşümü katsayıları elde edilir.

2.3.2. Ayırık Dalgacık Dönüşümü

Dalgacık katsayılarının ölçek değerinde hesaplanması çok miktarda katsayının oluşmasına ve işlem yüküne neden olduğundan dolayı, katsayıların yalnızca seçilen ölçekler ve zaman diliminde hesaplanması birçok avantaj sağlar. Bu sayede daha az sayıda ancak yinede işaretin frekans-ölçek bilgisinin zaman boyunca değişimini veren katsayılar elde edilmiş olur. Ayırık dalgacık dönüşümünde kullanılan ikili ölçek ve zaman adıdır. Bu şekilde elde edilen her bir bileşen iki ve ikinin katları olacak şekilde ölçek değerlerine ait zaman serilerini ya da dalgacık katsayılarını verirler. Ayırık dalgacık dönüşümü için kullanılan dalgacık fonksiyonu aşağıda verilmiştir.

$$\psi_{m,n}\left(\frac{t-\tau}{s}\right) = s_0^{-m/2} \psi\left(\frac{t-n\tau_0 s_0}{s_0^m}\right) \quad (2.15)$$

burada m ve n tamsayı ile ölçek ve zaman eksenindeki öteleme parametreleridir. S_0 sabit bir öteleme adımını ifade eder ve bu çalışma da 2 olarak alınmıştır. τ_0 zaman eksenindeki öteleme aralığı değerini verir ve değeri 1 olarak alınmıştır. Bu değerler literatürde en çok kullanılan değerlerine göre alınmıştır. İkinin katları kullanılarak oluşturulan dalgacık fonksiyonu aşağıdaki şekilde tanımlanabilir.

$$\psi_{m,n}(\tau) = 2^{-m/2} \psi(2^{-m} \tau - n) \quad (2.16)$$

Bir i ayırık adımına sahip $x(t)$ zaman serisi için ayırık dalgacık dönüşümü aşağıdaki şekilde tanımlanabilir.

$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} X_i \psi(2^{-m} i - n) \quad (2.17)$$

burada $W_{m,n}$, $s=2^m$ ölçek ve $\tau=2^m n$ zaman değerlerine sahip dalgacık dönüşümü katsayılarıdır.

2.4. Çoklu Doğrusal Regresyon (ÇDR)

Y bağımlı değişkeninin $X_1, X_2, \dots, X_m$ gibi bağımsız değişkenlerden etkilendiği kabul edilir ve aralarındaki ilişki için doğrusal bir denklem seçilirse Y'nin regresyon denklemi şu şekilde yazılabilir:

$$y = a + b_1x_1 + b_2x_2 + \dots + b_mx_m \quad (2.18)$$

Bu denklemde y, bağımsız değişkenler $X_1= x_1, X_2= x_2, \dots, X_m= x_m$ değerlerini aldığıında Y değişkeninin beklenen değerini göstermektedir. a, $b_1, b_2, \dots, b_m$ regresyon katsayıları basit regresyondakine benzer şekilde, gözlem noktalarının regresyon denkleminin gösterdiği düzlemden olan e_{yi} uzaklıklarının karelerinin toplamı olan

$$\sum_{i=1}^N e_{yi}^2 = \sum_{i=1}^N (y_i - a - b_1x_{1i} - b_2x_{2i} - \dots - b_mx_{mi})^2 \quad (2.19)$$

ifadesini minimum yapacak şekilde hesaplanır [51]. Bu çalışmada, a katsayısı sıfır kabul edilerek b katsayıları en küçük kareler metodu ile bulunmuştur. Bu amaçla MATLAB programlama dilinde bir program hazırlanmıştır.

2.5. Modelleme

2.5. 1. Modellerin Güvenilirlikleri

Tez çalışmasında oluşturulan modellerin güvenilirlikleri ve tahmin kapasiteleri çeşitli hata kriterleri yardımıyla belirlenmiştir. Model oluşturulurken kullanılmayan veriler, modelin test aşamasında kullanılmış ve çeşitli hata kriterleri ile modeller test edilmiştir. Çalışmada kullanılan modellerin tahmindeki başarısını ölçmek için karekök ortalama karesel hata (KOKH) ve ortalama mutlak hata (OMH) kriterleri kullanılmıştır.

2.5.2. Ortalama Karesel Hatanın Karekökü (KOKH)

Hata kriterlerinden birisi ortalama karesel hata (OKH)'dır. Bu kriterin karekökü bize KOKH kriterini verir. Ortalama karesel hatanın ifadesi aşağıda verilmiştir:

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{i(\text{ölçüm})} - Y_{i(\text{model})})^2} \quad (2.20)$$

burada Y_i (ölçüm) gerçek ölçüm değerlerini, Y_i (model) model yardımıyla tahmin edilen değerleri ifade eder. N ise ölçüm sayısını (toplam girdi sayısını) belirtir. Ortalama karesel hata kriterinin değeri modelin hatalarına karşın karesel olarak artış göstermektedir. Her ne kadar oluşan toplam hata örnek sayısına bölünse de pik değerlerde hata değeri üstsel olarak artmaktadır. Düşük değerlerde ise üstsel olarak azalmaktadır. Bu nedenle yalnızca ortalama karesel hatayı kriter olarak seçmek yeterli olmaz. Başka hata kriterlerinin de göz önünde bulundurulması gerekir.

2.5.3. Ortalama Mutlak Hata (OMH)

KOKH kriteri örnek başına düşecek mutlak hatayı ifade edemez. Bir başka hata kriteri olarak ortalama mutlak hata (OMH) kriteri test aşamasında kullanılmaktadır. OMH aşağıdaki bağıntıda belirtilmiştir:


$$OMH = \frac{1}{N} \sum_{i=1}^N |Y_{i(\text{ölçüm})} - Y_{i(\text{model})}| \quad (2.21)$$

3. BULGULAR

3.1. Çalışmada Kullanılan Veriler

Çalışma alanı olarak Fırat Nehri ve kollarını içine alan 21 no'lu Fırat-Dicle havzasının Fırat bölümü seçilmiştir. Havza Güney Doğu Anadolu ile Doğu Anadolu Bölgesinin büyük bir bölümünü kapsamaktadır. Havza Yukarı Fırat, Orta Fırat, Aşağı Fırat ve Dicle bölümü olmak üzere dört bölümden oluşmaktadır. Fırat–Dicle Havzasının Fırat bölümünün toplam yağış alanı 120917.0 km², ortalama yağış yüksekliği 540.10 mm ve ortalama 31.66 milyar m³ akış miktarı ile toplam ülke potansiyelinin yaklaşık %16.83'üne sahiptir [52].

Fırat–Dicle Havzasının su potansiyelinin belirlenebilmesi amacıyla Fırat Nehri ve kolları üzerinde çok sayıda Akarsu Gözlem İstasyonu (AGİ) kurulmuştur. Fırat-Dicle Havzası genelinde Elektrik İşleri Etüt İdaresi (EİE) tarafından işletilmekte olan ve verisi bulunan toplam istasyon sayısı 130'dur. Bunların 79'u kapalı 51'i ise halen faaliyettedir [8,9]. İstasyonların büyük bir bölümünde elektronik limnigraflar olup 15 dakikalık veriler kesintisiz mevcuttur. Şekil 3.1'de Havzanın görünümü ve Elektrik İşleri Etüt İdaresi tarafından işletilen AGİ'lerin havza üzerindeki dağılımı verilmiştir [53].




Şekil 3.1. Fırat Dicle Havzasının Lokasyonu [55].

The map illustrates the Euphrates River (Fırat N.) and its extensive network of tributaries, including the Tigris (Dicle N.), Karasu, Aras, and others. Key cities like Erzurum, Van, and Diyarbakir are marked. A large red '21' is prominently displayed in the center of the map. The legend at the bottom right provides the following information:

- L Limniför Tesli
- T Yüzeysel Tesli
- D Dışya ve E'E Tarafından İstisna AGI
- Açık Akım Gözlem İstasyonu
- Kapalı Akım Gözlem İstasyonu
- Açık Göl Gözlem İstasyonu
- Kapalı Göl Gözlem İstasyonu

Orta Fırat bölümünden Murat kolu üzerinde bulunan Palu (2102), Tutak (2122), Abdurahman Paşa Köprüsü (2158), Çayağzı (2164), Akkonak (2174), Adıvar (2177), Devecik köprü (2178) ve Tutak (2181) olmak üzere 8 adet AGİ'ye ait günlük ortalama akış verileri kullanılmış Şekil 3.3'te Havzanın Orta Fırat bölümündeki istasyonların konumları verilmiştir.



Şekil 3.3. Fırat Havzası (Orta Fırat Bölümü) [9].

Aşağı Fırat Bölümünden Malpınarı (2115), Yazıköy (2124), Hisarcık (2145), Çanakçı (2194) olmak üzere dört adet akarsu gözlem istasyonlarına ait günlük ortalama akış verileri kullanılmıştır. İstasyonların seçiminde birbirlerine olan konumları, memba-mansap ilişkisi ve veri aralığının uzunluğu göz önüne alınmıştır.

Çalışmada kullanılan EİE tarafından işletilmekte olan 17 adet AGİ'ye ait genel bilgiler Tablo 3.1'de verilmiştir [54].

Tablo 3.1. Çalışmada Kullanılan Akarsu Gözlem İstasyonları hakkında Genel Bilgiler [55].

İstasyon No	İstasyon Adı	Koordinatları (° ‘ ‘')		Kot (m)	Yağış Alanı (km ²)
		Doğu	Kuzey		
2102	Murat Nehri – Palu	39 55 52	38 41 25	852	25515,6
2115	Göksu Nehri – Malpınarı	38 09 32	37 29 22	390	3998,8
2119	Fırat Nehri – Kemah Boğazı	39 23 37	39 41 02	1123	10356,0
2122	Murat Nehri – Tutak	42 46 49	39 32 19	1552	5882,4
2124	Tohma Suyu – Yazıköy	37 26 35	38 40 23	1193	1256,1
2145	Tohma Suyu – Hisarcık	37 41 08	38 28 34	933	5780,8
2151	Fırat Nehri – Demirkapı	40 10 05	39 34 45	1355	8185,6
2156	Fırat Nehri – Bağıştaş	38 27 04	39 26 05	865	15562,0
2158	Bingöl Çayı-A.R.Paşa Köp.	41 29 14	39 06 30	1310	1577,6
2162	Fırat Nehri – Eriç	38 57 02	39 35 06	1000	12260,7
2164	Göynük Çayı –Çayağzı	40 33 17	38 48 31	990	2232,0
2174	Murat Nehri – Akkonak	41 31 11	39 02 29	1285	17435,1
2176	Tacik Deresi – Mutu Boğazı	39 52 15	39 25 29	1225	94,4
2177	Hıms Çayı – Adıvar	42 10 06	39 13 10	1452	2995,3
2178	Göynük Çayı – Devecik köprü	40 51 45	39 04 43	1579	437,5
2181	Arabalı Deresi – Tutak	42 49 35	39 31 31	1615	117,3
2194	Değirmendere Çayı – Çanakçı	38 06 35	37 30 42	444	949,7

3.2 . Çalışmanın Yapılış Şekli

Çalışmada 17 adet akım gözlem istasyonlarından bir birleri ile ilişkileri göz önüne alınmış özellikle memba-mansap ilişkisine bakılarak membadaki akım gözlem istasyonunun günlük ortalama akım verilerini kullanarak mansaptaki istasyonun günlük akım verilerinin tahmin edilmesine çalışılmıştır. Her istasyonun akım verileri t anından t-3 anına kadar ayrı ayrı veri sütunu haline dönüştürülmüş, bugünkü (Q_t) akım değerini tahmin edebilmek için üç gün öncesine kadarki akım (O_{t-1} , Q_{t-2} , Q_{t-3}) verileri modellere giriş olarak kullanılmıştır. Memba–Mansap ilişkisi içindeki istasyonların ortak çalışma periyotları göz önüne alınarak toplam verinin %60’ı kurulacak modellerin kalibre aşamasında, geriye kalan verilerin de %20’si değerlendirme, %20’si de test edilmesinde kullanılacak şekilde kısımlara ayrılmıştır.

