



İSKENDERUN TEKNİK
ÜNİVERSİTESİ

**YÜKSEK
LİSANS
TEZİ**

**YAĞIŞ – AKIŞ İLİŞKİSİNİN
YAPAY SİNİR AĞLARI VE
OTOREGRESİF HAREKETLİ
ORTALAMALAR
MODELLERİ İLE TAHMİNİ**

Levent KESKİN

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2020



**YAĞIŞ – AKIŞ İLİŞKİSİNİN YAPAY SİNİR AĞLARI VE OTOREGRESİF
HAREKETLİ ORTALAMALAR MODELLERİ İLE TAHMİNİ**

Levent KESKİN

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2020

Levent KESKİN tarafından hazırlanan “YAĞIŞ – AKIŞ İLİŞKİSİNİN YAPAY SİNİR AĞLARI VE OTOREGRESİF HAREKETLİ ORTALAMALAR MODELLERİ İLE TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Başkan: Prof. Dr. Fatih ÜNEŞ

İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Danışman: Doç. Dr. Mustafa DEMİRCİ

İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Dr. Öğr. Ü. M. Eyyüp KAVŞUT

İnşaat Mühendisliği Anabilim Dalı, Osmaniye Korkut Ata Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Tez Savunma Tarihi: 25/06/2020

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Tolga DEPCİ
Mühendislik ve Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Levent KESKİN

25/06/2020



YAĞIŞ – AKIŞ İLİŞKİSİNİN YAPAY SİNİR AĞLARI VE OTOREGRESİF HAREKETLİ
ORTALAMALAR MODELLERİ İLE TAHMİNİ
(Yüksek Lisans Tezi)

Levent KESKİN

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2020

ÖZET

Su kaynaklarının daha verimli kullanılması, havza yönetimi ve afetlerin engellenmesi amacıyla yapılan su yapıları planlamasında, akış verilerinin tahmini büyük bir önem taşımaktadır. Planlama aşamasında kullanılacak verilerin eksiksiz ve tutarlı olması, planlama ve tasarım süreçlerinin verimini artıracak, daha güvenilir sonuçlar alınmasına olanak tanıyacaktır. Yağış - akış modellemelerinde, verilerin tahmini için kullanılan geleneksel yöntemler yetersiz kalabilmektedir. Bu nedenle eksik veya gelecekteki akışın tahmini için bir çok alternatif yöntem geliştirilmiştir.

Bu çalışmada Amerika Birleşik Devletleri Waltham Massachusetts'te yer alan Stony Brook Rezervuarı'ndan elde edilen veriler kullanılarak yağış – akış modelleri oluşturulmuştur. 731 günlük yağış, akış ve sıcaklık bilgilerini içeren bu veriler İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA), Çoklu Doğrusal Regresyon (ÇDR) ve Otoresif Hareketli Ortalamalar (ARMA) yöntemlerinde girdi verisi olarak kullanılmıştır. Elde edilen akış verileri gerçek ölçüm sonuçları ile karşılaştırılarak bu üç yöntem değerlendirilmiştir. YSA yöntemi bu akış verilerinin tahmininde %92'nin üzerinde uyumluluk göstermiştir.

Anahtar Kelimeler : Yapay Sinir Ağları, yağış - akış, Çoklu Doğrusal Regresyon,
Otoresif Hareketli Ortalamalar
Sayfa Adedi : 52
Danışman : Doç. Dr. Mustafa DEMİRCİ

PREDICTION OF RAINFALL - RUNOFF RELATION WITH ARTIFICIAL NEURAL
NETWORKS AND AUTOREGRESSIVE MOVING AVERAGE MODELS
(M. Sc. Thesis)

Levent KESKİN

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

June 2020

ABSTRACT

In terms of efficient use of water resources and prevention of disasters, rainfall and runoff relation is very important. Complete and consistent data increases the efficiency of planning and design processes and ensures more reliable results. In rainfall - runoff modeling, traditional methods for estimating data may be insufficient. Therefore, many alternative methods have been developed for the prediction of missing or future runoff.

In this study, the data obtained from USA Waltham Massachusetts Stony Brook Reservoir was used. 731 days of rainfall, runoff and temperature data were used to generate input data in the Feed Forward Backpropagation Neural Network (FFBNN), Multiple Linear Regression (MLR) and Autoregressive Moving Average (ARMA) models. The results obtained were compared with the actual results. As a result, it was found that the ANN method is more than 92% compatibility in estimating these current data.

Key Words : Artificial Neural Networks, rainfall - runoff, Multiple Linear Regression,
Autoregressive Moving Average
Page Number : 52
Supervisor : Assoc. Dr. Mustafa DEMİRCİ

TEŐEKKÜR

Yüksek lisans tez konumun belirlenmesi, araştırılması ve deneylerin yapılması sürecinde sahip olduđu bilgi birikimleri ve tecrübeleriyle çalışmaya yön veren çok değerli danışman hocam Doç. Dr. Mustafa DEMİRCİ ve hiçbir yardımı esirgemeyen Prof. Dr. Fatih ÜNEŐ'e sonsuz saygı ve teşekkürlerimi sunarım.

Çalışma yöntemlerinin uygulanması esnasında yardımda bulunan çok değerli Arş. Gör. Bestami TAŐAR'a teşekkür ederim.

Maddi ve manevi desteklerini her zaman en içten şekilde hissettiren aileme teşekkürü borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR.....	8
3. MATERYAL VE YÖNTEM	15
3.1. Çalışma Alanı.....	15
3.2. Yapay Sinir Ağları (YSA).....	18
3.2.1. Doğrusal (lineer) fonksiyon	24
3.2.2. Sigmoid fonksiyonu	25
3.2.3. Tanjant hiperbolik fonksiyonu	26
3.2.4. ReLU (rectified linear unit) fonksiyonu.....	27
3.2.5. İleri beslemeli geri yayımlı sinir ağı (İBGYSA).....	28
3.3. Otoregresif Hareketli Ortalamalar Modeli (ARMA)	31
3.4. Çoklu Doğrusal Regresyon (ÇDR)	32
4. ÇALIŞMADA KULLANILAN DEĞERLENDİRME KRİTERLERİ	33
4.1. R ² Belirleme (Determinasyon) Katsayısı	33
4.2. Ortalama Mutlak Hata (OMH-MAE).....	34
4.3. Ortalama Karesel Hata (OKH-MSE)	34

5. ARAŐTIRMA BULGULARI VE TARTIŐMA.....	36
6. SONUÇLAR VE ÖNERİLER.....	48
KAYNAKLAR.....	49
DİZİN.....	52
ÖZGEÇMİŐ.....	53



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. 01104480 numaralı istasyon bilgileri (USGS)	15
Çizelge 5.1. Modellerde kullanılan girdi verileri.....	36
Çizelge 5.2. Modellere göre sonuçların uyumluluk ve istatistiksel hata değerleri.....	46



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Su döngüsü (USGS, 2019).....	1
Şekil 1.2. Hidrograf.....	4
Şekil 1.3. Birim hidrograf.....	5
Şekil 3.1. Stony Brook Havzası / Rezervuar alanı (Goolge Maps)	16
Şekil 3.2. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük hava sıcaklığı değişimi grafiği (°C).....	16
Şekil 3.3. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük yağış miktarı değişimi (mm).....	17
Şekil 3.4. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük ortalama akış miktarı değişimi (m ³ /s)	17
Şekil 3.5. Biyolojik sinir ağı yapısı (Wikipedia, 2020)	19
Şekil 3.6. Üç katmanlı YSA mimarisi	20
Şekil 3.7. Satranç oyununda YSA modellemesi / Giriş nöronlarının oluşturulması	22
Şekil 3.8. Satranç oyununda YSA modellemesi / Ağın eğitilmesi ve çıkış nöronu.....	22
Şekil 3.9. Yapay Sinir Ağı mimarisinde aktivasyon fonksiyonunun gösterilmesi	23
Şekil 3.10. Doğrusal (linear) fonksiyon grafiği	24
Şekil 3.11. Sigmoid fonksiyonu grafiği	25
Şekil 3.12. Tanjant hiperbolik fonksiyonu grafiği.....	26
Şekil 3.13. ReLU (rectified linear unit) fonksiyonu grafiği.....	27
Şekil 3.14. İleri Beslemeli Geri Yayılımlı Sinir Ağı mimarisi	28
Şekil 3.15. Yapay Sinir Ağı modelinin veri çıkışı kısmı	29
Şekil 4.1. R ² değerlerinin regresyon çizgisi üzerinde gösterimi (Quora, 2018).....	34
Şekil 5.1. YSA model 1 eğitim sonuçları için dağılım ve saçılım grafikleri	37

Şekil	Sayfa
Şekil 5.2. YSA model 1 test sonuçları için dağılım ve saçılım grafikleri.....	37
Şekil 5.3. YSA model 2 eğitim sonuçları için dağılım ve saçılım grafikleri	38
Şekil 5.4. YSA model 2 test sonuçları için dağılım ve saçılım grafikleri.....	38
Şekil 5.5. YSA model 3 eğitim sonuçları için dağılım ve saçılım grafikleri.....	39
Şekil 5.6. YSA model 3 test sonuçları için dağılım ve saçılım grafikleri.....	39
Şekil 5.7. ÇDR model 1 eğitim sonuçları için dağılım ve saçılım grafikleri.....	40
Şekil 5.8. ÇDR model 1 test sonuçları için dağılım ve saçılım grafikleri	40
Şekil 5.9. ÇDR model 2 eğitim sonuçları için dağılım ve saçılım grafikleri.....	41
Şekil 5.10. ÇDR model 2 test sonuçları için dağılım ve saçılım grafikleri	41
Şekil 5.11. ÇDR model 3 eğitim sonuçları için dağılım ve saçılım grafikleri	42
Şekil 5.12. ÇDR model 3 test sonuçları için dağılım ve saçılım grafikleri	42
Şekil 5.13. ARMA(1,1) eğitim sonuçları için dağılım ve saçılım grafikleri	43
Şekil 5.14. ARMA(1,1) test sonuçları için dağılım ve saçılım grafikleri	43
Şekil 5.15. ARMA(2,2) eğitim sonuçları için dağılım ve saçılım grafikleri	44
Şekil 5.16. ARMA(2,2) test sonuçları için dağılım ve saçılım grafikleri	44
Şekil 5.17. ARMA(3,3) eğitim sonuçları için dağılım ve saçılım grafikleri	45
Şekil 5.18. ARMA(3,3) test sonuçları için dağılım ve saçılım grafikleri	45
Şekil 5.19. YSA, ÇDR ve ARMA yöntemleri için karşılaştırmalı saçılım grafiği	47

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklamalar
a	MA(q) Model Parametresi
B	Basınç, Bias
β	AR(p) Model Parametresi, Regresyon Katsayısı
E	Verimlilik Katsayısı
Es	Güneşlenme Şiddeti
ϵ	Hata Terimi
N	Nem
P	Yağış
R	Kolerasyon Katsayısı, Rüzgar
R²	Determinasyon Katsayısı
S	Sıcaklık
T	Sıcaklık
t	Zaman
t₀	Artık Yağış Yüksekliği
t_p	Gecikme Süresi
y_t	Zaman Serisi
Q	Akış, Debi
Q_p	Dolaysız Akış
W	Ağırlık
Kısaltmalar	Açıklamalar
ANFIS	Adaptive Neuro Fuzzy Inference System

ARMA	Autoregressive Moving Average
BM	Bulanık Mantık
ÇDR	Çoklu Doğrusal Regresyon
ÇKYSA	Çok Katmanlı Yapay Sinir Ağı
ÇRM	Çoklu Regresyon Modeli
DP	Different Peak
GEP	Gen Ekspresyon Programlama Yöntemi
GRSA	Genelleştirilmiş Regresyon Sinir Ağı
HKO	Hata Kareler Ortalaması
HKOK	Hata Kareler Ortalaması Karekökü
İBGYSA	İleri Beslemeli Geri Yayılımlı Sinir Ağı
LRM	Lineer Regresyon Modeli
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
MLP	Multilayer Perceptron
MSE	Ortalama Karesel Hata
OKH	Ortalama Karesel Hata
OMH	Ortalama Mutlak Hata
OMGH	Ortalama Mutlak Göreceli Hata
RBF	Radial Basis Function
RMSE	Ortalama Karesel Hataların Karekökü
RTYSA	Radyal Tabanlı Yapay Sinir Ağı
TBAYSA	Temel Bileşenler Analizi Yapay Sinir Ağı
USGS	United States Geological Survey
YSA	Yapay Sinir Ağı
ZGÖYSA	Zaman Geciktirmeli Özyineli Yapay Sinir Ağı

1. GİRİŞ

Yağış ve akış ilişkisi hidroloji bilimi için en önemli parametrelerdendir. Bunun için öncelikle yağış ve yağışı akışa dönüştüren parametrelerin bilinmesi gerekmektedir.

Güneş ışınlarının direkt etkisi ve yansıması ile yeryüzündeki su buharlaşır. Buharlaşan su ile birlikte hava, yeryüzündeki yüksek basınç alanından yukarıya doğru yani alçak basınç alanına doğru taşınır. Bu alanda hava soğumaya başlar. Soğuyan havada buharlaşma miktarı yoğunlaşmaya kıyasla her zaman daha “az”dır. Bu noktada bir araya gelen su buharı tanecikleri damlacıklar haline gelir ve bulutları oluşturur. Soğumanın devam etmesi ile yoğunlaşma daha da artar ve su damlacıkları havanın taşıyamayacağı hale gelir ve yerçekimi etkisi ile yağış olarak yeryüzüne düşer.

Dünya üzerindeki toplam su miktarı asla değişmez. Bu nedenle güneş enerjisi ile yeryüzünden buharlaşarak yükselen, daha sonra yer çekimi ile tekrar yağmur olarak yeryüzüne düşen yağmur suları sürekli bir döngüye girer. Bu döngüye “hidrolojik çevrim” denir. Şekil 1.1.’de hidrolojik çevrim, su döngüsü olarak gösterilmiştir.



Şekil 1.1. Su döngüsü (USGS, 2019)

Çevrimin başlangıcını yağış olarak kabul edersek, yeryüzüne düşen bu yağışın belirli bir kısmı toprak tarafından emilerek yer altı sularını oluşturur. Daha sonra bu sular tekrar buharlaşacakları büyük su kütlelerine (deniz, okyanus vb.) ulaşır. Buna “yüzeysel akış” denir. Yeryüzü üzerinden akarak nehir, çay ve dereleri oluşturup, daha sonra büyüyerek bir yerde toplanan su birikintileri ise “akarsu akışını” oluşturur.

Yüksek kesimlerde biriken karların ve soğuk iklimlerdeki buzulların erimesi ile büyük bir akış hareketi meydana gelir. Eriyen bu kar ve buzul suları da nehir ve akarsulara karışarak döngüye katılır. Akarsuya karışmayıp kapalı bir havzada göl olarak depolanan sular ise “tatlı su rezervlerini” oluşturur.

Yağmur ve kar olarak düşen, sonra toprak altına geçerek yüzeysel akışı oluşturan suyun bir kısmı alt tabakadaki toprağa sızarak “akiferleri” doldurur. Bir kısmı da toprak tarafından emilerek toprağın mineral açısından zenginleşmesini sağlar. Kalan kısmı da tekrar yüzeye çıkıp akarsuya karışabilir.

Bu şekilde dünya üzerindeki 1,4 milyar km³ su, eksilmeden sürekli bir döngüye girmiş olur.

Bir havzaya düşen yağışın belli aşamalardan geçip en son akışa dönmesi ve bunun miktarının doğru analiz edilmesi; taşkın kontrolü, su temini ve hidroelektrik santralleri ile enerji üretimi gibi su yapıları planlamalarında doğru bir projelendirme ve uygulama açısından mühendisler için büyük bir önem taşımaktadır. Bu analizler yapılırken günlük, aylık ve yıllık yağış verileri kullanılabilir. Veriler ne kadar geniş bir aralıkta ve istikrarlı olursa sonuçlar da o kadar tutarlı olacaktır. Fakat bölgesel şartlar, ölçüm aletlerindeki teknik sorunlar ve havza özellikleri nedeniyle ölçüm alınamaması yağış akış verilerinin belirlenmesinde sıkıntılar yaşatabilmektedir. Bu nedenle yağış - akış ilişkisinin belirlenmesinde ve eksik ölçümlerin tamamlanmasında çeşitli hidrolojik modeller kullanılabilir. Böylece hem daha doğru bir analiz yapılabilir, hem geriye dönük hata payları tolere edilebilir, hem de geleceğe yönelik herhangi bir veri eksikliği bu yöntemle ortadan kaldırılabilir.

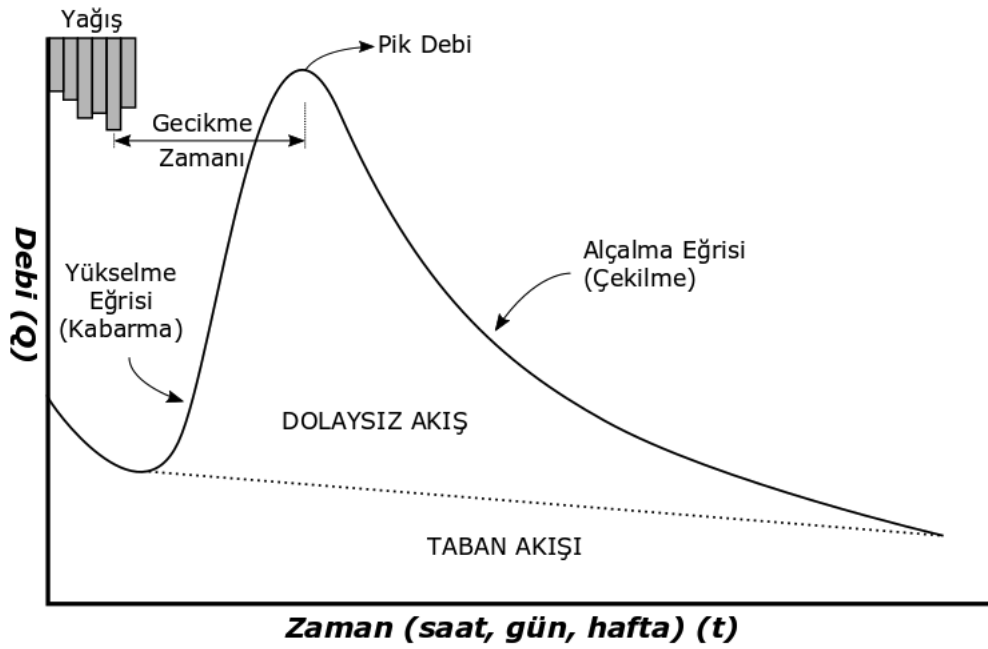
Bu yağış - akış ilişkisinin belirlenmesinde genel olarak iki modelden bahsedilebilir. Bunlar Parametrik (Kavramsal - Çok Bileşenli) ve Sistem Yaklaşımı olarak bilinen Ampirik Kara Kutu modelleridir.

Parametrik modeller yağışın akışa dönüştüğü süreci tüm detayları ile ele alan çok başarılı bir modelleme yöntemidir. Yağışın havza üzerinde uğradığı kayıpların ardından biriktirmeye girmesi ile bu biriktirme elemanlarının birçok elemana ayrılıp her eleman üzerinde gerçekleşen hidrolojik süreçleri ve aralarındaki ilişkiyi matematiksel ifadelerle tanımlamaya çalışır. Havza ne kadar fazla elemana ayrılırsa, biriktirme elemanları üzerindeki değişimler daha detaylı olarak incelenebilir ve yağışın akışa dönüşüm süreci daha detaylı modellenebilir.

Diğer modellere kıyasla yağış, akış ve sıcaklık verilerinin dışında sızma, buharlaşma, yüzey, yüzey altı ve yer altı suyu akımı gibi çok fazla parametre (değişken) modelde girdi verisi olarak kullanılmaktadır. Bu da beraberinde birçok zorluğu getirmektedir. Modellerde havza sistemi ne kadar çok alt bileşene ayrılırsa, geliştirilen model, yağış - akış dönüşümünü o derecede iyi temsil edecektir Fakat havza sisteminin çok sayıda alt bileşene ayrılması, model içindeki parametre sayısının artmasına; bu da modelin kalibrasyonunun güçleşmesine neden olacaktır (Beven, 1993; Lindström ve diğerleri, 1997; Refsgaard J.C., 1997; Uhlenbrook ve diğerleri, 1999).

Kara Kutu modellerinde ise havzada gerçekleşen fiziksel olaylar dikkate alınmaz. Normalde bir havza modeli yapılırken yağış ile akış arasındaki ilişkiyi hesaplamak çok zordur ve bu ilişki lineer değildir. Ama kara kutu modellerinde havzaya sadece yağışı akışa dönüştüren matematiksel bir fonksiyon gözüyle bakılır. Sherman'ın 1932 yılındaki "Birim Hidrograf" yöntemine dayanır (Sherman, 1932). Büyük su yapıları projelerinde, taşkınların incelenmesinde akımın değişiminin bilinmesi çok önemli olduğu için mevcut havzanın akarsu kesitine ait hidrografın belirlenmesi oldukça önemlidir.

Hidrograf: Bir akarsu kesitindeki akış miktarının zamanla değişimini gösteren grafikdir (Şekil 1.2.). Normalde lineer olmayan yağış - akış ilişkisi için bu grafik üzerinden belirli kabuller yapılarak yağışı akışa dönüştüren lineer bir fonksiyon yazılabilir. Hidrograf, havza ve yağış özelliklerine göre değişim göstermektedir.



Şekil 1.2. Hidrograf

Yükselme Eğrisi (Kabarma): Yağışın başlaması ile debinin hızlıca arttığı kısımdır. Yağışın süresine, şiddetine ve havzanın özelliklerine bağlıdır. Yağış şiddeti ve havza eğimi fazla ise bu kısımdaki eğim de fazla olacaktır.

Pik Debi (Tepe Noktası): Akışın maksimum olduğu andır.

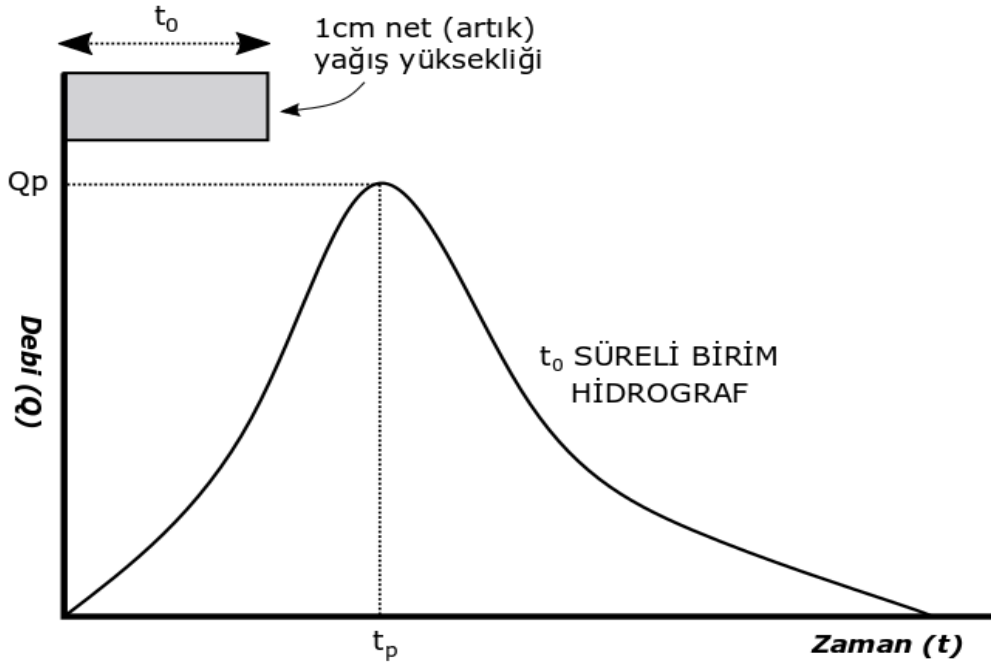
Gecikme Zamanı: Yağış hiyetografinin ağırlık merkezi ile akışın maksimum olduğu ana kadar (pik debi) geçen süredir. Yağışın havza alanındaki dağılımı ve süresi etkilidir.

Alçalma Eğrisi (Çekilme): Akışın azalmaya geçtiği bölümdür. Yağıştan bağımsızdır ve bu kısım yeraltı suyu, yüzeysel biriktirme gibi havzanın özelliklerine bağlıdır. Zamanla giderek yavaşlayacağı için eğri, yükselme eğrisine göre daha yatık olacaktır.