Tablo 3.2. Giriş verilerine ait özel istatistik parametreler

İstasyonlar No	Veriler	Xort (m ³ /s)	Sx (m ³ /s)	Cv (S/X)	Csx (m ³ /s)	Xmax (m ³ /s)	Xmin (m ³ /s)
2102	Tüm Veri	245.00	354.760	1.448	2.938	3291.00	12.10
	Eğitim	247.58	360.495	1.456	3.108	3291.00	18.20
	Test	261.28	374.432	1.433	2.630	2631.00	25.20
	Değerlendirme	221.57	315.762	1.425	2.623	2200.00	12.10
2115	Tüm Veri	15.60	55.670	3.569	5.260	1703.00	1.70
	Eğitim	31.99	31.558	0.986	3.221	298.00	3.38
	Test	19.60	18.839	0.961	1.869	104.00	1.73
	Değerlendirme	31.53	29.295	0.929	1.493	162.00	3.20
2119	Tüm Veri	79.20	90.330	1.141	2.770	743.00	12.30
	Eğitim	77.92	86.977	1.116	2.769	743.00	14.60
	Test	83.19	96.171	1.156	2.536	734.00	15.70
	Değerlendirme	78.55	93.330	1.188	2.989	670.00	12.30
2122	Tüm Veri	46.70	72.030	1.542	3.007	821.00	2.00
	Eğitim	36.79	55.064	1.497	2.599	397.00	1.97
	Test	62.99	91.025	1.445	2.881	821.00	7.05
	Değerlendirme	55.11	83.232	1.510	2.521	496.00	5.05
2124	Tüm Veri	7.90	4.310	0.546	4.175	66.00	0.77
	Eğitim	8.83	4.736	0.536	4.505	66.00	3.42
	Test	7.42	2.667	0.359	4.714	54.80	4.60
	Değerlendirme	5.58	3.275	0.587	1.951	39.40	0.77
2145	Tüm Veri	23.00	16.490	0.717	10.424	801.00	2.40
	Eğitim	25.38	19.146	0.754	10.599	801.00	2.40
	Test	21.10	11.817	0.560	3.399	137.00	9.68
	Değerlendirme	18.01	9.270	0.515	3.265	123.00	7.88
2151	Tüm Veri	58.90	76.060	1.291	2.721	712.00	1.93
	Eğitim	56.97	78.315	1.375	2.707	672.00	1.93
	Test	60.00	72.225	1.204	2.885	615.00	9.00
	Değerlendirme	62.65	70.139	1.119	2.801	712.00	9.00
2156	Tüm Veri	144.20	122.190	0.847	2.833	1179.00	12.00
	Eğitim	140.90	113.543	0.806	2.903	1179.00	12.00
	Test	157.35	138.286	0.879	2.590	1137.00	59.10
	Değerlendirme	140.29	127.157	0.906	2.837	980.00	54.80
2158	Tüm Veri	18.40	28.310	1.539	2.998	338.00	1.30
	Eğitim	18.69	29.746	1.591	3.354	338.00	1.30
	Test	16.36	25.932	1.585	2.960	189.00	1.40
	Değerlendirme	19.98	27.561	1.379	2.080	177.00	1.91
2162	Tüm Veri	106.10	94.980	0.895	2.355	801.00	28.50
	Eğitim	112.15	105.857	0.944	2.262	801.00	33.50
	Test	91.32	63.495	0.695	1.301	283.00	28.50
	Değerlendirme	97.17	65.941	0.679	1.285	295.00	38.50
2164	Tüm Veri	33.60	58.370	1.737	3.576	639.00	0.45
	Eğitim	33.91	59.674	1.760	3.859	639.00	0.45
	Test	35.03	59.585	1.701	2.998	541.00	1.12
	Değerlendirme	31.19	53.308	1.709	3.222	552.00	1.45
2174	Tüm Veri	134.90	193.210	1.432	2.719	1485.00	8.36
	Eğitim	126.62	181.943	1.437	2.847	1259.00	8.36
	Test	128.67	204.512	1.589	3.041	1485.00	9.54
	Değerlendirme	157.97	201.862	1.278	2.178	1384.00	19.60

Tablo 3.2. (Devamı) .Günlük akış verilerinin özel istatistik parametreleri

İstasyonlar No	Veriler	X _{ort} (m ³ /s)	S _x (m ³ /s)	C _v (S/X)	C _{sx} (m ³ /s)	X _{max} (m ³ /s)	X _{min} (m ³ /s)
2177	Tüm Veri	29.10	38.810	1.334	2.913	329.00	2.30
	Eğitim	31.08	41.941	1.349	2.901	329.00	2.90
	Test	23.14	34.970	1.511	3.425	251.00	2.30
	Değerlendirme	31.09	35.277	1.135	2.314	296.00	6.05
2178	Tüm Veri	7.40	12.190	1.647	2.678	80.80	0.47
	Eğitim	8.08	13.183	1.632	2.645	80.80	0.47
	Test	6.46	10.375	1.606	2.315	57.30	0.55
	Değerlendirme	6.04	9.802	1.623	2.579	48.90	0.82
2181	Tüm Veri	1.30	2.790	2.146	5.277	37.90	0.13
	Eğitim	1.08	2.385	2.211	5.479	29.40	0.13
	Test	1.62	3.668	2.263	5.204	37.90	0.18
	Değerlendirme	1.39	2.695	1.934	3.457	20.50	0.17
2194	Tüm Veri	2.60	2.680	1.031	6.485	47.30	0.09
	Eğitim	3.25	3.373	1.039	5.893	47.30	0.09
	Test	1.75	1.146	0.656	0.414	5.78	0.16
	Değerlendirme	2.03	1.709	0.841	2.387	12.20	0.41

Verilerin tüm değerleri ile beraber eğitim, test ve değerlendirme aşamasındaki özet istatistik parametreleri Tablo 3.2’de verilmiştir. Tabloda x_{ort} , s_x , c_v , c_{sx} , x_{min} , x_{max} sırasıyla verilerin ortalamasını, standart sapmasını, değişim katsayısını, çarpıklık katsayısını, minimum ve maksimum değerlerini göstermektedir. Tüm verilere bakıldığında çarpıklık katsayısının yüksek olduğu, akım verilerinin çarpık bir dağılıma sahip olduğu, normal dağılımdan uzak olduğu açıkça görülmektedir. Bazı istasyonlarda test aşamasındaki maksimum akım verileri eğitime aşamasındakinden daha büyüktür. Bu durum test aşamasında pik değerlerin tahmin edilmesini zorlaştırmaktadır.

Seçilen her ikili akarsu gözlem istasyonu için 4 ayrı model oluşturulmuştur. Bu modeller;

- Çoklu Doğrusal Regresyon (ÇDR),
- Dalgacık Dönüşümü Çoklu Doğrusal Regresyon (DDÇDR),
- Çok Katmanlı Yapay Sinir Ağı (ÇKYSA),
- Radyal Tabanlı Yapay Sinir Ağı (RTYSA).

Modellerin tahmin sonuçları karekök ortalama karesel hata (KOKH), ortalama mutlak hata (OMH) ve belirginlik katsayısı (R^2) kriterlerine göre karşılaştırılmıştır. KOKH değeri Eşitlik (2.20) ve OMH değeri de Eşitlik (2.21) ile hesaplanmıştır.

Her model için 4 kombinezon (KOM) oluşturulmuş, oluşturulan kombinezonlardan en iyi model olarak en küçük KOKH ve OMH değerleri ile en büyük R^2 değerlerine sahip model seçilmiş ve koyu renk ile gösterilmiştir.

Çalışmada analizler Matlab programı ile yapılmıştır. Matlab programında her bir yapay zeka yöntemi için (ÇDR, DDÇDR, ÇKYSA, RTYSA) ayrı bir program hazırlanmıştır.

YSA yöntemleri uygulanmadan önce veriler Eşitlik (3.3) ile $[0.2, 0.8]$ aralığında normalize edilmiştir. Bu denklemde c ve d değerleri sırasıyla 0.6 ve 0.2 olarak seçilmiştir.

$$c \cdot \frac{x - x_{\min}}{x_{\max} - x_{\min}} + d \quad (3.3)$$

Kullanılan her ağ bir girdi katmanı, bir ara tabaka (gizli katman) ve çıktı katmanı olmak üzere 3 katmandan meydana gelmektedir. Analiz sırasında ileri beslemeli geri yayılım yapay sinir ağı yönteminde her bir kombinasyon için en iyi sonucu vermeye yönelik farklı ara tabaka hücre sayısı kullanılmıştır. Bu ara tabaka hücre sayıları, deneme programı yardımıyla bulunmuştur. Yine RTYSA yönteminde de ara tabaka hücre sayısı ve sprit katsayısı kullanılmış ve bu değerler yine deneme programı yardımıyla belirlenmiştir. Bu yöntemlerin her biri için ayrı denklem, katsayı ve ara tabaka hücre sayısı kullanılması her bir kombinasyonun ayrı bir sistemi olduğunu göstermektedir. Hücrelerde aktivasyon fonksiyonu olarak Logaritma Sigmoid ve Lineer fonksiyon kullanılmıştır.

3.3. Elde Edilen Bulgular ve Grafikler

Bu bölümde yapılan çalışma sonucunda elde edilen bulgular tüm istasyonlar için her bir modelde (ÇDR, DDÇDR, ÇKYSA, RTYSA) ayrı ayrı bağımsız olarak bulunmuş bölüm içinde her biri kısa değerlendirmeler halinde verilmiştir.