Taban Akışı: Yağış öncesinde akarsudaki mevcut akıştır.

Dolaysız Akış: Sadece yağışın (veya kar erimesinin) sebep olduğu akıştır.

Birim Hidrograf: Basit olarak, net (artık) yağışı dolaysız akışa dönüştüren lineer sistem haline getirilmiş bir havza modelidir (Şekil 1.3). Burada havzaya belirli bir sürede üniform olarak düşen yağışın 1cm'lik kısmının (artık, net yağış) meydana getirdiği dolaysız akış dikkate alınır.



Şekil 1.3. Birim hidrograf

Havza modellemesinin zor olduğu ve yağış ile akış arasındaki ilişkinin aslında lineer olmayan bir ilişki olduğu bilinmektedir. Yani havzadaki toplam yağış, her zaman toplam akışa denk olmaz. Arada sızma, yüzey biriktirmesi, tutma gibi kayıplar da mevcuttur. Bu nedenle buradaki birim hidrograf modeli kullanılarak belirli kabuller yapılır ve sistem lineer bir sistem gibi düşünülür.

Toplam Yağış – Kayıplar = Artık (Net) Yağış

Toplam Akış – Taban Akışı = Dolaysız Akış

- Burada artık yağışın şiddeti sabit, yani havzada üniform olduğu kabul edilir.
- Dolaysız akışın yani hidrografın taban genişliği, yağış şiddetinden bağımsız olarak kabul edilir.
- Birim hidrograf tüm havzanın fiziksel özelliklerini temsil eder, havza için tektir ve havza özellikleri sabittir.

Sonuç olarak akarsu havzaları, kara kutu sistemlerinde, birim hidrograf modelinden faydalanılarak yağışı akışa dönüştüren matematiksel “lineer” bir fonksiyon olarak kabul edilir. Amaç sisteme giren yağıştan oluşan akımın debisini tahmin etmektir.

Son yıllarda gelişmekte olan yapay zeka teknikleri ile yağış - akış ilişkisi arasında gerçeğe çok yakın tahminlerde bulunulabilmektedir. Yapay zeka modellerinin temelinde ise bilgisayar destekli bir makinenin, insana özgü nitelikler ile sorunlara çözüm üretmesi, genelleme yapabilmesi ve geçmişteki deneyimlerden öğrenip mantık yürütebilmesi düşüncesi yer almaktadır (Nabiyev, 2012).

Bir yapay zeka metodu olan Yapay Sinir Ağları (YSA) da son yıllarda hidrolik, hidroloji ve su yapıları planlamalarında sıkça kullanılan bir kara kutu modelidir. Yapay Sinir Ağları; örneklerle ilgili bilgiler toplamakta, genellemeler yapmakta ve daha sonra hiç görmediği örnekler ile karşılaştırılınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Yapay Sinir Ağları modeli bu öğrenebilme ve genelleme özellikleri nedeniyle karmaşık problemleri başarı ile çözebilme yeteneğini ortaya koymaktadır (Ergezer, 2003).

Yapay Sinir Ağları ile ilgili ilk modellemenin temelleri bir nörofizyolog olan Warren S. McCulloch ve bir mantık bilimci olan Walter H. Pitts’in, 1943 yılında yayınladıkları bir makaleyle atılmıştır (McCulloch ve Pitts, 1943). Çalışmalarında elektrik devreleri üzerinde basit yapay sinirler modellemişlerdir. Ayrıca bu çalışma, günümüz bilgisayarlarının temelini atılmasına yardımcı olan John Von Neumann’ın 1945’te tasarladığı ENIAC ve ardından MANIAC’ı üretmesine ilham kaynağı olmuştur.

Günümüzde yapılan Yapay Sinir Ağları çalışmalarına bakıldığında genelde İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA) modelinin kullanıldığı görülür. Bu modelde katmanlar sıralı bir şekilde sadece kendinden sonraki katmana bağlıdır ve bilgiler değişikliğe uğramadan giriş katmanından çıkış katmanına aktarılır. Hızlı bir programlama yöntemi olsa da negatif tahmin üretme gibi olumsuz yönleri de bulunmaktadır.

Su yapıları çalışmalarında ve su kaynakları ile ilgili çeşitli araştırmalarda YSA’dan sıkça faydalanılmıştır. Özellikle lineer olmayan (non-linear) durumlar için YSA yöntemi, yağış – akış ilişkisinin çözümlenmesinde iyi bir performans sergilemiştir sergilemiştir (Hsu ve

diğerleri, 1995; Mason ve diğeri, 1996; Minns ve Hall, 1996; Fernando ve Jayawardena, 1998). Aci (2006), YSA kullanarak Akarçay Havzası'nın yağış - akış ilişkisini incelemiştir. Gümüş ve diğeri (2013), aylık ortalama akım verileri ile yağış verileri arasındaki ilişkiyi YSA ve ÇDR yöntemleri ile tahmin etmişlerdir. Turhan (2012), yaptığı çalışmada YSA yöntemi ile Seyhan Havzası'nın yağış - akış ilişkisini modellemiştir.

Bu çalışmada ise, ABD'nin Stony Brook Havzası üzerinde bulunan 01104480 numaralı gözlem istasyonuna ait 731 günlük yağış, sıcaklık ve akış verileri girdi olarak girilip yeni akış değerleri İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA), Çoklu Doğrusal Regresyon (ÇDR) ve Otoregresif Hareketli Ortalamalar (ARMA) yöntemleri ile tahmin edilmiştir. Elde edilen sonuçlar gerçek ölçüm sonuçları ile karşılaştırılarak bu üç yöntem değerlendirilmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Alp ve Cıgızoğlu (2004), Amerika Birleşik Devletleri Juniata Havzası'nda bulunan 3 adet yağış istasyonundan alınan günlük yağış verilerini kullanarak yeni akım değerlerini İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA) ve Genelleştirilmiş Regresyon Sinir Ağı (GRSA) ile tahmin etmeye çalışmışlardır. Çalışmada 1983-1989 yılları arasındaki 2458 adet yağış verisinin 200 tanesi modellerin eğitimi için kullanılırken 458 tanesi test aşamasında kullanılmıştır. Hata oranları Determinasyon Katsayısı (R^2) ve Ortalama Karesel Hata (OKH) ile analiz edilmiştir. Bu iki Yapay Sinir Ağı (YSA) metodu arasında İBGYSA metodunun GRSA metoduna göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Yaşar (2004), İBGYSA yöntemini kullanarak Adıyaman Meteoroloji İstasyonu Ziyaret Çayı'nın 1985-1988 yılları arasındaki eksik akım verilerini tahmin etmeye çalışmıştır. 1435 adet verinin kullanıldığı çalışmada yağış, sıcaklık ve bir gün önceki akış verileri girdi olarak kullanılıp, bir gün sonraki akış değeri tahmin edilmiştir. Verilerin 1312'si ağın eğitim aşamasında, 123 tanesi de test aşamasında kullanılmıştır. Elde edilen sonuçlarda gerçek akım değerleri ile tahmin edilen akım değerleri arasında %90 uyumluluk gözlemlenmiştir.

Kumar, Sudheer, Jain ve Agarwal (2004), Hindistan'da yer alan Malaprabha ve Krishna Nehri havzasının yağış – akış modellemesi için birer YSA modeli olan MLP (Multilayer Perceptron) ve RBF (Radial Basis Function) kullanmışlardır. MLP günümüzde de kullanılan ileri beslemeli bir ağ mantığı ile çalışmaktadır. RBF ise mantık olarak MLP ile aynı gibi olsa da RBF gizli katmandaki radyal fonksiyonlardan oluşan bir ağ kullanarak bilinmeyen yağış – akış modelini simüle etmektedir. Yaptıkları çalışmada Karnataka Sulama Departmanı'ndan alınan 1987-1991 yılları arasına ait günlük yağış ve akış verilerini kullanmışlardır. Sonuçlara göre her iki YSA modelinden RBF modelinin MLP'ye göre yağış – akışı modellemesini genellemeye zayıf olduğunu ancak her iki modelin de yağış – akış modellemesinde kullanılabilir aralıkta olduğunu göstermiştir.

Oğul (2006), Eskişehir Araştırma Enstitüsü'nden aldığı 1984-1998 yılları arasındaki saatlik yağış ve akım verilerini kullanarak Bilecik ili Kurukavak Deresi havzasının akım tahminini yapmaya çalışmıştır. 3 farklı yöntem ile (İleri Beslemeli Geri Yayılımlı Sinir Ağı, Genelleştirilmiş Regresyon Sinir Ağı ve Radyal Tabanlı Sinir Ağı) modeller yapmış

ve bunları Ortalama Karesel Hata ve Determinasyon Katsayısı yöntemleri ile kıyaslamıştır. Verilerin 1988-1989 yıllarına ait olanları modellerin eğitimi için kullanılırken 1990-1991 yıllarına ait olanı ise test aşamasında kullanılmıştır. Modeller arasında en iyi sonuçları İBGYSA modelinin verdiği görülmüştür.

Şahin (2007), Doğu Karadeniz havzası sınırları içindeki gözlem istasyonlarından alınan 1979 -1997 tarihleri arasına ait verilerle Solaklı Deresi havzasının akım değerlerini tahmin etmiştir. Bunun için bölgedeki birçok istasyondan alınan yağış, sıcaklık, nem ve akım verileri ve eksik olan veriler regresyon denklemleri ile sürekli hale getirilip İBGYSA, RTYSA, GRYSA ve ÇDR yöntemleri ile modellenmiştir. Model sonuçları R^2 ve OKH ile değerlendirilip kıyaslanmıştır. Modeller arasında en yüksek belirlilik katsayısını İBGYSA modeli verirken ÇDR ise GRYSA ile İBGYSA modelleri arasında yer almıştır. Kullanılan veri setinin kısıtlı olmasından dolayı RTYSA faydalı bir sonuç verememiştir.

Yurdusev, Acı, Turan ve İçağa (2008), yaptıkları çalışmada Akarçay Havzası'nın yakınlarında bulunan 10 yağış istasyonundan aldıkları aylık yağış ve akım değerleri ile gelecekteki aylık akım değerlerini tahmin etmişlerdir. Alınan verilerle İBGYSA ve ÇDR modelleri oluşturulmuş ve bu modellerin performansları R^2 ve OKH ile değerlendirilmiştir. İBGYSA ile elde edilen sonuçların ÇDR yöntemine göre daha iyi sonuçlar verdiğini ortaya koymuşlardır.

Okkan ve Mollamahmutoğlu (2010), Gediz Havzası'ndaki Yiğitler Çayı'nın günlük akımlarının tahmini için YSA ve ÇDR yöntemlerini kullanmışlardır. 525 numaralı Yiğitler Akım İstasyonundan alınan 01.10.2002 – 30.09.2006 tarihleri arasındaki 1461 adet günlük akım verisi ile 5615 numaralı Turgutlu Meteoroloji İstasyonundan alından yağış verilerini girdi verisi olarak kullanıp modeller oluşturmuşlardır. Verilerin %80'i MATLAB programında eğitim seti olarak kullanılırken %20'si test aşamasında kullanılmıştır. YSA ve ÇDR modellerinin performans analizleri Hata Kareler Ortalaması (HKO), Hata Kareler Ortalamasının Karekökü (HKOK) ve Determinasyon Katsayısı (R^2) ile yapılmıştır. Sadece yağış verilerininin girdi verisi olarak kullanıldığı modellerde bile YSA, ÇDR'ye göre iyi sonuçlar verirken akım değerlerin de eklendiği modellerde YSA daha anlamlı sonuçlar ortaya çıkarmıştır.

Saplıođlu ve imen (2010), yaptıkları alıřmada YSA kullanarak lümü yapılamamıř veya yeni bir istasyonun gemiř yađıř verilerini tahmin etmeye alıřmıřlardır. Bunun iin ABD Portland'da bulunan 21,107,120 ve 121 numaralı yađıř gzlem istasyonunun 2000-2009 yılları arasına ait gnlk yađıř verilerini kullanmıřlardır. 21, 120 ve 121 no'lu istasyon verileri girdi olarak kullanılırken 107 no'lu istasyona ait veriler ıktı verisi olarak ele alınmıřtır. 11 adet YSA modeli ile yapılan arařtırma sonuları E (Verimlilik Katsayısı) ve Ortalama Karesel Hata (OKH) ile kıyaslanmıřtır. Elde edilen sonular ađırlıklı ortalama ve harmonik ortalama metotları ile kıyaslanmıř ve YSA modelinin eksik yađıř verilerinin hesaplanmasında diđer iki metoda kıyasla daha stn olduđunu gstermiřtir.

Yarar (2010), yaptıđı alıřmada Susurluk Havzası'na ait Elektrik İřleri Ett İdaresinden elde edilen 7 farklı akım gzlem istasyonunun aylık ortalama akım verileri ile Devlet Meteoroloji İřleri Genel Mdrlđnden alınan aylık yađıř verilerini kullanarak yađıř ile akıř arasında bir iliřki ıkarmaya alıřmıřtır. Alınan veriler Yapar Sınır Ađları (YSA) ve ANFIS (Adaptive Neuro Fuzzy Inference System – Uyarlamalı Ađ Tabanlı Bulanık Mantık Sistemi) yntemleri kullanılarak modellenmiř ve elde edilen akım verileri ARIMA (Auto Regressive Integrated Moving Average – Otoregresif Hareketli Ortalama) modelinden elde edilen akım verileri ile karřılařtırılmıřtır. Modellerin performans deđerlerini kıyaslamak iin Determinasyon Katsayısı (R^2) ve Ortalama Karesel Hata (OKH) yntemlerinden faydalanmıřtır. 7 istasyonun 5'inden elde edilen model sonularının, llen deđerlere uygun olduđu grlmřtir.

Can (2012), yaptıđı alıřmada Bursa'da bulunan Kurudere Akım Gzlem İstasyonunun 1981-1989 yılları dıřında kalan dnemlere ait akım verilerini tahmin etmeye alıřmıřtır. Yapılması planlanan Mahmudiye Gleti'ne su temin edecek olan Fulacık Deresi mansabında bulunan Kurudere AGİ'ye ait 9 yıllık bu veriler; gletin 25m'den daha fazla olması ve baraj sınıfına girmesi nedeniyle yetersiz kalmıřtır. Kabul edilebilir akım gzlem aralıđının en az 20 yıllık olması nedeniyle Kurudere AGİ'nin bu 9 yıllık verileri LRM (Lineer Regresyon Modeli), RM (oklu Regresyon Modeli) ve YSA ile tamamlanmıřtır. 3 farklı yntem ile 5 farklı model oluřturulmuř ve elde edilen veriler gerek veriler ile karřılařtırılmıřtır. YSA ile elde edilen sonuların, halihazırda DSİ tarafından kullanılan LRM ve akademik olarak hl alıřmalarda tercih edilen RM yntemlerine yakın sonular verdiđi gzlemlenmiřtir.

Turhan (2012), Seyhan Havzası üzerinde bulunan 35 akım gözlem istasyonunun 13 tanesinden elde edilen yağış ve akım verilerini İBGYSA ve ÇDR yöntemlerinde kullanarak aylık akım değerlerini tahmin etmeyi amaçlamıştır. Verilerin %80'inin eğitim, %20'sinin test aşamasında kullanıldığı 120 farklı simülasyon yapmış ve hata oranlarını R^2 ve OMGH (Ortalama Mutlak Göreceli Hata) ile hesaplamıştır. Elde edilen verilerden İBGYSA yönteminin ÇDR yöntemine göre daha iyi sonuç verdiğini ortaya çıkarmıştır.

Gümüş, Soydan, Şimşek, Aköz ve Kırkgöz (2013), Orta Fırat Havzası'nda bulunan iki farklı gözlem istasyonundan alınan verilerle yeni akım değerlerini tahmin etmişlerdir. 2157 numaralı gözlem istasyonundan alınan aylık akım verileri ve 17204 numaralı gözlem istasyonundan alınan aylık yağış verileri ile 5 farklı duruma göre yağış ve akım değerleri girdi olarak kullanılıp, yeni akım değerleri İBGYSA, GRYSA (Genelleştirilmiş Regresyon Yapay Sinir Ağı), RTYSA (Radyal Tabanlı Yapay Sinir Ağı) ve ÇDR ile elde edilmiştir. Modellerin %70'i eğitim, %30'u test aşamasında kullanılmıştır. Modeller R^2 ve KOKH ile analiz edilmiştir. Kullanılan üç YSA modelinin de ÇDR yöntemine göre daha iyi sonuç verdiği gözlemlenmiştir.

Yavuz ve Deveci (2013), yaptıkları çalışmada Meteoroloji Genel Müdürlüğünden aldıkları Adana iline ait 7448 adet veri ile günlük ortalama sıcaklık tahmininde bulunmak için Yapay Sinir Ağları yönteminden faydalanmışlardır. 1990 ile 2004 yılları arasındaki 5500 adet veri ağı eğitimi için, 2005 ile 2011 yılları arasındaki 1948 adet veri ise ağı testi için kullanılmıştır. Dokuz adet girdi parametresi kullanılarak yapılan çalışmada çıktı olarak elde edilen ortalama günlük yağış miktarı sonuçları Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Karesel Hata (MSE) istatistikleri ile karşılaştırılmıştır. Elde edilen sonuçlarda, Yapay Sinir Ağlarının gerçek sonuçlara yakın değerler verdiği ortaya çıkmıştır.

Gemici, Ardıçlıoğlu ve Kocabaş (2013), yaptıkları çalışmada Kızılırmak Nehri'nin debisini Yapay Sinir Ağları ve Bulanık Mantık modelleri ile tahmin etmeye çalışmışlardır. Nehrin yan kollarından seçilen 5 farklı istasyonda ve 22 farklı akım şartında, bu akarsu enkesiti toplam 270 parçaya bölünerek her dilimin hız-alan yöntemi ile debisi belirlenmiştir. Taban eğimi, taban pürüzlülük katsayısı, enkesit dilim genişliği, dilimden geçen su seviyesi ve nehir enkesit genişliği değerlerinin girdi verisi olarak kullanıldığı çalışmada çıkış verisi olarak debi, Çok Katmanlı Yapay Sinir Ağı (ÇKYSA), Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ve Adaptif Tabanlı Bulanık Mantık (ANFIS) modelleri ile tahmin edilmeye

çalışılmıştır. Enkesit dilim debisi verilerinin 199 adeti Yapay Sinir Ağları modelinin eğitim verisi olarak, kalan 71 adeti de test verisi olarak kullanılmıştır. Modellerden elde edilen debi tahmin sonuçları Ortalama Mutlak Hata (MAE), Karekök Ortalama Karesel Hata (KOKH) ve Regresyon Analizi (R^2) yöntemleri ile karşılaştırılmıştır. En iyi sonuca ANFIS modeli ile ulaşılsa da ÇKYSA ve RTYSA modellerinin de belirlenen debi değerlerine ve ANFIS verilerine oldukça yakın sonuçlar verdiği görülmüştür.

Nacar (2014), üç farklı YSA modeli ile Haldizen Deresi'nin 1998-2009 yılları arasındaki günlük akım değerlerini kullanarak, ileriye yönelik akım değerlerini tahmin etmiştir. Şerah AGİ'den aldığı 4291 adet günlük akım verisinin %60'ını modellerin eğitimi için kullanırken %40'ını teste ayırmıştır. 1,2,3,4,5,6 ve 7 gün önceki akım değerleri girdi verisi olarak kullanılırken 1,3,5,7 ve 14 gün sonraki akım değerleri ÇKYSA (Çok Katmanlı Yapay Sinir Ağı), TBAYSA (Temel Bileşenler Analizi Yapay Sinir Ağı) ve ZGÖYSA (Zaman Geciktirmeli Özyineli Yapay Sinir Ağı) ile tahmin edilmiştir. Elde edilen çıktı verilerinin analizleri RMSE (Ortalama Karesel Hatanın Karekökü), R (Korelasyon Katsayısı) ve E (Nash - Cutcliffe) kriterlerine göre yapılmıştır. Tüm YSA yöntemlerinin akım tahmininde kullanılabilir olduğu çalışmalarda görülse de, ÇKYSA yönteminin diğerlerine göre daha iyi sonuçlar verdiğini ortaya çıkarmıştır.

Gümüş, Şimşek, Soydan, Aköz ve Yenügün (2015), Adana iline ait 17351 no'lu istasyondan aldıkları 1986-2008 yılları arasına ait 22 yıllık meteorolojik verileri kullanarak, bu istasyona ait aylık ortalama buharlaşma miktarını Yapay Sinir Ağı (YSA), Bulanık Mantık Yapay Sinir Ağı (ANFIS) ve Gen Ekspresyon Programlama Yöntemi (GEP) ile tahmin etmeye çalışmışlardır. İstasyondan alınan 22 yıllık ortalama sıcaklık (S), nem (N), rüzgar (R), atmosfer basıncı (B) ve güneşlenme şiddeti (GS) verileri, bu üç tahmin yönteminde giriş parametresi olarak kullanılmıştır. 1986 – 2003 yılları arasındaki veriler analizlerin eğitim sürecinde, 2003 – 2008 yılları arasındaki veriler ise test sürecinde kullanılmıştır. Elde edilen sonuçlar R^2 ve KOKH ile kıyaslanmıştır. Tüm yöntemlerin başarılı sonuçlar verdiği ortaya çıksa da ANFIS yönteminin diğerleri içinde en başarılı sonucu verdiği görülmüştür.

Turhan, Çağatay ve Çetin (2016), Aşağı Seyhan Ovası havzasında bulunan Akım Gözlem İstasyonu (AGİ) ve Çatalan Karaisalı Yağış Gözlem İstasyonu (YAGİ)'den alınan verilerle bu havzanın yağış – akış ilişkisini modellemeye çalışmışlardır. YAGİ'den alınan aylık

ortalama yağış değerleri ve AGİ'den alınan önceki akım değerli İBGYSA, GRYSA ve ÇDR ile modellenmiş olup verilerin %70'i eğitim %30'u test aşamasında kullanılmıştır. R^2 ve OKH yöntemleri ile analiz edilen modellerde 6 adet giriş verisine yer verilmiştir. Bu 6 verinin 2'si aylık ortalama yağış verisi olup kalan 4 veri AGİ'lerden alınan akım verilerinin kombinasyonundan oluşmaktadır. Her iki YSA yönteminden GRYSA'nin ÇDR'ye göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Kumar, Praveen ve Prasad (2016), yağış ve akış değerlerinin düzensiz olduğu Sarada Nehri havzasına ait 3652 günlük yağış ve akış değerlerini İBGYSA modelinde girdi verisi olarak kullanıp günlük akış değerlerini tahmin etmeye çalışmışlardır. Model sonuçlarını E_{NS} (Nash – Sutcliffe), RMSE (Root Mean Square Error), R^2 (Coefficient of Determination), MAE (Mean Absolute Error) ve DP (Different Peak) istatistiksel yöntemleri ile kıyaslamışlardır. Simüle edilen YSA modeli sonuçlarının, gözlemlenen sonuçlara oldukça yakın olduğu görülmüştür.

Turhan ve Çağatay (2016), yaptıkları çalışmada Hatay Demirköprü Köyü'nde bulunan 1907 numaralı istasyona ait 1960 yılının eksik olan aylık akım verileri tahmin etmeye çalışmışlardır. Bunun için aynı havzada yer alan 1905, 1906 ve 1908 numaralı istasyon verilerinden faydalanmışlardır. Alınan akım verileri kullanılarak İleri Beslemeli Geri Yayılımlı Sinir Ağı yöntemi ile bir model oluşturulmuştur. Bu modellerde verilerin %70'i eğitim, %30'u test verisi olarak kullanılmıştır. Model verileri Çoklu Doğrusal Regresyon ve Çoklu Doğrusal Olmayan Regresyon ile kıyaslanmıştır. Modellerin performans analizleri OMOH ve R^2 baz alınarak yapılmıştır. Eksik akım verilerinin bulunmasında İBGYSA yönteminin ÇDR ve ÇDOR yöntemlerine göre az farkla da olsa daha iyi sonuç verdiği gözlemlenmiştir.