ÇDR, DDÇDR, ÇKYSA, RTYSA yöntemlerinden oluşturulan modellere günlük akım verileri ile farklı girdi kombinezonları uygulanmıştır.

1. Kombinezon (KOM1) için bir girdi vektörü; t günündeki akım,
2. Kombinezon (KOM2) için iki girdi vektörü; t günündeki ve $t-1$ günündeki akım,
3. Kombinezon (KOM3) için üç girdi vektörü; t günündeki, $t-1$ günündeki ve $t-2$ günündeki akım,

4. Kombinezon(KOM4) için dört girdi vektörü; t günündeki, $t-1$ günündeki, $t-2$ günündeki ve $t-3$ günündeki akımdan oluşan 4 değişik kombinezon denenmiştir.

Membada bulunan akarsu gözlem istasyonunun günlük ortalama akım verilerini kullanarak modelin girdi kombinezonlarını oluşturan değerlerde;

O_t = t anındaki akış (m^3/s) değeri,

O_{t-1} = $t-1$ anındaki (1 gün önceki) akış (m^3/s) değeri,

Q_{t-2} = $t-2$ anındaki (2 gün önceki) akış (m^3/s) değeri,

Q_{t-3} = $t-3$ anındaki (3 gün önceki) akış (m^3/s) değeri göstermektedir.

Yukarı Fırat bölümünde Fırat Nehri üzerinde bulunan 2156 no'lu Bağıştaş Akarsu Gözlem İstasyonu 865 m kotunda Bağıştaş Devlet Demir Yolları İstasyonu'nun 3 km batısındadır. 01.10.1968'den günümüze kadar tüm verileri kesintisiz olarak mevcuttur. Kuş uçuşu 57 km membasında 1000 m kotunda 2162 no'lu Eriç Akarsu Gözlem İstasyonu vardır. 01.10.2003'ten bu güne verileri mevcuttur. Eriç Akarsu Gözlem İstasyonu'nun yaklaşık 50 km (kuş uçuşu) membasında 1123 m kotunda 2119 no'lu Kemah Boğazı Akarsu Gözlem İstasyonu vardır. 01.10.1955'ten günümüze kadar değerleri olmakla beraber 1988-1994 su yılları arasındaki değerler eksiktir. Kemah Boğazının yaklaşık 87 km (kuş uçuşu) membasında 1355 m kotunda 2151 no'lu Demirkapı Akarsu Gözlem İstasyonu vardır. İki istasyonun arasında yan kol üzerinde 1225 m kotunda 2176 no'lu Mutu Boğazı Akarsu Gözlem İstasyonu mevcuttur. Bu istasyonların memba mansap ilişkileri göz önüne alınarak mabadaki istasyonun verilerini kullanarak mansaptaki istasyonun akım verilerini tahmin etmek için ikili modeller oluşturulmuştur.

Oluşturulan modeller sıra ile Bağıştaş (2156)- Kemah Boğazı (2119), Kemah Boğazı (2119)-Eriç (2162), Eriç (2162)-Bağıştaş (2156), Demirkapı (2151)-Kemah Boğazı (2119), Mutu Boğazı (2176)-Kemah Boğazı (2119)'dir. Bu modellerin test aşamasındaki performans değerleri tablolar halinde verilmiş, her modelin en iyi performansı gösteren kombinezonu tabloda koyu renkle gösterilmiş ve en iyi kombinezonların değerlendirme aşamasındaki performanları da tablolar halinde verilmiştir. Değerlendirme aşamasında modellerle bulunan değerler ile istasyondaki ölçülmüş (gözlenen) değerlerin karşılaştırılması yaptırılarak saçılma diyagramları oluşturulmuş ve mukayese edilmiştir.

Oluşturulan bu modelde mansapta bulunan Bağıştaş (2156) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Kemah Boğazı

(2119) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2119 ve 2156 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.1968-30.09.1987 tarihleri arasındaki toplam 19 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 11 yıllık (1969-1979) verilerini modellerin kalibre aşamasında, 4 yıllık (1980-1983) verileri test aşamasında, 4 yıllık (1984-1987) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.3'te verilmiştir.

Tablo 3.3. Bağıştaş (2156) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2119-2156)


METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		39,53	35,26	0,97
	Q _t , Q _{t-1}	KOM2		39,18	34,98	0,97
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		39,16	34,98	0,97
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		39,13	34,96	0,97
DDÇDR	Q _t	KOM1		40,88	35,81	0,97
	Q _t , Q _{t-1}	KOM2		39,15	35,09	0,97
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		39,21	35,11	0,97
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		39,08	35,08	0,97
ÇKYSA	Q _t	KOM1	1, 8, 1	26,92	13,84	0,98
	Q _t , Q _{t-1}	KOM2	2, 10, 1	25,79	13,54	0,98
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 10, 1	26,59	14,57	0,98
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 8, 1	25,06	13,27	0,98
RTYSA	Q _t	KOM1	1, 20, 0.1, 1	27,49	14,27	0,98
	Q _t , Q _{t-1}	KOM2	2, 20, 0.2, 1	26,67	14,28	0,98
	Q_t, Q_{t-1}, Q_{t-2}	KOM3	3, 19, 0.3, 1	26,25	14,32	0,98
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 19, 1.3, 1	26,36	14,55	0,98

Tablo 3.3'te de görüldüğü gibi yapılan analizlerde en iyi sonuçlar ÇKYSA-KOM4, RTYSA-KOM3, DDÇDR-KOM4, CDR-KOM4 olarak sıralanmıştır. Test aşamasında tüm modellerde 2-3 gün öncesine kadarki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür. Her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.4'te verilmiştir.

Tablo 3.4. Bağıstaş (2156) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2119-2156)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	37,46	29,62	0,96
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	37,14	29,53	0,96
ÇKYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4, 8, 1	26,55	15,97	0,96
RTYSA	Q_t, Q_{t-1}, Q_{t-2}	KOM3 3, 19, 0.3, 1	25,86	15,15	0,98

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Bağıstaş (2156) istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.4'te gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin RTYSA-KOM3 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 3, gizli tabakadaki hücre sayısı 19, çıktı tabakası hücre sayısı 1 ve sprit katsayısı da 0.3 olarak bulunmuştur.



Şekil 3.4. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2119-2156)

Diğer bir modelde mansapta bulunan Eriç (2162) Akarsu Gözlem İstasyonunun akım verilerini tahmin edebilmek için membasında bulunan Kemah Boğazı (2119) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2119 ve 2162 no'lu AGİ'lerin ortak zamanda çalışmış olduğu toplam 6 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 4 yıllık verilerini modellerin kalibre aşamasında, 1 yıllık verileri test aşamasında, 1 yıllık verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.5'te verilmiştir.

Tablo 3.5. Eriç (2162) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2119-2162)

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		12,59	9,85	0,98
	Q _t , Q _{t-1}	KOM2		12,53	9,78	0,98
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		12,47	9,74	0,98
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		12,46	9,73	0,98
DDÇDR	Q _t	KOM1		13,10	10,41	0,98
	Q _t , Q _{t-1}	KOM2		12,59	9,90	0,98
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		12,42	9,74	0,98
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		12,52	9,82	0,98
ÇKYSA	Q _t	KOM1	1, 7, 1	7,85	5,50	0,99
	Q _t , Q _{t-1}	KOM2	2, 10, 1	8,05	6,12	0,99
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 8, 1	7,98	6,18	0,99
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 8, 1	8,05	6,31	0,98
RTYSA	Q _t	KOM1	1, 9, 0.1, 1	7,97	5,80	0,99
	Q _t , Q _{t-1}	KOM2	2, 19, 0.1, 1	7,98	5,91	0,99
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 20, 0.1, 1	8,02	6,16	0,99
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 19, 0.2, 1	8,43	6,11	0,99


Tablo 3.5'te de görüldüğü gibi yapılan analizlerde en iyi sonuçlar ÇKYSA-KOM1, RTYSA-KOM1, CDR-KOM4, DDÇDR-KOM4 olarak sıralanmıştır. Test aşamasında modellerde farklı zamanlardaki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zeka yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Çalışılan her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.6’da verilmiştir.

Tablo 3.6. Eriç (2162) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2119-2162)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	14.79	10.67	0.98
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	14.93	10.69	0.97
ÇKYSA	Q_t	KOM1	1, 7, 1	7.35	0.98
RTYSA	Q_t	KOM1	1, 9, 0.1, 1	7.34	0.97

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında bulunan değerler Eriç(2162) istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek şekil 3.5’te gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇKYSA-KOM1 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 1, gizli tabakadaki hücre sayısı 7, çıktı tabakası hücre sayısı 1 olarak bulunmuştur.



Şekil 3.5. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2119-2162)

Burada da Bağıştaş (2156) istasyonunun Eriç (2162) ilişkisine bakılmıştır. Mansapta bulunan Bağıştaş (2156) Akarsu Gözlem İstasyonunun akım verilerini tahmin edebilmek için membasında bulunan Eriç (2162) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2162 ve 2156 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar da toplam 6 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 4 yıllık verilerini modellerin kalibre aşamasında, 1 yıllık verileri test aşamasında, 1 yıllık verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.7'de verilmiştir.

Tablo 3.7. Bağıştaş (2156) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2162-2156)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²	
ÇDR	Q _t	KOM1	22,80	16,99	0,96	
	Q _t , Q _{t-1}	KOM2	22,84	17,00	0,96	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	22,86	17,01	0,96	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	22,87	17,01	0,96	
DDÇDR	Q _t	KOM1	23,31	17,07	0,96	
	Q _t , Q _{t-1}	KOM2	22,90	16,99	0,96	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	22,86	16,93	0,96	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	22,81	16,91	0,96	
ÇKYSA	Q _t	KOM1	1, 10, 1	22,01	16,84	0,96
	Q _t , Q _{t-1}	KOM2	2, 7, 1	21,59	16,38	0,96
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 8, 1	21,38	16,30	0,96
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 4, 1	21,56	16,58	0,96
RTYSA	Q _t	KOM1	1, 1, 0.3, 1	20,75	16,28	0,96
	Q _t , Q _{t-1}	KOM2	2, 20, 0.1, 1	21,58	16,50	0,96
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 2, 0.5, 1	21,34	16,86	0,96
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 20, 0.5, 1	21,74	16,71	0,96


Tablo 3.7 incelendiğinde yapılan analizlerde en iyi sonuçların RTYSA-KOM1, ÇKYSA-KOM3, DDÇDR-KOM4, ÇDR-KOM1 olarak sıralandığı görülmektedir. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zeka yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür. Burada her bir metodun test aşamasındaki en düşük

KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.8’de verilmiştir.

Tablo 3.8. Bağıştaş (2156) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2162-2156)

METOT		GİRDİLER	MODEL	KOKH (m³/s)	OMH (m³/s)	R²
ÇDR	Q _t	KOM1		34.28	30.37	0.96
DDÇDR	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		34.19	30.22	0.96
ÇKYSA	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 8, 1	20.76	14.07	0.97
RTYSA	Q _t	KOM1	1, 1, 0.3, 1	18.72	13.07	0.97

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Bağıştaş istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek şekil 3.6’da gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin RTYSA-KOM1 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 1, gizli tabakadaki hücre sayısı 1, çıktı tabakası hücre sayısı 1 ve sprit katsayısı da 0.3 olarak bulunmuştur.



Şekil 3.6. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2162-2156)

Bir diğer model olarakta Kemah Boğazı (2119) – Demirkapı (2151) ikilisi oluşturulmuş, mansapta bulunan Kemah Boğazı (2119) Akarsu Gözlem İstasyonunun akım verilerini tahmin edebilmek için membasında bulunan Demirkapı (2151) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2119 ve 2151 no’lu AGİ’lerin ortak zamanda çalışmış olduğu yıllar olan toplam 24 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 12 yıllık (1971-1987) verilerini modellerin kalibre aşamasında, 6 yıllık (1995-2000) verileri test aşamasında, 6 yıllık (2001-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.9’da verilmiştir.

Tablo 3.9. Kemah Boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2151-2119).

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		19,32	15,12	0,97
	Q _t , Q _{t-1}	KOM2		19,21	14,92	0,97
	Q_t, Q_{t-1}, Q_{t-2}	KOM3		19,20	14,90	0,97
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		19,22	14,86	0,97
DDÇDR	Q _t	KOM1		19,61	15,13	0,97
	Q _t , Q _{t-1}	KOM2		19,01	14,84	0,97
	Q_t, Q_{t-1}, Q_{t-2}	KOM3		18,92	14,75	0,97
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		19,09	14,84	0,97
ÇKYSA	Q _t	KOM1	1, 1, 1	15,00	11,08	0,97
	Q_t, Q_{t-1}	KOM2	2, 1, 1	14,75	10,84	0,98
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 6, 1	14,75	10,85	0,97
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 4, 1	15,78	11,52	0,97
RTYSA	Q_t	KOM1	1, 5, 0.3, 1	14,98	11,09	0,97
	Q _t , Q _{t-1}	KOM2	2, 10, 0.5, 1	15,62	11,36	0,97
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 8, 0.5, 1	15,33	11,26	0,97
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 8, 0.5, 1	15,80	11,43	0,97


Tablo 3.9’da görüldüğü gibi yapılan analizlerde en iyi sonuçlar RTYSA-KOM1, ÇKYSA-KOM2, DDÇDR-KOM3, ÇDR-KOM3 olarak sıralanmıştır. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.10’da verilmiştir.

Tablo 3.10. Kemah Boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2151-2119).

METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t , Q _{t-1} , Q _{t-2}	KOM3		17.22	12.76	0.98
DDÇDR	Q _t , Q _{t-1} , Q _{t-2}	KOM3		17.08	12.73	0.98
ÇKYSA	Q_t, Q_{t-1}	KOM2	2, 1, 1	14.60	9.08	0.98
RTYSA	Q _t	KOM1	1, 5, 0.3, 1	15.2	9.36	0.98

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Kemah Boğazı istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.7’de gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇKYSA-KOM2 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 2, gizli tabakadaki hücre sayısı 1, çıktı tabakası hücre sayısı 1 olarak bulunmuştur.



Şekil 3.7. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2151-2119)

Başka bir model olarakta Kemah Boğazı(2119) istasyonunun Mutu Boğazı(2176) istasyonu ile olan ilişkisi incelenmiş, mansapta bulunan Kemah Boğazı(2119) Akarsu Gözlem İstasyonunun akım verilerini tahmin edebilmek için membasında bulunan Mutu Boğazı(2176) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2119 ve 2176 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan toplam 24 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 6 yıllık (1995-2000) verilerini modellerin kalibre aşamasında, 3 yıllık (2001-2003) verileri test aşamasında, 3 yıllık (2004-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.11'de verilmiştir.

Tablo 3.11. Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2176-2119)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²	
ÇDR	Q _t	KOM1	30,63	20,66	0,83	
	Q _t , Q _{t-1}	KOM2	27,37	19,37	0,86	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	26,40	18,83	0,87	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	26,23	18,56	0,87	
DDÇDR	Q _t	KOM1	28,20	19,68	0,85	
	Q _t , Q _{t-1}	KOM2	27,17	19,28	0,86	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	26,24	18,68	0,87	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	26,07	18,52	0,87	
ÇKYSA	Q _t	KOM1	1, 2, 1	27,88	15,66	0,84
	Q _t , Q _{t-1}	KOM2	2, 2, 1	25,20	15,12	0,87
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 1, 1	25,02	16,55	0,87
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 1, 1	24,91	16,42	0,87
RTYSA	Q _t	KOM1	1, 15, 1.8, 1	27,82	15,54	0,84
	Q _t , Q _{t-1}	KOM2	2, 1, 0.5, 1	24,70	15,24	0,87
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 1, 0.5, 1	23,47	14,57	0,88
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 1, 0.7, 1	23,25	14,93	0,88


Tablo incelendiğinde yapılan analizlerde en iyi sonuçların RTYSA-KOM4, ÇKYSA-KOM4, DDÇDR-KOM4, ÇDR-KOM4 olarak sıralandığı görülmektedir. Test aşamasında tüm modellerde aynı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zeka yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Her metodun test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 performans değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları çıkartılıp ve Tablo 3.12’de verilmiştir.

Tablo 3.12. Kemah boğazı (2119) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2176-2119)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	48.40	29.72	0.78
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	48.19	29.66	0.78
ÇKYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4, 1, 1	46.80	27.83	0.78
RTYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4, 1, 0.7, 1	46.95	26.47	0.78

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Kemah Boğazı istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.8’de gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin RTYSA-KOM4 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 4, gizli tabakadaki hücre sayısı 1, çıktı tabakası hücre sayısı 1, sprit katsayısı 0.7 olarak bulunmuştur.



Şekil 3.8.ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2176-2119)

Orta Fırat bölümünde Fırat Nehrinin ana kollarından olan Murat Nehri üzerinde bölgenin su potansiyelini belirlemek amacı ile çok sayıda AGİ kurulmuştur. Bu istasyonların dağılımı Şekil 3.3'te görülmektedir. Burada görülen istasyonlardan 2102 no'lu Palu Akarsu Gözlem İstasyonu 852 m kotunda Elazığ'ın Palu ilçesindedir. İstasyonda kule limnigraf tesisi kurulu olup 01.10.1967 yılından günümüze kadar tüm verileri kesintisiz olarak mevcuttur. 2007 yılından sonra elektronik limnigraf kurulmuş olup 15 dakikalık akım değerleri mevcut bulunmaktadır. Kuş uçuşu 57 km membasında Göynük çayı üzerinde 990 m kotunda 2164 no'lu Çayağzı Akarsu Gözlem İstasyonu, aynı çay üzerinde 1579 m kotunda, kuş uçuşu 95 km membasında 01.10.1986 dan 30.09.1992 yılına kadar çalıştırılan 2178 no'lu Devecik köprü istasyonu vardır. Devecik köprü istasyonu 04.11.1992 tarihinde kapatılmıştır. Palu istasyonunun kuş uçuşu 150 km membasında Murat Nehri üzerinde Muş ili sınırları içerisinde 1285 m kotunda 2174 no'lu Akkonak istasyonu vardır. Bingöl çayı üzerinde Akkonak istasyonunun 10 km membasında 1310 m kotunda 2158 no'lu Abdurrahman Paşa köprüsü istasyonu vardır. Hınıs Çayı üzerinde 1452 m kotunda Malazgirt-Hınıs yolu üzerinde 2177 no'lu Adıvar istasyonu vardır. İstasyonun Akkonak istasyonuna mesafesi kuş uçuşu 60 km civarındadır. 01.10.1985 den günümüze kadar akım verileri mevcuttur. Ağrı ili sınırları içerisinde 1618 m kotunda 2122 no'lu Tutak istasyonu ve 6 km membasında yan kol olan Arabalı Deresi üzerinde 1615 m kotunda bulunan Arabalı deresi – Tutak istasyonu bulunmaktadır.

Tüm bu istasyonların konumlarına bakılarak membada bulunan istasyonun akım verileri kullanılarak mansapta bulun istasyonun akım verilerini tahmin edebilmek için sıra ile ikişerli modeller oluşturulmuştur.

Oluşturulan modeller, Palu (2102)-Çayağzı (2164), Çayağzı (2164)-D.Köprü (2178), Palu (2102)-Akkonak (2174), Akkonak (2174)-A.Paşa Köprüsü (2158), Akkonak (2174)-Adıvar (2177) ve Tutak (2122)-Tutak (2181) ikilileridir. Bu modellerin test ve değerlendirme aşamasındaki performanları bulunmuş ve test aşamasındaki en iyi kombinezonların değerlendirme aşamasındaki performans değerleri tablolar halinde çıkarılmıştır. Burada modellerle bulunan değerlerin ölçülmüş (gözlenen) değerler ile karşılaştırılması yapılarak saçılma diyagramları oluşturulmuştur.

Oluşturulan ilk modelde mansapta bulunan Palu (2102) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Çayağzı (2164) Akarsu Gözlem İstasyonunun akım verileri modelin girdisi olarak kullanılmıştır. Çalışmada 2164 ve 2102 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.12.1969-30.09.2006

tarihleri arasındaki toplam 38 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 22 yıllık (1969-1990) verilerini modellerin kalibre aşamasında, 8 yıllık (1991-1998) verileri test aşamasında, 8 yıllık (1999-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.13'te verilmiştir.

Tablo 3.13. Palu (2102) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki OKH, OMH ve R^2 değerleri (2164-2102)

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		155,44	85,50	0,85
	Q _t , Q _{t-1}	KOM2		128,75	74,68	0,90
	Q _b , Q _{t-1} , Q _{t-2}	KOM3		115,65	69,18	0,92
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		109,52	66,04	0,92
DDÇDR	Q _t	KOM1		139,19	79,87	0,88
	Q _t , Q _{t-1}	KOM2		126,37	74,05	0,90
	Q _b , Q _{t-1} , Q _{t-2}	KOM3		112,91	67,77	0,92
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		110,23	66,12	0,92
ÇKYSA	Q _t	KOM1	1, 5, 1	133,24	67,72	0,87
	Q _t , Q _{t-1}	KOM2	2, 5, 1	113,96	60,06	0,91
	Q _b , Q _{t-1} , Q _{t-2}	KOM3	3, 1, 1	106,58	56,02	0,92
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 2, 1	102,69	53,86	0,92
RTYSA	Q _t	KOM1	1, 8, 1.6, 1	133,88	66,68	0,87
	Q _t , Q _{t-1}	KOM2	2, 10, 0.9, 1	115,65	59,53	0,90
	Q _b , Q _{t-1} , Q _{t-2}	KOM3	3, 10, 0.6, 1	106,65	55,40	0,92
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 10, 0.8, 1	100,87	53,34	0,93


Tablo 3.13'te de görüldüğü gibi yapılan analizlerde en iyi sonuçlar RTYSA-KOM4, ÇKYSA-KOM4, DDÇDR-KOM4, ÇDR-KOM4 olarak sıralanmıştır. Test aşamasında tüm modellerde aynı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Her metotta test aşamasındaki performanslarında en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları Tablo 3.14'te verilmiştir.