Altunkaynak ve Başakın (2018), ABD Columbia Nehri'ne ait 1950-1960 yılları arasındaki 3650 adet günlük akım verilerini kullanarak, ileriye dönük akım tahmini yapmaya çalışmışlardır. Çalışmada YSA ve ANFIS modellerinden elde edilen akım tahmin sonuçları, ARIMA modelinden elde edilen sonuçlarla kıyaslanmıştır. Verilerin %60'ı eğitim, %40'ı test aşamasında kullanılmıştır. Modellerin performans değerleri OKH ve VK (Verimlilik Katsayısı) yöntemleri ile belirlenmiştir. Verimlilik katsayısı; ölçülen değerlere karşılık gelen tahmin değerlerinin ne oranda doğru olduğunu belirler. Buna göre en başarılı veri tahminini ANFIS modeli yapmıştır.

Yıldıran (2019), yaptığı çalışmada Porsuk Havzası'ndaki 10 akım gözlem istasyonundan ve Eskişehir ilinde ölçüm yapan 1 yağış gözlem istasyonundan alınan verilerle bir akım tahmin modeli geliştirmiştir. Yapılan model ile akım istasyonları tarafından ölçümü yapılmamış akım verilerinin tahmini amaçlanmıştır. İleri Beslemeli Geri Yayılımlı Sinir Ağı, Gen İfade Programlama yöntemi ve Çoklu Doğrusal Regresyon yöntemleri ile yapılan bu modellerin sonuçları Belirlilik Katsayısı, Ortalama Karesel Hata ve Ortalama Karesel Hatanın karekökü yöntemleri ile kıyaslanmıştır. Ölçülemeyen ve tahminin yapılması istenen akım değerleri için en başarılı sonucu İleri Beslemeli Geri Yayılımlı Sinir Ağı yöntemi vermiştir.

Fırat (2019), Göksü Deresi aylık ortalama akım değerleri ve Şile Meteoroloji Gözlem İstasyonu aylık maksimum yağış değerleri tahmini için Yapay Sinir Ağları (YSA) ve Çoklu Regresyon Analizi (ÇRA) yöntemlerini kullanmıştır. Şile Meteoroloji İstasyonu'ndan alınan 40 yıllık (1979-2018) ortalama yağış, aylık maksimum yağış, basınç, sıcaklık, nispi nem, rüzgar hızı, buharlaşma verileri, Sungur Deresi'nden alınan ortalama akım verileri ve Göksü Deresi'nden alınan debi verileri kullanılmıştır. 480 aylık toplam 11 farklı parametre içeren bu veriler ile 4 farklı senaryo üzerinden YSA ve ÇRA modeli yapılmıştır. Sonuçlar R^2 Determinasyon Sayısı ile kontrol edilip Ortalama Yüzde Hata (MAE), Ortalama Karesel Hata (MSE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) ile hata oranları kıyaslanmıştır. YSA ile elde edilen tahmin değerlerinin ÇRA'ya göre daha başarılı olduğu görülmüştür.

3. MATERYAL VE YÖNTEM

Çalışma kapsamında asıl yöntem olarak Yapay Sinir Ağları ve Otoregresif Hareketli Ortalamalar yöntemi kullanılmıştır. Bunlara ek olarak Çoklu Doğrusal Regresyon yöntemi ile de modellemeler yapılmıştır. Çalışma alanı olarak Stony Brook Rezervuarı seçilmiş ve kullanılan veriler Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınmıştır.


3.1. Çalışma Alanı

Çalışma alanı olarak Amerika Birleşik Devletleri'ndeki Massachusetts eyaletinde yer alan Waltham şehrinin 3,2 km güneybatısındaki Stony Brook Rezervuarı seçilmiştir.

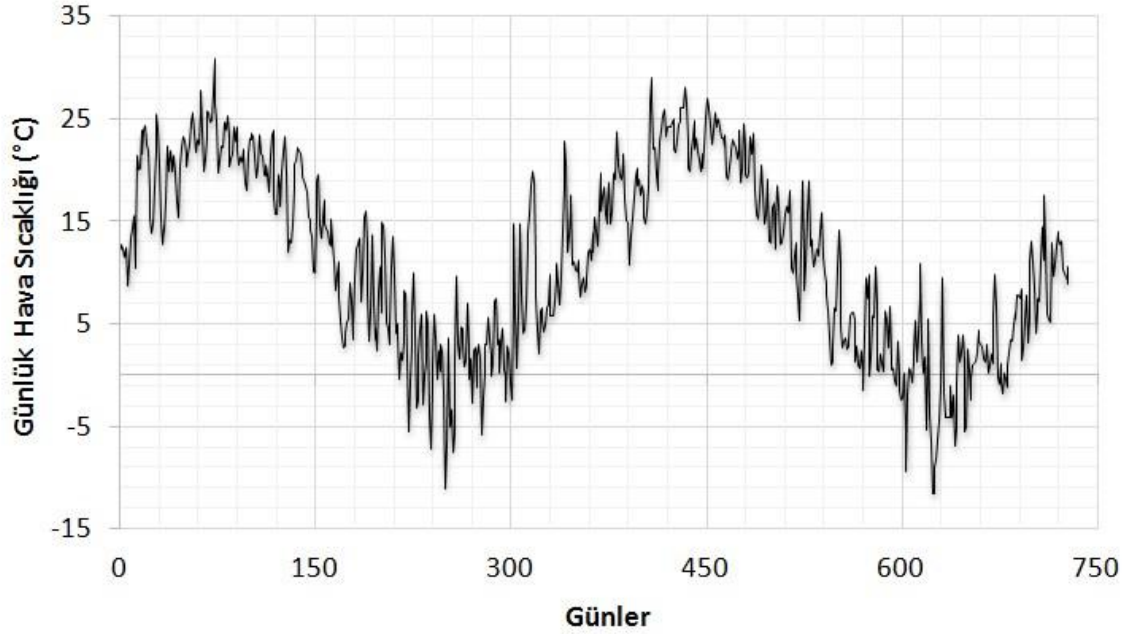
Stony Brook; Massachusetts eyaletindeki Boston şehrini doğudan batıya saran uzun bir su yoludur. Charles Nehri'nin en büyük su akışını oluşturmaktadır. MA eyaletindeki Weston şehrinden geçip Weston/Waltham sınırını oluşturur ve Waltham/Newton sınırı karşısındaki Charles Nehri'ne akar. Batısında Cherry Brook ve doğusunda Hobbs Brook olarak iki kolu bulunur. Havzasında Cambridge Rezervuarı (Hobbs Göleti), Stony Brook Rezervuarı (Turtle Göleti) ve Flint Göleti (Sandy Göleti) olarak üç tane yapay gölet barındırır. Stony Brook Rezervuarı 23,57 mi² (61 km²) drenaj alanına ve 354 000 000 US gallons (1 340 000 m³) depolama kapasitesine sahiptir. Havza ve rezervuar alanı Şekil 3.1.'de gösterildiği gibidir. Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınan 01104480 numaralı istasyon bilgileri aşağıda Çizelge 3.1.'de; sıcaklık, yağış ve akış bilgileri ise Şekil 3.2., Şekil 3.3. ve Şekil 3.4.'te grafik olarak verilmiştir. Veriler 07.05.2011-07.05.2013 tarihleri arasındaki 731 günlük yağış, akış ve sıcaklık bilgilerini içermektedir.

Çizelge 3.1. 01104480 numaralı istasyon bilgileri (USGS)

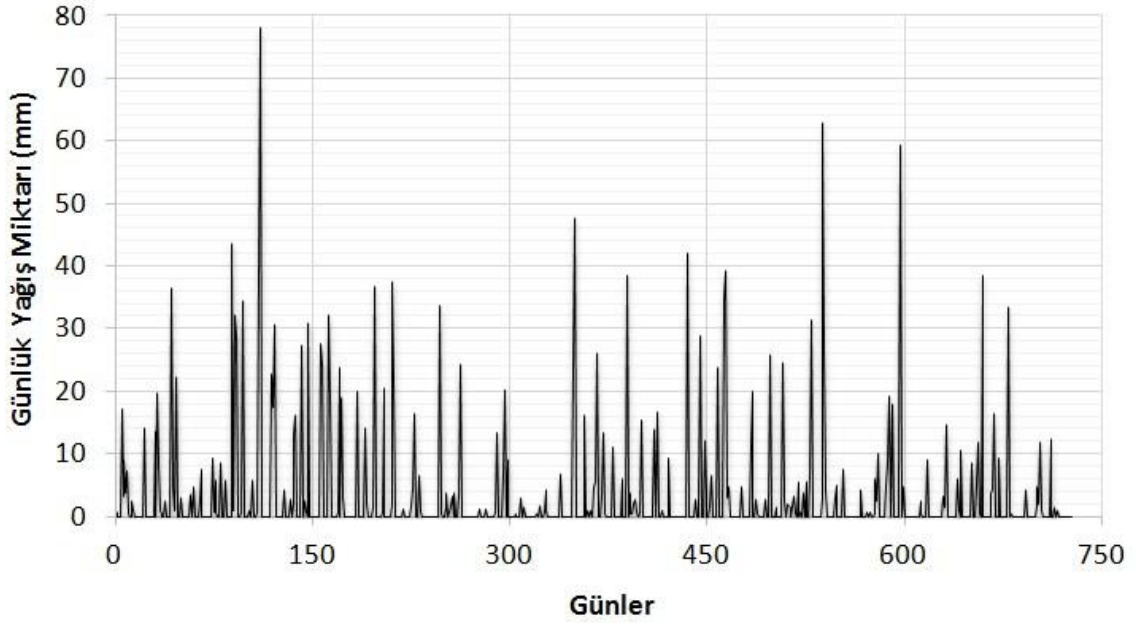
İstasyon No	Adı	Bölge	Enlem	Boylam	Veri Tarihi
1104480	STONY BROOK RESERVOIR	MA	42°35'56"	-71°26'50"	07.05.2011-07.05.2013



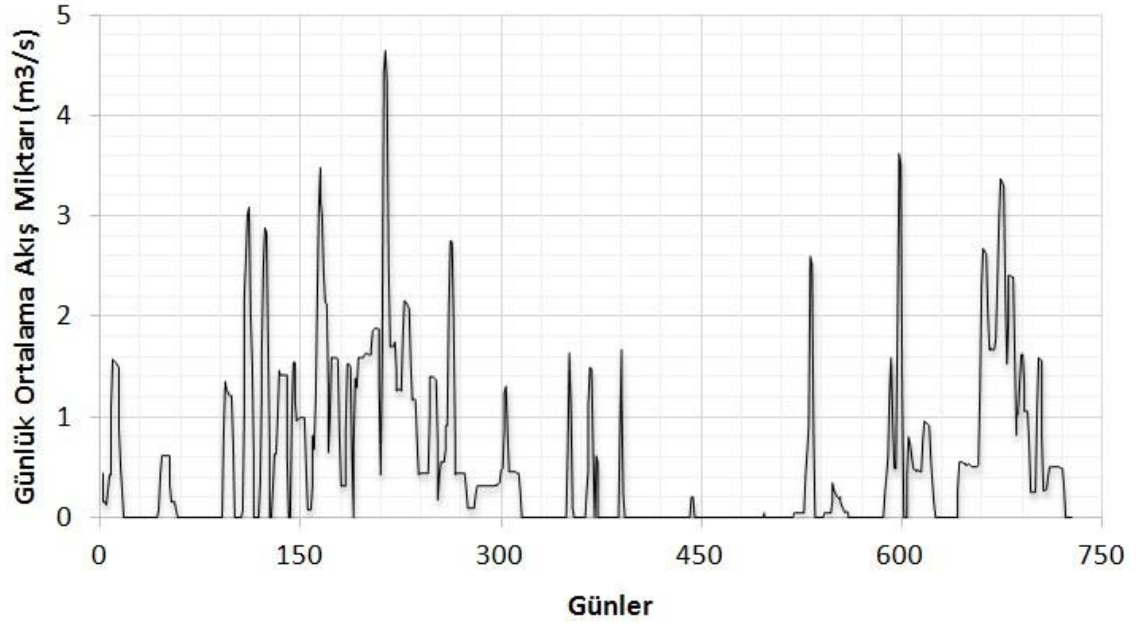
Şekil 3.1. Stony Brook Havzası / Rezervuar alanı (Goolge Maps)



Şekil 3.2. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük hava sıcaklığı değişimi grafiği (°C)



Şekil 3.3. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük yağış miktarı değişimi (mm)



Şekil 3.4. 01104480 numaralı istasyonun 2011-2013 yılları arasındaki günlük ortalama akış miktarı değişimi (m³/s)