Tablo 3.14. Palu (2102) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2164-2102)

METOT	GİRDİLER	MODEL	KOKH (m³/s)	OMH (m³/s)	R²	
ÇDR	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	104.80	58.56	0.90	
DDÇDR	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	104.25	58.69	0.90	
ÇKYSA	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 2, 1	99.36	56.15	0.90
RTYSA	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 10, 0.8, 1	100.79	56.59	0.90

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Palu istasyonunun gözlenmiş değerleri ile mukayese edilmiş, değerlerin saçılma diyagramları çizdirilerek Şekil 3.9’da gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇKYSA-KOM4 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 4, gizli tabakadaki hücre sayısı 2, çıktı tabakası hücre sayısı 1 olarak bulunmuştur.



Şekil 3.9. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2164-2102)

İkinci modelimizde mansapta bulunan Çayağzı (2164) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Devecik Köprü (2178) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2178 ve 2164 nolu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.1987-30.09.1992 tarihleri arasındaki toplam 6 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 4 yıllık (1987-1990) verilerini modellerin kalibre aşamasında, 1 yıllık (1991) verileri test aşamasında, 1 yıllık (1992) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.15'te verilmiştir.

Tablo 3.15. Çayağzı (2164) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2178-2164)

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		29,35	12,93	0,77
	Q _t , Q _{t-1}	KOM2		28,50	13,02	0,78
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		27,54	12,69	0,80
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		26,56	12,23	0,81
DDÇDR	Q _t	KOM1		33,19	14,14	0,70
	Q _t , Q _{t-1}	KOM2		29,19	13,08	0,77
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		27,96	12,58	0,79
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		27,30	12,25	0,80
ÇKYSA	Q _t	KOM1	1, 3, 1	29,77	14,25	0,79
	Q _t , Q _{t-1}	KOM2	2, 5, 1	27,22	13,95	0,82
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 6, 1	24,84	13,31	0,84
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 6, 1	24,48	13,13	0,85
RTYSA	Q _t	KOM1	1, 1, 0.5, 1	29,49	14,81	0,76
	Q _t , Q _{t-1}	KOM2	2, 14, 0.2, 1	27,43	14,33	0,80
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 16, 0.2, 1	24,82	13,11	0,83
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 20, 0.7, 1	24,54	14,56	0,84


Tablo 3.15 incelendiğinde yapılan analizlerde en iyi sonuçların RTYSA-KOM4, ÇKYSA-KOM4, DDÇDR-KOM4, ÇDR-KOM4 olarak sıralandığı görülmüştür. Test aşamasında tüm modellerde aynı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür. Çalışılan her metotta test aşamasındaki en düşük KOKH, en

düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları görülmüş ve Tablo 3.16’da verilmiştir.

Tablo 3.16. Çayağzı(2164) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2178-2164)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	21.52	10.49	0.85
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	21.05	10.50	0.86
ÇKYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4, 6, 1	25.03	14.62	0.78
RTYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4, 20, 0.7, 1	24.42	14.95	0.79

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Çayağzı istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizdirilerek Şekil 3.10’da gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇDR-KOM4 olduğu görülmüştür. Bu modelde test aşamasındaki performans değerleri yüksek olan model değerlendirme aşamasındaki performans değerlerine bakıldığında daha düşük olduğu görülmektedir.



Şekil 3.10. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2178-2164)

Bir diğerk modelde de mansapta bulunan Akkonak (2174) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Abdurrahman Paşa (2158) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2158 ve 2174 no’lu AGİ’lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.1995-30.09.2006 tarihleri arasındaki toplam 19 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 12 yıllık (1995-2000) verilerini modellerin kalibre aşamasında, 3 yıllık (2001-2003) verileri test aşamasında, 3 yıllık (2004-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.17’de verilmiştir.

Tablo 3.17. Akkonak (2174) istasyonunun akım tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2158-2174)

METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		71,65	32,83	0,94
	Q _t , Q _{t-1}	KOM2		66,01	29,84	0,95
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		65,04	29,03	0,96
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		65,01	28,86	0,96
DDÇDR	Q _t	KOM1		67,37	29,59	0,95
	Q _t , Q _{t-1}	KOM2		64,92	29,49	0,96
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		64,37	28,41	0,96
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		64,43	28,44	0,96
ÇKYSA	Q _t	KOM1	1, 5, 1	64,06	26,02	0,94
	Q _t , Q _{t-1}	KOM2	2, 6, 1	61,71	24,96	0,95
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 2, 1	62,55	25,20	0,95
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 2, 1	62,30	25,16	0,95
RTYSA	Q _t	KOM1	1, 8, 0.1, 1	65,24	26,38	0,94
	Q _t , Q _{t-1}	KOM2	2, 5, 0.1, 1	61,13	34,42	0,95
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 1, 0.4, 1	60,81	24,46	0,95
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 2, 0.5, 1	61,49	26,10	0,96


Tablo 3.17’ye baktığımızda yapılan analizlerde en iyi sonuçlar RTYSA-KOM3, ÇKYSA-KOM2, DDÇDR-KOM3, ÇDR-KOM4 olarak sıralandığı görülmüştür. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür. Her metotta test aşamasındaki en düşük KOKH, en düşük

OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performans değerleri görölüp Tablo 3.18’de verilmiştir.

Tablo 3.18. Akkonak (2174) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2158-2174).

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	70.82	37.95	0.92
DDÇDR	Q_t, Q_{t-1}, Q_{t-2}	KOM3	71.42	37.78	0.92
ÇKYSA	Q_t, Q_{t-1}	KOM2 2, 6, 1	67.75	33.32	0.91
RTYSA	Q_t, Q_{t-1}, Q_{t-2}	KOM3 3, 1, 0.4, 1	65.45	30.64	0.91

Test aşamasındaki en iyi performansların değerlendirme aşamasındaki performanslarına da bakılıp, burada metotlarla bulunan değerler Akkonak istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizdirilerek Şekil 3.11’de gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin RTYSA-KOM3 olduğu görölmüştür. Bu modelde girdi tabakasındaki hücre sayısı 4, gizli tabakadaki hücre sayısı 2, çıktı tabakası hücre sayısı 1, sprit katsayısı 0.5 olarak bulunmuştur.



Şekil 3.11. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2158-2174)

Burada da mansapta bulunan Akkonak (2174) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Adıvar (2177) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2177 ve 2174 nolu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.1994-30.09.2006 tarihleri arasındaki toplam 12 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 6 yıllık (1995-2000) verilerini modellerin kalibre aşamasında, 3 yıllık (2001-2003) verileri test aşamasında, 3 yıllık (2004-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.19'da verilmiştir.

Tablo 3.19. Akkonak (2174) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2177-2174)

METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		79,76	34,27	0,94
	Q _t , Q _{t-1}	KOM2		79,59	33,85	0,94
	Q_t, Q_{t-1}, Q_{t-2}	KOM3		79,05	33,52	0,95
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		79,07	33,38	0,95
DDÇDR	Q _t	KOM1		79,61	33,48	0,94
	Q _t , Q _{t-1}	KOM2		78,82	33,64	0,95
	Q_t, Q_{t-1}, Q_{t-2}	KOM3		78,32	33,08	0,95
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		78,34	33,06	0,95
ÇKYSA	Q _t	KOM1	1, 5, 1	73,76	34,44	0,95
	Q _t , Q _{t-1}	KOM2	2, 7, 1	74,01	33,06	0,94
	Q_t, Q_{t-1}, Q_{t-2}	KOM3	3, 9, 1	72,53	33,22	0,95
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 7, 1	73,43	33,09	0,95
RTYSA	Q _t	KOM1	1, 20, 0.1, 1	72,82	33,09	0,95
	Q _t , Q _{t-1}	KOM2	2, 10, 0.2, 1	74,73	35,09	0,94
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 10, 0.2, 1	73,04	34,55	0,95
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 4, 0.2, 1	71,43	35,96	0,93


Tablo 3.19'da görüldüğü gibi yapılan analizlerde en iyi sonuçlar RTYSA-KOM4, ÇKYSA-KOM3, DDÇDR-KOM3, ÇDR-KOM3 olarak sıralanmıştır. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.20’de verilmiştir.

Tablo 3.20. Akkonak (2174) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2177-2174)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²	
ÇDR	Q _t , Q _{t-1} , Q _{t-2}	KOM3	73.44	36.75	0.95	
DDÇDR	Q _t , Q _{t-1} , Q _{t-2}	KOM3	73.65	36.64	0.95	
ÇKYSA	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 9, 1	75.77	35.13	0.93
RTYSA	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 4, 0.2, 1	74.15	37.14	0.93

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Akkonak istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.12’de gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇDR-KOM3 olduğu görülmüştür.



Şekil 3.12. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2177-2174)

Bir diğ er modelde de mansapta bulunan Murat Nehri-Tutak (2122) AGİ akım verilerini tahmin edebilmek i in membasında bulunan Arabalı Dere-Tutak (2181) AGİ akım verileri girdi olarak kullanılmıştır.  alıřmada 2122 ve 2181 no'lu AGİ'lerin ortak zamanda  alıřmıř olduėu yıllar olan 01.10.1997-30.09.2006 tarihleri arasındaki toplam 9 yıllık g nl k ortalama akım deėerleri kullanılmış, bunlardan ilk 5 yıllık (1998-2002) verilerini modellerin kalibre ařamasında, 2 yıllık (2003-2004) verileri test ařamasında, 2 yıllık (2005-2006) verileri de deėerlendirme ařamasında kullanılmıştır. Modellerin test ařamasındaki performans deėerleri olan KOKH, OMH ve R^2 deėerleri ve YSA modellerinin gizli tabakadaki h cre sayıları ve sprit katsayısı Tablo 3.21'de verilmiřtir.