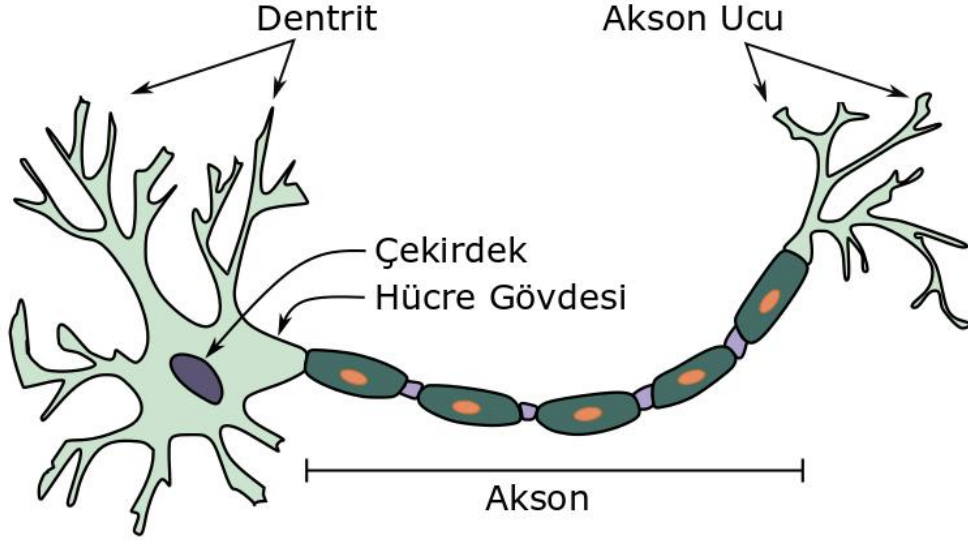
3.2. Yapay Sinir Ağları (YSA)

Su yapıları tasarımı yapılırken gelecek 50-100 yıldaki akımın bilinmesi çok büyük bir önem taşımaktadır. Tasarlanacak olan yapı taşkın veya sel gibi doğal afet durumlarını karşılayabilmenin dışında; kullanılabilir hidroelektrik santrallerine yeterli su taşıma veya çevre sulama ve su temini gibi ihtiyaç durumlarına da cevap verebilecek nitelikte olmalıdır. Bu nedenle havzaya düşebilecek su miktarının ön görülmesi gerekmektedir. Bu durum havzaya düşen yağış miktarına (veya erimelere) bağlıdır. Fakat havza özellikleri birçok fiziksel parametre ile değişkenlik göstermektedir. Havza büyüklüğü arttıkça yağıştan sonra meydana gelecek olan kayıplar (sızma, erime, buharlaşma vb.) büyük oranda değişiklik gösterebileceği için havzaya düşen “net” akışın tahmin edilmesi de çok güç olacaktır. Bu gibi durumlarda gerekli olan veriler akarsu üzerindeki yağış – akım gözlem istasyonlarından elde edilir. Fakat her akarsu üzerinde bu istasyonlar mevcut olmayabilir. Mevcut olanlarda ise veri kaybı (ölçüm cihazında arıza veya hatalı ölçüm) gibi durumlar yaşanabilir. Bu gibi durumlar havzaya ait olan bu verilerin tahmin edilmesi ihtiyacını doğurmaktadır. Günümüzde bu sebeple, yağış ile akış arasındaki ilişkinin tahmin edilmesinde belirli matematiksel tabanlı modeller kullanılmaktadır.

“Yağış - akış modelleri, 19. yüzyılın ikinci yarısında kentlerin kanalizasyon tasarımı, drenaj sistemlerinin düzenlenmesi ve dolusavak hazne tasarımıyla ilgili üç tip mühendislik sorununa çözüm getirebilmek amacıyla ortaya çıkmıştır” (Yaşar, 2004). Günümüzde ise yağış ile akış arasındaki ilişkiyi tanımlayabilmek için birçok sistem yaklaşımı metodundan faydalanılmaktadır. Bunlardan en sık kullanılanı bir kara kutu modeli olan Yapay Sinir Ağı yöntemidir. Normalde yağış ile akış arasındaki ilişki karmaşıktır ve doğrusal (lineer) değildir. Fakat birim hidrograf modelini baz alan bu yöntemde, havzadaki fiziksel parametreler dikkate alınmaz. Sadece yağışı, akışa dönüştüren lineer bir fonksiyon olarak kabul eder. Ayrıca eksik verilen hesaplanabilmesi, çok fazla parametreye ihtiyaç duymaması ve kendini eğitme döngüsü ile hata oranını azaltabilmesi gibi pozitif yönleri vardır.

İnsanoğlu varoluşundan bu yana sorunlara çözüm üretebilmek adına düşünebilme yetisi, mantıksal ilişki kurabilme kabiliyeti ve deneyimlerinden faydalanmıştır. İnsan beyni, doğası gereği diğer canlılardan farklı olarak sorunlara çözüm üretirken neden – sonuç ilişkisi arasında karmaşık bir bağlantı kurar. Kişinin yaşamı boyunca edindiği tecrübeleri

ve öğrendikleri bilgileri kullanarak, doğru ve yanlış arasında mantık yürütebilir. Biyolojik bir sinir sistemi üzerinde (Şekil 3.5.), nöronları kullanarak dentritlerle aksonlar arasında sinaptik bağlantılar kurarak bu işlemi gerçekleştirir. İki nöron arasında saniyede yaklaşık 200 işlem yapılabilir.



Şekil 3.5. Biyolojik sinir ağı yapısı (Wikipedia, 2020)

Çok karmaşık olan bu biyolojik yapı yaklaşık yüz milyar nöron ile saniyeler içinde 20×10^9 adet işlemi yapabilme kapasitesine sahiptir. Günümüzde teknolojinin geliştirdiği hiçbir bilgisayar, insan beyni kadar karmaşık bir yapıda değildir ve onun işlem yapabilme hızına ulaşamaz. Bu nedenle yüzyıllardır insan beyni ve zekası, problemlerin çözümünde bir araç olarak kullanılabilme bakımından merak konusu olmuştur.

Teknolojinin gelişimi ile birlikte insan beyninin sorunlara çözüm üretebilme yöntemi, bilgisayar programları ile taklit edilmeye çalışılmıştır. Bu çalışmaların içinde son yıllarda en yaygın olarak kullanılanlarından biri de yapay zeka tekniklerinden olan Yapay Sinir Ağları modelleridir.

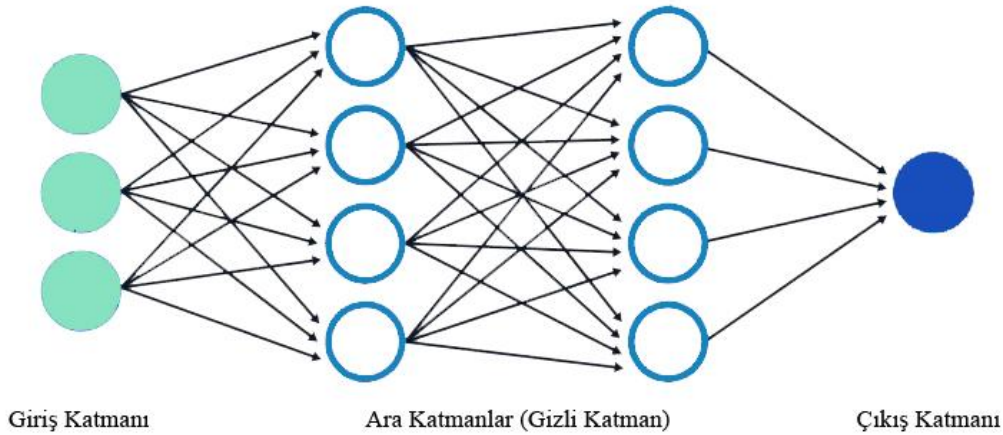
“Yapay Sinir Ağları; insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları; bir başka deyişle, biyolojik sinir ağlarını

taklit eden bilgisayar programlarıdır” (Elmas, 2003). Beyni oluşturan nöronların matematiksel olarak modellenmesi prensibine dayanmaktadır.

İnsan beyinde bir bilginin işlenmesi sinir sistemindeki iki nöron arasındaki sinaptik bağlantılarla yapılır. Dendritler bilgileri aksonlarla yeni nöronlara aktarır. İnsanın doğumundan ölümüne kadar gözlemedikleri ile birlikte bu bağlantılar sürekli yeni bağlantıları oluşturur. Yani bu süreç sürekli bir öğrenme ve gelişme döngüsü içindedir.

Yapay Sinir Ağlarında ise, sinir sistemindeki dendritleri taklit eden nöronlar bulunur. Bu nöronlara bir takım veriler girdi olarak verilir. Sistem bu girdileri farklı ağlarla birbirine bağlayarak bir çok ara işlem elemanları oluşturur. Bu işlem elemanları YSA'nın eğitime, öğrenme ve geri besleme görevlerini yerine getirmek için kullanılır. Sistemdeki tüm amaç bir takım girdilerin, “ağırlık” denilen bilginin önemini gösteren fonksiyonlarla işleme sokulup çıktı olarak alınmasıdır.

Görüldüğü üzere bu model bir eğitime sürecinden geçtiği için öğrenebilme yeteneğine sahiptir. Böylece diğer yöntemlerden ayrılır.



Şekil 3.6. Üç katmanlı YSA mimarisi

Yapay Sinir Ağının genel yapısı $n \times m$ boyutlu bir matris olarak düşünülebilir. Bu yapının içinde $n \times m$ kadar nöron bulunur. Her bir nöron içinde 0 ile 1 arasında, nöronu temsil eden bir sayı mevcut olduğu kabul edilirse bu sayı nöronun aktivasyonudur. Bu $n \times m$ adet nöron, ağın ilk katmanını yani giriş katmanını oluşturur. Ağın son katmanında ise yine 0 ile 1 arasında (yanlış ve doğru) sonuç gösteren çıktı verilerini veren nöronlar bulunur. Bu

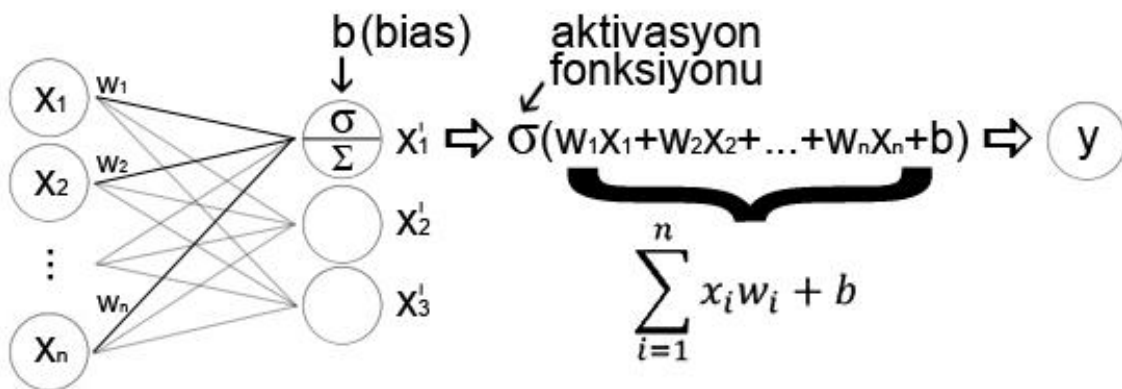
girdi ile çıktı verileri arasında ise ağı eğitilmesi ve hata oranını azaltıp sistemi doğru sonuca götürecektir. Ara katmanlar yer alır. Ağ, doğru sonuca ulaşana kadar girdi verilerini ara katmanlarda analiz eder ve birbirleri arasında bir mantık kırmaya çalışır. Ara katmandaki her nöron, girdi katmanındaki ana nöronların bir parçasını temsil eder ve istenen verinin “doğru parçasına” denk gelen ara katman nöronlarının aktivasyonları, diğer ara katman nöronlarına göre daha yüksek bir sayısal değer ile ifade edilir. Ara katman sayısı ne kadar artırılır ise bütüne yaklaşan parçalar daha iyi temsil edileceğinden ağı performansı artırılabilir.

Daha anlaşılır olması için 6 tane birbirinden farklı taşı bulunan satranç oyunu düşünülebilir. Her bir taşa birer numara verip, oyuncunun oynamak istediği taşın, sistemin arka planında aslında hangi matematiksel rakama denk geldiğini bildiren bir program yazılabilir. Yapay Sinir Ağı, sistemi seçilen sayıda parçalara ayıracak (nöron), bu parçalar arasında bir matris ilişkisi kuracak ve parçalar içinde taşın olduğu noktaya gelen kısımlara 0 ile 1 arasında bir rakam verecektir (aktivasyon). Taşı tam olarak temsil eden noktalarda nöronların aktivasyonu 1'e yakın, tam olarak temsil edemediği nöronlarda ise aktivasyonu 0'a yakın olarak atayacaktır. Daha sonra sistem yine seçilen sayıdaki ara katmanlarda bu giriş nöronlarını (taşa ait olan parçalanmış matris sisteminin her bir elemanını) parçadan tüme ulaşacak şekilde eğiterek hata oranını olabildiğince azaltıp, seçilen taşın doğru taş olma olasılığını arttıracaktır. Böylece program, oyuncunun hangi taşı seçtiğini bilecek ve yönlendirmeyi taşın hareket kuralına uygun olacak şekilde yapacaktır.

Şekil 3.7. ve Şekil 3.8.'de bilgisayar programı tarafından işlenen bir Yapay Sinir Ağı modelinin arka planı açıklanmaya çalışılmıştır. Her bir taşa 1'den 6'ya kadar numara verilmiş ve oyuncunun oynamak istediği taş piyon olarak seçilmiştir (1 numara). Model sonucunda Yapay Sinir Ağı modelinin; bu taşın piyon olduğunu ve sadece piyonun hareketlerini algılayabilmesi için ona atanan numara olan “1”e ulaşması hedeflenmiştir. Çizimin kolay olması adına piyon 90 piksele ayrılmış ve 10x9 boyutunda bir matrise çevrilmiştir.

Giriş nöronları ara katmanlara ağırlık denen parametrelerle bağlıdır. Bu ağırlık parametreleri rastgele değerlerden veya belirli aralıktaki değerleri kapsayacak şekilde seçilebilir. Ya da daha önce eğitilmiş farklı bir modelin ağırlık parametreleri de kullanılabilir. 0 olarak seçilmesi ağırlık öğrenimini durduracağından, sabit bir değer seçilmesi de tüm ağda aynı değerleri döngüye sokacağından tercih edilmez. Bu nedenle rastgele dağılımlı 0'a yakın pozitif ve negatif değerler kullanılması uygun olacaktır. Bu durumda ağırlık yapısındaki girdi verilerine x ve ağırlıklara w denilirse, çıktı verisi $y=x.w$ gibi doğrusal bir fonksiyon olacaktır. Bu fonksiyon ağırlık yapısının en yalın halini temsil etmektedir. Fonksiyondaki w ağırlık parametreleri x 'e bağlı olarak değişecektir ve model sonucu x/y gibi sınırlı bir doğrultuda hareket edecektir. Bu nedenle ağırlık yapısına x 'ten bağımsız olarak hareket etmesine olanak tanıyacak olan "b" bias değişkeni eklenir ($y=x.w+b$). Böylece hem x 'in 0 olduğu durumlarda bile öğrenme işlemi devam edecek hem de y parametresini öteleyerek ağırlık yapısını daha iyi sonuçlar vermesine olanak tanıyacaktır (satranç örneğinde bulunan ara katmanlardaki parçaların tanımlanmasındaki hassasiyet artacaktır).

Yine de bu $y=x.w+b$ fonksiyonu lineer bir fonksiyon olduğundan temel, basit bir Yapay Sinir Ağı temsil edecektir (perceptron). Gerçek hayattaki problemlere uyarlanmak istenen Yapay Sinir Ağı modelleri Şekil 3.9.'da gösterildiği gibi bir takım aktivasyon fonksiyonları ile non-linear hale getirilebilir. Böylece ağırlık yapısını daha güçlü öğrenmesi sağlanabilir. Aktivasyon fonksiyonu bulunmayan bir sinir ağı, lineer bir fonksiyon olmasının yanı sıra; güçlü bir öğrenime sahip olamayacak ve doğrusal regresyon gibi davranacaktır.

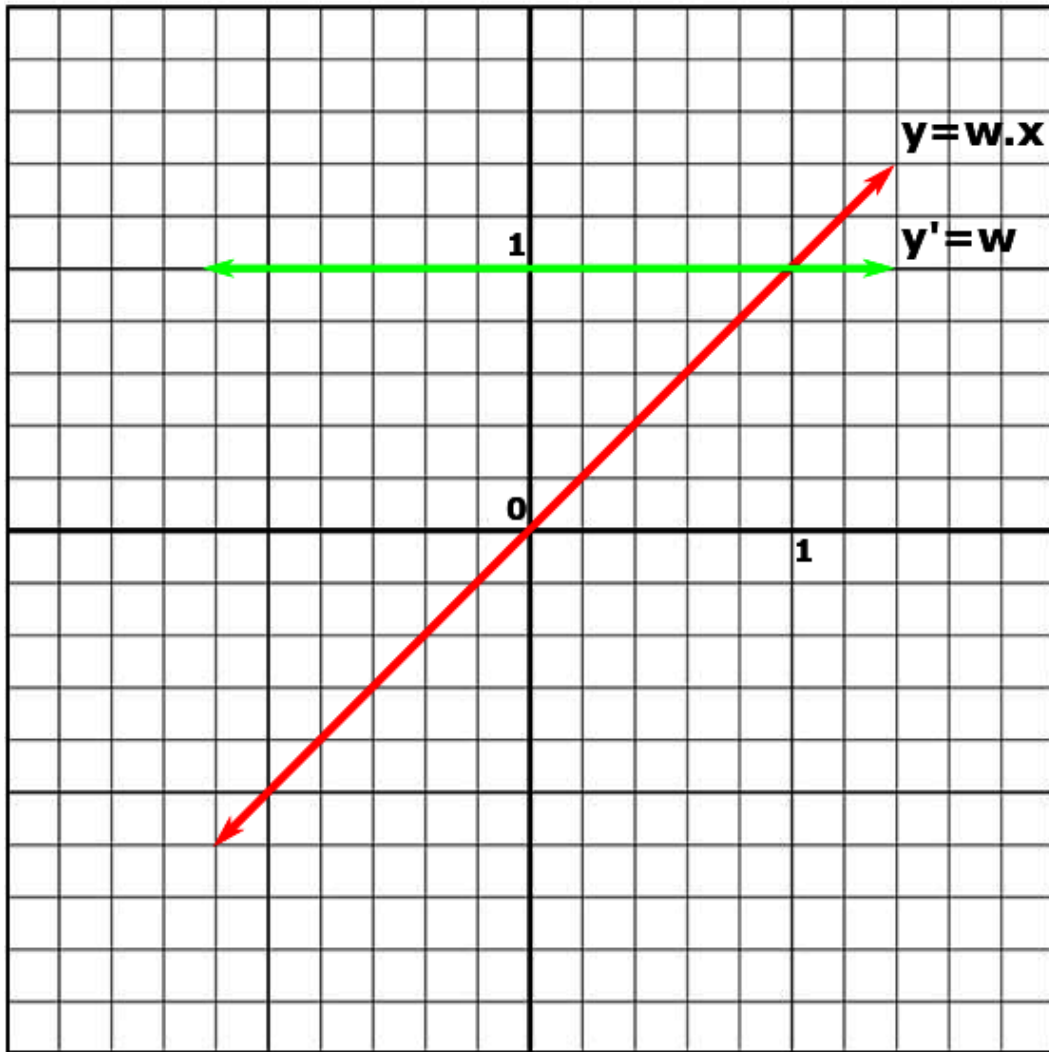


Şekil 3.9. Yapay Sinir Ağı mimarisinde aktivasyon fonksiyonunun gösterilmesi

Geriye yayımlı sinir ağlarında aktivasyon fonksiyonunun türevinden faydalanılacağı için sonuca daha hızlı ulaşabilmek adına kolay türevi alınabilir fonksiyonlar kullanılmaktadır. Çok katmanlı sinir ağı modellerinde yaygın olarak kullanılan fonksiyonlar: sigmoid fonksiyonu, tanjant hiperbolik fonksiyonu ve ReLU fonksiyonu olarak sıralanabilir.

3.2.1. Doğrusal (linear) fonksiyon


$y=w.x$ fonksiyonu, çok katmanlı YSA modelinde türevleneceği için $y=w$ gibi sabit bir fonksiyon olacaktır (Şekil 3.10.). Sonuç x 'e bağlı olmayacağı için ara katmanlardaki öğrenme işlevi gerçekleşmeyecektir. Bu nedenle geri beslemeli ağlarda kullanılmaz. Fakat "perceptron" denilen YSA'nın temel mekanizmasını oluşturduğu için doğrusal fonksiyonun önemi gözetenilemez.



Şekil 3.10. Doğrusal (linear) fonksiyon grafiği

3.2.2. Sigmoid fonksiyonu

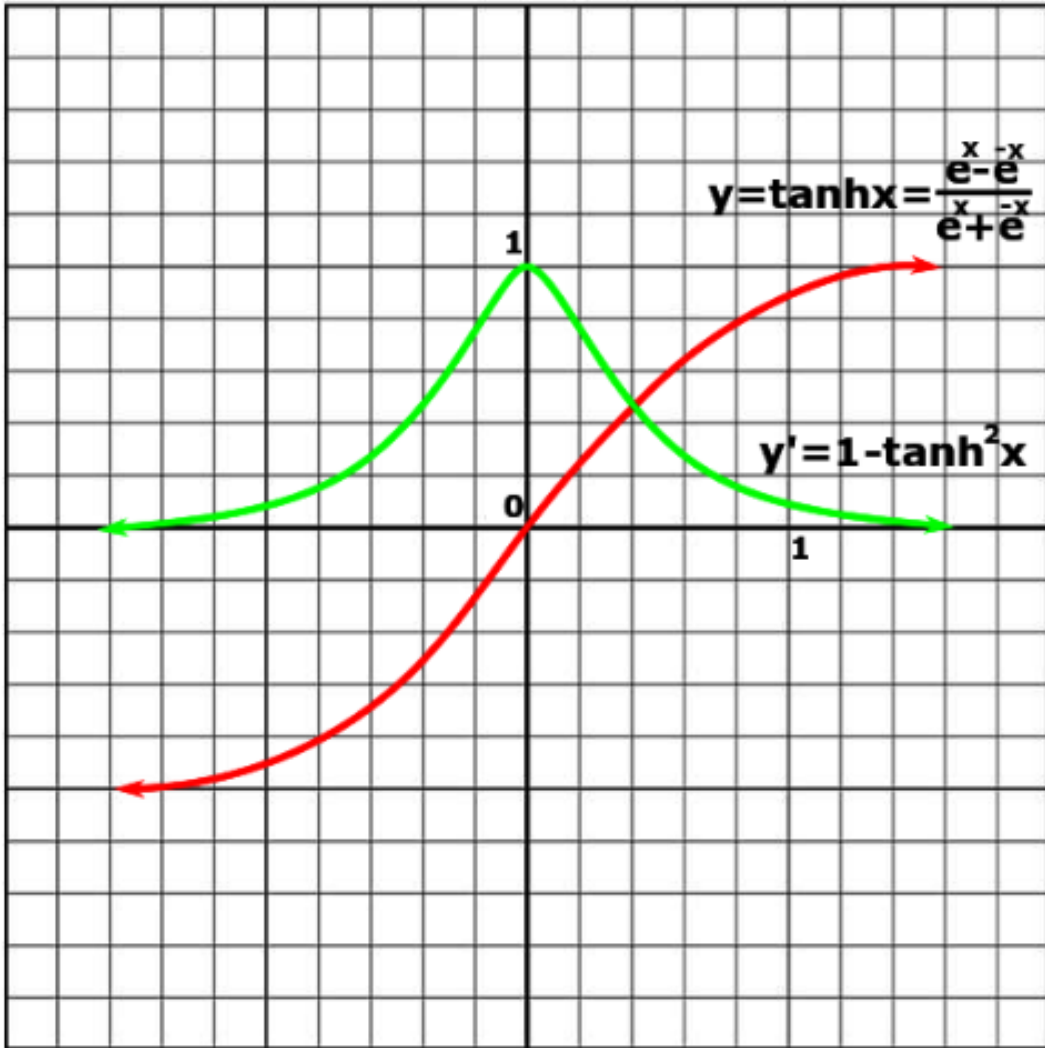
Doğrusal olmaması nedeniyle gerçek hayattaki problemlerin çözümünde sık kullanılır. x 'in $-\infty$ tüm değerleri için her zaman 0 ile 1 arasında sonuç verir. Bu da öğrenmenin sürekli olacağı anlamına gelir. Daha çok iki sınıflı olarak tabir edilen (0 ise yanlış 1 ise doğru gibi) daha basit geriye yayımlı YSA modellerinde tercih edilir. Fakat x , $-\infty$ ve $+\infty$ 'a yaklaştıkça y 'deki değişimler azalacağı için türevi de 0'a yaklaşacaktır. Bu da öğrenme işlevini minimum seviyeye çekecektir (vanishing gradient). Fonksiyonun kendisi ve türevi Şekil 3.11.'de gösterildiği gibidir.