Tablo 3.21. Murat Nehri -Tutak (2122) istasyonunun akım verilerinin tahmininde modellerin test ařamasındaki KOKH, OMH ve R^2 deėerleri (2181-2122)

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		56,06	33,57	0,72
	Q _t , Q _{t-1}	KOM2		55,23	32,85	0,73
	Q _b , Q _{t-1} , Q _{t-2}	KOM3		55,21	32,40	0,72
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		54,01	31,43	0,73
DDÇDR	Q _t	KOM1		57,57	34,35	0,69
	Q _t , Q _{t-1}	KOM2		55,68	32,90	0,72
	Q _b , Q _{t-1} , Q _{t-2}	KOM3		56,04	32,26	0,70
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		54,41	31,24	0,72
ÇKYSA	Q _t	KOM1	1, 2, 1	47,51	21,83	0,81
	Q _t , Q _{t-1}	KOM2	2, 2, 1	46,24	21,49	0,82
	Q _b , Q _{t-1} , Q _{t-2}	KOM3	3, 3, 1	46,22	21,48	0,80
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 3, 1	44,99	20,59	0,85
RTYSA	Q _t	KOM1	1, 6, 0.4, 1	43,46	21,10	0,82
	Q _t , Q _{t-1}	KOM2	2, 14, 0.2, 1	44,13	21,21	0,81
	Q _b , Q _{t-1} , Q _{t-2}	KOM3	3, 16, 0.2, 1	56,73	24,20	0,68
	Q_b, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 20, 0.7, 1	43,14	20,30	0,83


Tablo 3.21'de g r ld ėu gibi yapılan analizlerde en iyi sonu lar RTYSA-KOM4,  KYSA-KOM4, DD DR-KOM4,  DR-KOM4 olarak sıralanmıřtır. Test ařamasında t m modellerde aynı g nlerdeki akım verilerinin girdi olarak kullanıldığ  kombinezonlar en iyi sonucu vermiřtir. Test ařamasında yapay zek  y ntemlerinin  oklu doėrusal regresyon ve dalgacık d n ř ml   oklu doėrusal regresyon analizine g re daha iyi sonu lar verdiėi g r lm řtir. Her metotta test ařamasındaki en d ř k KOKH, en d ř k OMH ve en y ksek

R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.22’de verilmiştir.

Tablo 3.22. Murat Nehri -Tutak (2122) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2181-2122)

METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		50.37	27.53	0.73
DDÇDR	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		49.65	27.00	0.74
ÇKYSA	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 3, 1	43.69	18.98	0.79
RTYSA	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 20, 0.7, 1	43.22	32.03	0.80

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Murat Nehri-Tutak istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.13’te gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇKYSA-KOM4 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 4, gizli tabakadaki hücre sayısı 3, çıktı tabakası hücre sayısı 1 olarak bulunmuştur.



Şekil 3.13. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2181-2122)

Oluşturulan bir başka modelde mansapta bulunan Palu (2102) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan Devecik Köprü (2178) Akarsu Gözlem İstasyonunun akım verileri modele girdi olarak kullanılmıştır. Çalışmada 2119 ve 2156 nolu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan toplam 6 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 4 yıllık verilerini modellerin kalibre aşamasında, 1 yıllık verileri test aşamasında, 1 yıllık verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.23'de verilmiştir.

Tablo 3.23. Palu (2102) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2178-2102)

METOT		GİRDİLER	MODEL	KOKH (m³/s)	OMH (m³/s)	R²
ÇDR	Q _t	KOM1		129,90	66,20	0,86
	Q _t , Q _{t-1}	KOM2		123,08	63,13	0,87
	Q_t, Q_{t-1}, Q_{t-2}	KOM3		121,07	61,64	0,87
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		121,15	61,60	0,87
DDÇDR	Q _t	KOM1		121,00	62,93	0,87
	Q _t , Q _{t-1}	KOM2		121,75	63,03	0,87
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		120,61	61,27	0,87
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4		118,78	60,99	0,88
ÇKYSA	Q _t	KOM1	1, 2, 1	132,42	84,52	0,85
	Q _t , Q _{t-1}	KOM2	2, 2, 1	122,68	64,42	0,86
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 3, 1	114,15	59,76	0,88
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 6, 1	108,88	59,59	0,89
RTYSA	Q _t	KOM1	1, 2, 0.2, 1	129,53	78,59	0,85
	Q _t , Q _{t-1}	KOM2	2, 4, 1.2, 1	120,95	76,23	0,87
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 14, 1.2, 1	111,68	63,11	0,89
	Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}	KOM4	4, 20, 0.9, 1	105,78	64,00	0,90


Tablo 3.23 incelendiğinde yapılan analizlerde en iyi sonuçların RTYSA-KOM4, ÇKYSA-KOM4, DDÇDR-KOM4, ÇDR-KOM3 olarak sıralandığı görülmektedir. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.24’te verilmiştir.

Tablo 3.24. Palu (2102) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2178-2102)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	Q_t, Q_{t-1}, Q_{t-2}	KOM3	115.62	69.27	0.92
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	113.94	68.98	0.92
ÇKYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	4, 6, 1	79.23	0.89
RTYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	4, 20, 0.9, 1	75.81	0.91

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Kemah Boğazı istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.14’te gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin DDÇDR-KOM4 olduğu görülmüştür.



Şekil 3.14. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2178-2102)

Oluşturulan bu modelde Fırat Nehrinin Tohma kolu üzerinde bulunan Hisarcık (2145) istasyonunun verileri tahmin edilmeye çalışılmıştır. Malatya - Darende sınırları içerisinde 933 m kotundaki Hisarcık (2145) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında bulunan 1193 m kotundaki Yazıköy (2124) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2124 ve 2145 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.1962-30.09.2006 tarihleri arasındaki toplam 44 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 26 yıllık (1962-1988) verilerini modellerin kalibre aşamasında, 9 yıllık (1989-1997) verileri test aşamasında, 9 yıllık (1998-2006) verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşamasındaki performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve sprit katsayısı Tablo 3.25'te verilmiştir.

Tablo 3.25. Hisarcık (2145) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2124-2145)

METOT	GİRDİLER		MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t	KOM1		6,07	4,06	0,79
	Q_t, Q_{t-1}	KOM2		6,03	4,06	0,80
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		6,04	4,07	0,80
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		6,05	4,07	0,80
DDÇDR	Q _t	KOM1		6,26	4,14	0,78
	Q_t, Q_{t-1}	KOM2		6,12	4,08	0,79
	Q _t , Q _{t-1} , Q _{t-2}	KOM3		6,19	4,13	0,79
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4		6,17	4,12	0,79
ÇKYSA	Q _t	KOM1	1, 9, 1	6,34	4,27	0,78
	Q _t , Q _{t-1}	KOM2	2, 4, 1	5,99	4,38	0,80
	Q_t, Q_{t-1}, Q_{t-2}	KOM3	3, 8, 1	5,38	3,23	0,82
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 10, 1	7,56	6,39	0,77
RTYSA	Q _t	KOM1	1, 10, 0.5, 1	5,65	3,40	0,79
	Q _t , Q _{t-1}	KOM2	2, 10, 0.5, 1	5,57	3,37	0,80
	Q_t, Q_{t-1}, Q_{t-2}	KOM3	3, 12, 0.5, 1	5,54	3,37	0,81
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 12, 0.5, 1	5,60	3,43	0,80


Tablo 3.25'te görüldüğü gibi yapılan analizlerde en iyi sonuçlar ÇKYSA-KOM3, RTYSA-KOM3, DDÇDR-KOM2, ÇDR-KOM2 olarak sıralanmıştır. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği

görülmüştür. Her metotta test aşamasındaki en düşük KOKH, en düşük OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.26’da verilmiştir.

Tablo 3.26. Hisarcık (2145) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2124-2145)

METOT		GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²
ÇDR	Q _t , Q _{t-1}	KOM2		7.12	5.80	0.53
DDÇDR	Q _t , Q _{t-1}	KOM2		7.10	5.80	0.54
ÇKYSA	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 8, 1	6.30	4.52	0.62
RTYSA	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 12, 0.5, 1	6.63	4.95	0.59

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Hisarcık istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizdirilerek Şekil 3.15’te gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin ÇKYSA-KOM3 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 3, gizli tabakadaki hücre sayısı 8, çıktı tabakası hücre sayısı 1 olarak bulunmuştur.



Şekil 3.15. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2124-2145)

Oluşturulan bir başka modelde de Adıyaman ili sınırları içerisinde Göksu Nehri üzerinde bulunan 390 m kotundaki Malpınarı (2115) Akarsu Gözlem İstasyonu akım verilerini tahmin edebilmek için membasında Değirmendere çayı üzerinde bulunan 444 m kotundaki Çanakçı (2194) Akarsu Gözlem İstasyonunun akım verileri girdi olarak kullanılmıştır. Çalışmada 2194 ve 2115 no'lu AGİ'lerin ortak zamanda çalışmış olduğu yıllar olan 01.10.2006-30.09.2009 tarihleri arasındaki toplam 4 yıllık günlük ortalama akım değerleri kullanılmış, bunlardan ilk 2 yıllık verilerini modellerin kalibre aşamasında, 1 yıllık verileri test aşamasında, 1 yıllık verileri de değerlendirme aşamasında kullanılmıştır. Modellerin test aşaması sonucunda elde edilen performans değerleri olan KOKH, OMH ve R^2 değerleri ve YSA modellerinin gizli tabakadaki hücre sayıları ve split katsayısı Tablo 3.27'de verilmiştir.

Tablo 3.27. Malpınarı (2115) istasyonunun akım verilerinin tahmininde modellerin test aşamasındaki KOKH, OMH ve R^2 değerleri (2194-2115)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R ²	
ÇDR	Q _t	KOM1	13,52	7,41	0,59	
	Q _t , Q _{t-1}	KOM2	13,36	7,47	0,59	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	13,39	7,47	0,59	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	13,30	7,49	0,59	
DDÇDR	Q _t	KOM1	13,55	7,56	0,57	
	Q _t , Q _{t-1}	KOM2	13,39	7,46	0,59	
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	13,31	7,50	0,59	
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	13,26	7,48	0,59	
ÇKYSA	Q _t	KOM1	1, 1, 1	12,48	8,06	0,59
	Q _t , Q _{t-1}	KOM2	2, 1, 1	12,58	7,96	0,59
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 1, 1	12,70	7,87	0,58
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 2, 1	12,58	7,86	0,60
RTYSA	Q _t	KOM1	1, 3, 0.1, 1	12,84	7,97	0,62
	Q _t , Q _{t-1}	KOM2	2, 2, 0.2, 1	12,46	7,86	0,59
	Q _t , Q _{t-1} , Q _{t-2}	KOM3	3, 4, 0.2, 1	12,34	7,88	0,60
	Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	KOM4	4, 4, 0.3, 1	12,46	7,89	0,60


Tablo 3.27 incelendiğinde yapılan analizler sonucunda en iyi sonuçların RTYSA-KOM4, ÇKYSA-KOM1, DDÇDR-KOM4, ÇDR-KOM4 olarak sıralandığı görülmüştür. Test aşamasında tüm modellerde farklı günlerdeki akım verilerinin girdi olarak kullanıldığı kombinezonlar en iyi sonucu vermiştir. Test aşamasında yapay zekâ yöntemlerinin çoklu doğrusal regresyon ve dalgacık dönüşümlü çoklu doğrusal regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür. Her metotta test aşamasındaki en düşük KOKH, en düşük

OMH ve en yüksek R^2 değerlerine sahip olan kombinezonların değerlendirme aşamasındaki performansları kontrol edilmiş ve Tablo 3.28’de verilmiştir.

Tablo 3.28. Malpınarı (2115) istasyonunun akım verilerinin tahmininde modellerin değerlendirme aşamasındaki KOKH, OMH ve R^2 değerleri (2194-2115)

METOT	GİRDİLER	MODEL	KOKH (m ³ /s)	OMH (m ³ /s)	R^2
ÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	21.58	13.75	0.79
DDÇDR	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4	21.48	13.66	0.80
ÇKYSA	Q_t	KOM1 1, 1, 1	19.34	12.48	0.81
RTYSA	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	KOM4 4,4,0,3,1	19.21	12.25	0.82

Test aşamasındaki en iyi modellerin değerlendirme aşamasına bakılıp, değerlendirme aşamasında metotlarla bulunan değerler Malpınar istasyonunun gözlenmiş değerleri ile mukayese edilmiş, saçılma diyagramları çizilerek Şekil 3.16’da gösterilmiştir. Gözlenen değerler ile kıyaslama sonucunda en iyi modelin RTYSA-KOM4 olduğu görülmüştür. Bu modelde girdi tabakasındaki hücre sayısı 4, gizli tabakadaki hücre sayısı 1, çıktı tabakası hücre sayısı 1, sprit katsayısı 0.7 olarak bulunmuştur.



Şekil 3.16. ÇDR, DDÇDR, ÇKYSA ve RTYSA metotlarının test aşamasındaki en iyi modellerin değerlendirme sonuçları (2194-2115)

3.4. Genel Değerlendirme

Bu çalışmada bir kapalı-kutu modeli olan yapay sinir ağı modellerinden radyal tabanlı yapay sinir ağı (RTYSA), çok katmanlı yapay sinir ağı (ÇKYSA) ile çoklu doğrusal regresyon (ÇDR) ve dalgacık dönüşümü çoklu doğrusal regresyon (DDÇDR) metodlarının günlük nehir akımlarının tahminindeki başarısı araştırılmıştır. Uygulamada mansapta bulunan akım gözlem istasyonunun günlük akım verilerini tahmin edebilmek için membasında bulunan akım gözlem istasyonunun günlük akım verilerini modele girdi olarak alınmıştır. Akım verileri dört farklı kombinasyon oluşturacak şekilde veri setlerine dönüştürülmüş ve Matlab programında analizler yapılmıştır. Modeller YSA metoduna uygun olarak eğitime, test ve değerlendirme aşamasından geçirilerek oluşturulmuştur. Yapılan analizlerin sonuçları hem sayısal olarak her model için ayrı ayrı değerlendirilmiş, regresyon analizlerinin sonuçları ile mukayese edilmiş, hem de gözlenen değerler ile karşılaştırılması yapılarak grafiksel olarak incelenmiştir.

YSA yöntemlerinde her bir kombinasyon 20 ara tabaka hücre sayısı için denenmiş en iyi sonuçlar elde edilmiştir. RTYSA’da her bir kombinasyonda denenilen 20 ara tabaka hücre sayısı için en iyi dağılım katsayısı da yine deneme sonucu bulunmuştur. Yapılan çalışmalar neticesinde;

KOKH ve OMH kriterlerine göre bakıldığında oluşturulan modellerde YSA modellerinin regresyon analizlerine göre daha iyi sonuçlar verdiği açık bir şekilde görülmüştür. Oluşturulan 12 modelin 10 tanesinde YSA modellerinin daha iyi sonuç vermiştir. YSA modelleri içerisinde de RTYSA modelinin akım tahminlerinde daha iyi olduğu gözlenmiştir.

R^2 kriterine göre baktığımızda çok büyük fark olmamakla beraber YSA modellerinin doğrusal regresyon modellerine göre daha iyi olduğu görülmüştür.

Saçılma diyagramlarına göre de incelediğimizde RTYSA’nın regresyon analizine göre daha iyi sonuçlar verdiği bulunmuştur.

4. SONUÇLAR VE ÖNERİLER

Yapılan çalışmada membada bulunan bir akım gözlem istasyonunun akım değerlerini kullanarak mansabındaki bir akım gözlem istasyonunun akım değerlerini tahmin etmede yapay sinir ağları ve dalgacık dönüşüm modelinin, regresyon analizlerine göre daha başarılı sonuçlar verdiği sonucuna varılmıştır. Bu sonuca göre belli bir dönemde bir istasyonda ölçüm yapılamadığı zamanlarda, eksik verileri tamamlamak için membasındaki istasyonun akım verilerini YSA modelinde girdi olarak kullanarak, verilerin tamamlanması, gelecekteki değerlerin tahmin edilmesi düşük bir hata ile mümkün olabilmektedir.

Yapılan çalışmalarda yapay sinir ağları ile akım tahminlerinin başarılı bir şekilde yapılabileceği, regresyon analizlerinden daha iyi sonuçlar verdiği ortaya konmuş olsa da yöntemin başarısı; sağlıklı, güvenilir ve yeterli miktarda verinin mevcut olmasına bağlıdır. Literatürde yapılan çalışmalara bakıldığında da son cümleler “*daha hassas ölçümlerle daha iyi sonuçlar elde edilebilir*” temennisi ile bitmektedir. Bu temenni de, modelde kullanılan verilerin ve ölçümlerin hassasiyetinin ne denli önemli olduğunu ortaya koymaktadır.

Hidrolik yapıların hem hidrolik tasarım ve hem de maliyet açısından en iyi şekilde tasarlanması, yeterli sayıdaki güvenilir verinin mevcudiyetine bağlıdır. Büyük taşkın debisine sahip dolusavaklar on bin yıllık taşkın debisine göre tasarlanmaktadır. Bu durumda on bin yıllık ölçümün olmaması nedeniyle, bu debi istatistiksel metotlarla bulunmaktadır. İstatistiksel metotla elde edilen sonuçların güvenilirliği ve doğruluğu da yeterli veriye bağlıdır. Bu nedenle eksik veri tamamlama ve veri uzatımında kullanılan modellerin başarısı, planlama çalışmalarında oldukça önemlidir.

Bu çalışmada günlük ortalama akım verileri ile çalışılmıştır. Fakat bu uygulamalar saatlik verilerle de çalışılarak tahminlerin daha düşük hatalarla belirlenmesi mümkündür.

KAYNAKLAR

- [1] **Karahan, H., İlhan, M.H., Ayvaz, M.T.**, 2007, Günlük eksik akımların yapay sinir ağları ve genetik algoritma kullanarak tamamlanması, *V.Ulusal Hidroloji Kongresi* ODTÜ, Ankara 5-7 Eylül.
- [2] **Özkaya, M., Seçkin, İ.U., Yıldız, M.**, 2006, EİE’de Göl Gözlemleri, *II ulusal Limnoloji Çalıştayı*, Sinop, 6-8 Eylül.
- [3] **Alp, M., Cıgızoglu, H.K.**, 2004, Farklı yapay sinir ağı metotları ile yağış-akış ilişkisinin modellenmesi. *İTÜ dergisi*, Cilt:3, Sayı:1, 80-88.
- [4] **Yurdusev, M.A., Acı, M., Turan, M.E., İcağa, Y.**, 2008, Akarçay nehri aylık akımlarının yapay sinir ağları ile tahmini. *C.B.Ü. Fen Bilimleri Dergisi* 4.1 (73 – 88).
- [5] **Partal,T., Cıgızoglu, H.K., Kahya, E.**, 2007, Yağış tahmininde yapay sinir ağları ve dalgacık dönüşümünün birlikte uygulanması. *V.Ulusal Hidroloji Kongresi* ODTÜ, Ankara 5-7 Eylül.
- [6] **Kişİ, Ö., Öztürk, Ö.**, 2005, Yapay zeka hesaplama teknikleri kullanılarak günlük nehir akımlarının tahmini ve eksik verilerin tamamlanması, *E. Ü. M. F. İnşaat müh. Kayseri*.
- [7] **Cigizoglu, H.K. & Kisi, O.** (2006), Methods to improve the neural network performance in suspended sediment estimation, *J. of Hydrology*. 317, 221-238.
- [8] **Hsu, K., Gupta, H.V., Sorooshian, S.**, 1995, Artificial neural network modelling of the Rainfall runoff process. *Water Resources Research*, 31, 2517-2530.
- [9] **Minns, A.W., Hall, M.J.**, 1996, Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal*, , 41(3), 399- 417.
- [10] **Kumar, P., Foufoula-Georgiou, E.**, 1993, A multicomponent Decomposition of Spatial Rainfall Fields 1. Segregation of Large- and Small-Scale Features Using Wavelet Transforms, *Water Resources Research*, 29(8), 2515-2532.
- [11] **Kumar, A.R.S., Sudheer, K.P., Jain. S.K., Agarwal, P.K.**, 2005, Rainfall-runoff modelling using artificial neural networks: comparison of network types. *Hydrologic Processes*, 19(6), 1277-1291.
- [12] **Wang, D., Ding, J.**, 2003, Wavelet network model and its application to the prodiction of hydrology, *Nature and Science*, 1.67-71.
- [13] **Elektrik İşleri Etüt İdaresi**, Hidrometri Kurs Notları, 2006, Anakara.
- [14] **Şen, Z.**,2004a, Yapay sinir ağları ilkeleri, Su Vakfı Yayınları, 183 s., İstanbul.

- [15] **Türkoğlu, İ.**, 2008 Yapay sinir ağları ders notları, F.Ü. İnşaat Müh.Böl., Elazığ.
- [16] **McCullogh, W.S. and Pitts, W.A.**, 1943, A logical calculus of the ideas immanent in nervous activity, *Bull. Math. Biophysics*, Vol. 5, 115-133 p.
- [17] **Hebb, D.**, 1949, The organization of behavior, Willey, New York.
- [18] **Güneş, M.**, 2010. Sultan sazlığı su seviyelerinin yapay sinir ağı-dalgacık modeli ile tahmini, *Yüksek Lisans Tezi*, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- [19] **Rosenblatt, F.**, 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological Review*, 65, 386-408.
- [20] **Minsky, M. L., Papert, S. A.**, 1969, Perceptrons. Cambridge. MA: MIT res.
- [21] **Cevat, F.**, 2009. Akarsularda seviye akış ilişkilerinin yapay zeka metodları ile belirlenmesi, *Yüksek Lisans Tezi*, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- [22] **Afşar, S.**, 2008. Yapay sinir ağları ve bulanık mantık yöntemleri kullanarak Tava buharlaşma tahmini yapılması, *Yüksek Lisans Tezi*, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- [23] **Hopfield, J.J.**, 1982, Neural Networks and physical systems with emergent collective computational capabilities, *Proc. Natl. Acad. Sci.*, V. 79, pp.2554-2558.
- [24] **Beyazıt, M.**, 1981, Hidrolojide istatistik yöntemler, İTÜ İnşaat Fakültesi, İstanbul.
- [25] **Kohonen, T.**, 1982, Self-organised Formation of Topologically Correct Feature Maps. *Biological Cybernetics*, 43, 59-69.
- [26] **Rumelhart, D.E., Hinton, G.E. and Williams, R.J.**, 1986, Learning representations by back propagation error, *Nature*, Vol. 32, 533-536.
- [27] **Özyılmaz, L.B.**, 2000, Konik kesit fonksiyonlu yapay sinir ağında öğrenme algoritmasının geliştirilmesi ve ağı çeşitli problemler için Performansı ile duyarlılığının incelenmesi, *Doktora Tezi*, YTÜ. Fen bilimleri enstitüsü, İstanbul.
- [28] a) **Haykin, S.**, 1994, *Neural Networks: A Comprehensive Foundation*. Macmillan, New York, 66.
b) **Haykin, S.**, 1999, *Neural Networks A Comprehensive Foundation*. Prentice Hall International, Inc..
- [29] **Akkurt, S., Ozdemir, S., Tayfur, G., and Akyol, B.**, 2003, The use of GA-ANNs in the modelling of compressive strength of cement mortar, *Cement and Concrete Research*, 33(7), 973-979
- [30] **Anderson, J.A.**, 1983, Cognitive and psychological computation with neural models, *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-13, No. 5, 799-814.

- [31] **Kişi, Ö.**, 2004, Yapay sinir ağları ve regresyon teknikleri ile Filyos Çayı akımlarının tahmini, IV Hidroloji Kongresi, İstanbul, Türkiye, 347-353, 23, 25 Haziran.
- [32] **Liu, S.W., Huang, J.H., Sung, J.C. and Lee, C.C.**, 2002, Detection of cracks using neural networks and computational mechanics, *Computer Methods in Applied Mechanics Engineering*, 191(25-26), 2831-2845.
- [33] **Topçu, İ.B. and Sarıdemir, M.**, 2007, Prediction of properties of waste AAC aggregate concrete using artificial neural networks, *Computational Materials Science*, 41(1),117-125.
- [34] **Topçu, İ.B. and Sarıdemir, M.**, 2008a, Prediction of compressive strength of concrete containing fly ash using artificial neural network and fuzzy logic, *Computational Materials Science*, 41(3) 305-311.
- [35] **Topçu, İ.B. and Sarıdemir, M.**, 2008b, Prediction of rubberized concrete properties using artificial neural network and fuzzy logic, *Construction and Building Materials*, 22(4), 532-540.
- [36] **Kişi,Ö., Nas, N.**, 2007, Nehirlerdeki askı maddesi miktarının yapay zeka yöntemleri ile tahmini, V.Ulusal Hidroloji Kongresi ODTÜ, Ankara 5-7 Eylül.
- [37] **Öztaş, A., Pala, M., Özbay, E., Kanca, E., Çağlar, N. and Asghar Bhatti, M.**, 2006, Predicting the compressive strength and slump of high strength concrete using neural network, *Construction and Building Materials*, 20(9), 769-775.
- [38] **Pala, M., Özbay, E., Öztaş, A. and Yuce, M.I.**, 2007, Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks, *Construction and Building Materials*, 21(2), 384-394.
- [39] **Topçu İ.B. and Sarıdemir M.**, 2008c, Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic, *Computational Materials Science*, 42(1), 74-82.
- [40] **Topçu İ.B. and Sarıdemir M.**, 2008d, Prediction of rubberized mortar properties using artificial neural network and fuzzy logic, *Journal of Materials Processing Technology*, 199(1-3), 108-118.
- [41] **Arbib, M.A.**, 1995, The handbook of brain theory and neural networks, Cambridge (MA): MIT Press, 738-741
- [42] **Lipmann, R.**, 1987, An introduction to computing with neural nets, *IEEEASSP Mag.*,4, 4-22
- [43] **Marquardt, D.**, 1963,An algorithm for least squares estimation of non-linear parameters, *J. Soc. Ind. Appl. Math.*, 431-441.
- [44] **Hacıoğlu, A.**, 2006, “Yapay sinir ağı ile güçlendirilmiş genetik algoritma ve hızlı evrimsel eniyileme için YSA kullanılması”, *HUTEN Havacılık ve Uzak Teknolojileri Dergisi*, Cilt 2, Sayı 3 (1-8), Ocak

- [45] **Daubechies, I.**, 1990, The Wavelet Transform, Time-Frequency Localization and Signal Analysis. IEEE Transactions on Information Theory, 36 (5), 961-1005.
- [46] **Daubechies, I.**, 1996, Where do wavelets come from? - A personal point of view, Proceedings of the IEEE. 84(4), 510-513.
- [47] **Grossman, A., Morlet, J.**, 1984, Decomposition of Hardy functions into square integrable wavelets of constant shape. SIAM J. Math. Anal., 15, 723-736.
- [48] **Mallat, S., G.**, 1989, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. IEEE Transactions on Pattern Analysis and Machine Intelligence. 11 (7), 674-693.
- [49] **Meyer, Y.**, 1993, Wavelets Algorithms & Applications. Society for Industrial and Applied Mathematics, Philadelphia.
- [50] **Küçük, M.**, 2004, Dalgacık Dönüşümü Tekniği Kullanılarak Akım Serilerinin Modellenmesi, *Doktora Tezi*, İstanbul Teknik Üniversitesi, Fen bilimleri enstitüsü, İstanbul.
- [51] **Beyazıt, M., Oğuz, B.**, 1998, Mühendisler için istatistik, Birsan Yayınevi, İstanbul.
- [52] **Yıldız, M., Malkoç, Y.**, E.İ.E, 2000 Türkiye Akarsu Havzaları ve Hidrolojik Kuraklık Anazlizi, ISBN: 975-7566-92-6, Ankara.
- [53] **Elektrik İşleri Etüt İdaresi.**, Akarsu-Göl-Kar Gözlem İstasyonları Genel Bilgileri, ISBN:978-605-4075-14-0, 2009, Ankara.
- [54] **Elektrik İşleri Etüt İdaresi.**, Akarsu-Göl-Kar Gözlem İstasyonları Genel Bilgileri, ISBN:978-605-4075-59-1, 2010, Ankara.
- [55] **Elektrik İşleri Etüt İdaresi.**, Su Akımları Aylık Ortalamaları (1935-2005), ISBN:978-605-4075-96-6, 2008, Ankara.
- [56] **Elektrik İşleri Etüt İdaresi.**, 2006 Su Akımları Yıllığı, ISBN: 978-605-4075-21-8, 2009, Ankara.
- [57] **Elektrik İşleri Etüt İdaresi.**, 2007 Su Akımları Yıllığı, ISBN: 978-605-4075-60-7, 2010, Ankara.
- [58] **Şen, Z.**, 2002, İstatistik veri isleme yöntemleri. *Su vakfi yayınlan*, İstanbul.
- [59] **Kişi, Ö.**, 2001, Akış tahmini ile ilgili bir uygulama, *Mühendislikte Modern Yöntemler Sempozyumu (MMYO'2001)*, İstanbul, Eylül.
- [60] **EİEİ Web Sitesi**, 2006. <http://www.eie.gov.tr/turkce/hidroloji/havzalar.html>
- [61] **Yenigün, K., Gümüş, V.**, 2007, Fırat Havzası Akımlarında Görülen Trendlerin Nedenlerinin Araştırılması *V.Ulusal Hidroloji Kongresi* ODTÜ, Ankara 5-7 Eylül.

- [62] **Onüçyıldız, M., Yarar, A.**, 2005, Beyşehir Gölü Su Seviyesi Değişimlerinin Yapay Sinir Ağları ile Belirlenmesi, *II.Ulusal Su Mühendisliği Sempozyumu*, İzmir, Türkiye 21-24 Eylül.
- [63] **Kiş, Ö.**, River flow modeling using artificial neural networks. *ASCE J.Hydrol. Eng.*
- [64] **Kiş, Ö.**, 2009 , “Neural network and wavelet conjunction model for modeling monthly level fluctuations of Van Lake in Turkey”, *Hydrological Processes*, 23(14) 2081-2092,.
- [65] **Kiş, Ö.**, 2004, River flow modeling using artificial neural networks. *ASCE J.Hydrol. Eng.* 9 (1). 60-63.
- [66] **Kiş, Ö.**, 2005, Daily river flow forecasting using artificial neural networks and autoregressive models. *Turk. J. Eng. Environ. Sci.* 29. 9-20.
- [67] **Kiş, Ö.**, 2005, Yapay Sinir Ağları ile Meteorolojik Verileri Kullanarak Buharlaşmanın Modellenmesi, *Bilimde Modern Yöntemler Sempozyumu(BMYS, Kocaeli syf 790-797*, Kasım 16-18.
- [68] **Venugopal, V., Foufoula-Georgiou, E.**, 1996, Energy decomposition of rainfall in the timefrequencyscale domain using wavelet packets. *Journal of Hydrology*, 187,3-27.

ÖZGEÇMİŞ

1973 yılında Mersin ili Silifke ilçesinin Sarıaydın köyünde doğdu. İlkokulu Sarıaydın köyü ilkokulu, Ortaokulu Hacıışaklı ortaokulu, Lise öğrenimini 1989 yılında Silifke Lisesinde tamamladı. 1992 Yılında İstanbul Teknik üniversitesi Uçak Uzay Bilimleri Fakültesi Meteoroloji Mühendisliği bölümünü kazandı. Bir yıl ingilizce eğitimi aldıktan sonra 1997 yılında lisans eğitimini bölüm ikincisi olarak tamamlayıp Meteoroloji Mühendisi olarak mezun oldu. Özel sektörde 10 yıl Halkla İlişkiler de görev yaptıktan sonra 2006 yılında EİE de Meteoroloji Mühendisi olarak göreve başladı. Halen EİE Genel Müdürlüğü 1.Hidrometrik Etüt Merkezi-Elazığ da Merkez şefi olarak görevini sürdürmektedir.

Adres: EİE Genel Müdürlüğü
1.Hidrometrik Etüt Merkezi
23100 Merkez- Elazığ

Telefon: 0 531 780 47 27
0 536 669 01 70

E-Posta: agunduz@eie.gov.tr
agunduz73@hotmail.com.tr