Şekil 3.11. Sigmoid fonksiyonu grafiği

3.2.3. Tanjant hiperbolik fonksiyonu


Merkezi 0 noktası olduğundan türevi sigmoid fonksiyonuna göre 0 noktası etrafında daha yüksektir. Bu da öğrenme işlevinin artması demektir. Fakat burada da sigmoid fonksiyonunda olduğu gibi $-\infty$ ve $+\infty$ 'a yaklaştıkça türev değerleri 0'ya yaklaşacak ve öğrenme işlevi azalacaktır. Fonksiyonun kendisi ve türevi Şekil 3.12.'de gösterildiği gibidir.



Şekil 3.12. Tanjant hiperbolik fonksiyonu grafiği

3.2.4. ReLU (rectified linear unit) fonksiyonu


Girdi yani x 'in negatif deęerleri için inaktif yani 0 olarak işlem görürken, giriş deęerinin pozitif olduęu yerlerde giriş deęerine eşit doğrusal çıktı verileri üretir. Böylece sadece pozitif deęerlerde aktif olacağı için aę daha hızlı çalışacaktır. Fakat aynı nedenden ötürü negatif deęerlerde öğrenme duracaktır. Fonksiyonun kendisi ve türevi Şekil 3.13.'te gösterildięi gibidir.



Şekil 3.13. ReLU (rectified linear unit) fonksiyonu grafięi

3.2.5. İleri beslemeli geri yayımlı sinir ağı (İBGYSA)

İleri Beslemeli Geri Yayımlı Sinir Ağları, YSA'yı eğitmenin başka bir yöntemidir. Sistemde amaç, girdi verisi olarak kullanılan nöronları ara katmanlarda işleme sokarak istenilen sonuca en yakın çıktı verisini almaktır. İleri beslemeli sinir ağı yapısında, seçilen rastgele ağırlık değerleri ile elde edilen çıktı verisi beklenilenden uzak çıkabilir. Bu durumda aranılan sonuca yakın olan çıkış nöronunun aktivasyonunu arttırmak, diğer nöronların aktivasyonunu düşürmek doğru bir yol olacaktır. İşte bu amaçla “Gradient Descent” (hatayı minimize edecek türev algoritması) kullanılır. Beklenen çıkış verisi ile hesaplanan çıkış verisi arasındaki hata hesaplanır. Bu hata çıkış nöronundan tekrar kendisine veya diğer giriş nöronlarına aktarılır. Fakat çıkış nöronlarının aktivasyonu doğrudan değiştirilemeyeceğinden hata oranı ile ağırlık değişim miktarı matematiksel olarak hesaplanır ve elde edilen sonuç bias ve ağırlıklar vasıtasıyla dağıtılarak, istenilen çıkış verisini elde edilene kadar geriye doğru işleme sokulur. Önceki katmanlardaki aktivasyonu yüksek olan nöronlar ve ağırlıklar bu şekilde daha da arttırılmış olacak ve çıkış nöronu üzerinde daha etkili sonuçlar doğuracaktır. Bu da demek oluyor ki; aslında geriye yayılım işlemi, çok katmanlı ileri beslemeli sinir ağında ağırlıkların eğitimi için kullanılan bir yöntemdir.



Şekil 3.14. İleri Beslemeli Geri Yayımlı Sinir Ağı mimarisi

Geri yayılım algoritması adım adım incelenecek olursa:

Sinir ağı üzerindeki çıkış nöronu; ağırlık ve bias üzerlerindeki değişikliklerden etkilenir. Nöronların üzerindeki hassas değişimler, çıkış nöronunda doğruluğa yakınsamalar yapılmasına olanak tanıyacaktır.

Genel anlamda bir geri yayılım algoritması aşağıdaki gibi 4 adımdan oluşur:

$$1- \delta^L = \nabla_a C * \sigma'(Z^L) \quad (3.1)$$

$$2- \delta^l = ((\omega^{l+1})^T \delta^{l+1}) * \sigma'(Z^l) \quad (3.2)$$

$$3- \frac{dC}{db_j^l} = \delta_j^l \quad (3.3)$$


$$4- \frac{dC}{d\omega_{jk}^l} = a_k^{l-1} \delta_j^l \quad (3.4)$$

Fakat bu çok kompleks bir yapının genel bile olsa kapalı halini temsil etmektedir. Döngüyü en başından ele almak olayı daha anlaşılır hale getirecektir.

Geri besleme, yani ağı eğitiminin, bias ve ağırlıklar üzerinden yapıldığı bilinmektedir. Ağı içeriği ise aşağıdaki gibidir:

$$1- c = (\omega_1, b_1, \omega_2, b_2, \omega_3, b_3 \dots) \quad (3.5)$$

Ağın son halkasındaki nöronlara dikkat edilecek olursa:



Şekil 3.15. Yapay Sinir Ağı modelinin veri çıkışı kısmı

Bu yapı için eğitim örneği:

$$2- C = (a^L - y)^2 \text{ olacaktır.} \quad (3.6)$$

Bu ağın son nöronu için (nöronun kendisi aktivasyon ile tanımlanacak olursa), aktivasyonu ω_L ağırlığı ile belirlenirse, yapı genel itibari ile:

$$3- a^L = \sigma(\omega^L a^{(L-1)} + b^L) \text{ olacaktır.} \quad (3.7)$$

Aktivasyon fonksiyonundan sonraki kısmı Z^L olarak gösterilirse;

$$4- a^L = \sigma(Z^L) \text{ halini alır.} \quad (3.8)$$

Bu küçük sinir ağı parçasının eğitiminde ω^L nin hassasiyeti C değerini etkileyeceğinden, sonuç C'nin ω^L ye göre türevi olacaktır. $(\frac{dC}{d\omega^L})$

Böylece ω^L üzerinde yapılacak hassas değişimlerde Z^L de etkilenecektir.

Bu terimler arasındaki değişimin oranı da aşağıdaki ifadeyi verecektir.

$$5- \frac{dC}{d\omega^L} = \frac{dZ^L}{d\omega^L} \frac{da^L}{dZ^L} \frac{dC}{da^L} \quad (3.9)$$

Buna "Chain Rule" yani "Zincir Kuralı" denir. Bu üç yapının çarpımı ω^L de yapılan hassas değişimlerin C'de nasıl sonuçlar doğurduğunu gösterecektir.

Yukarıdaki 4 numaralı işlemin açılımı yazılacak olursa da:

$$6- \frac{dZ^L}{d\omega^L} = a^{(L-1)}, \frac{da^L}{dZ^L} = \sigma'(Z^L), \frac{dC}{da^L} = 2(a^L - y) \quad (3.10)$$

olarak yazılabilir. Burada en baştaki terime dikkat edilecek olursa, bu nöronda $(a^{(L-1)})$ yapılacak değişikliğin $(d\omega^L)$ son nöronu etkileyeceği miktar, nöron ne kadar güçlü ise o kadar fazla olacaktır. Bu da ancak ağın eğitilmesi ve hata oranının her süreçte minimale çekilmesi ile mümkün olduğunu göstermektedir.

3.3. Otoregresif Hareketli Ortalamalar Modeli (ARMA)

George Box ve Gwilym Jenkins tarafından 1976'da temeli atılan ve Box - Jenkins metodu olarak da bilinen zaman serisi yöntemidir. Bir olayın geleceği ile ilgili tahmin yürütülmek istendiğinde zaman serisi kullanılabilir. Bir zaman serisinin bugünkü ve geçmişteki değerine bakılarak gelecekte alacağı değer tahmin edilebilir. Box – Jenkins metodu da kısa süreli stokastik zaman serilerinin tahmininde başarılı bir yöntemdir.

“Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanma ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif hem de hareketli ortalama parametrelerinin alınması birçok faydalar sağlamaktadır. Bu düşünce ARMA(p,q) modelini ortaya çıkarmıştır” (Kayım, 1985).

ARMA(p,q) modeli; AR(p) otoregresif kısım ve MA(q) hareketli ortalamalar kısmından oluşur. Buradaki p otoregresif kısmın derecesini, q ise hareketli ortalamalar kısmın derecesini göstermek için kullanılır. AR(p) ifadesi en genel hali ile aşağıdaki gibidir:

$$y_t = c + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \varepsilon_t \quad (3.11)$$

Burada y_t zaman serisini, β_p model parametresini, c sabit terimi ve ε_t hata terimini göstermektedir. MA(q) ifadesi ise en genel haliyle aşağıdaki gibidir:

$$y_t = \varepsilon_t + a_1 \varepsilon_{t-1} + a_2 \varepsilon_{t-2} + \dots + a_q \varepsilon_{t-q} \quad (3.12)$$

Burada y_t zaman serisini, a_q model parametresini, ε_t ise hata terimini göstermektedir.

Görüldüğü üzere AR(p) modelinde zaman serisi, geçmiş dönemdeki değerlerine ve stokastik olan hata terimine bağılıyken; MA(q) modelinde ise zaman serisi, şimdiki ve geçmiş dönemdeki hataların ağırlıklı toplamına eşittir.

İkisinin bir araya geldiği ARMA(p,q) ise aşağıdaki gibi gösterilebilir:

$$y_t = c + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \varepsilon_t + \varepsilon_t + a_1 \varepsilon_{t-1} + \dots + a_q \varepsilon_{t-q} \quad (3.13)$$

3.4. Çoklu Doğrusal Regresyon (ÇDR)

Çoklu Doğrusal Regresyon; bir bağımlı değişken (hedef veya sonuç) ile birden çok bağımsız değişken arasındaki doğrusal bağlantıyı incelemek için kullanılır. Örneğin kan basıncının tahmininin yapılması istenilen bir haftalık egzersiz programında boy, kilo, yaş, cinsiyet bağımsız değişkenler; kan basıncı ise bağımlı değişken olacaktır.

Bağımlı değişken y , bağımsız değişkenler ise x ile ifade edilirse aralarındaki ilişki;

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (3.14)$$

olarak yazılacaktır.

Burada $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ bilinmeyenlerine Regresyon Katsayısı denir. ε ise hata terimi olacaktır.

β yani Regresyon Katsayısını basitçe açıklamak gerekirse; bağımsız değişkenler ile y , yani gözlenen bağımlı değişken arasındaki ilişkinin gücünü ifade eder.

Herhangi bir β_n Regresyon Katsayısı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kaldırıldığında) x_j değişkeninde ortaya çıkan bir birimlik değişmeye karşılık y değişkenindeki beklenen değişiklik miktarını vermektedir (Alpar, 2003). Bunun karesi ise (R^2) yani Belirleme (Determinasyon) Katsayısı; bağımsız değişkenin, bağımlı değişkenin varyasyonu ile ne kadar doğru açıklanabildiğini gösterir. R^2 değeri 0-1 arasında olmalıdır. R^2 'nin 1'e yaklaşması bağımlı değişkenin, bağımsız değişkenlerle iyi açıklanabildiği anlamını ifade eder. R^2 değeri ne kadar yüksek olursa model, verilere o kadar iyi uyum sağlıyor demektir.

Hata terimi ise modelin, bağımsız değişkenlerle bağımlı değişkenler arasındaki ilişkiyi tam olarak ifade edemediğinin göstergesidir. Modelin teorik değeri ile gözlemlenen gerçek değeri arasındaki fark için açıklanan regresyon çizgisindeki¹ sapmaların toplamını temsil eder (Hayes, 2020).

¹Regresyon Çizgisi: Bir bağımsız değişken ile bir bağımlı değişken arasındaki korelasyonu belirlemeye çalışırken bir analiz noktası olarak kullanılır.

4. ÇALIŞMADA KULLANILAN DEĞERLENDİRME KRİTERLERİ

4.1. R² Belirleme (Determinasyon) Katsayısı

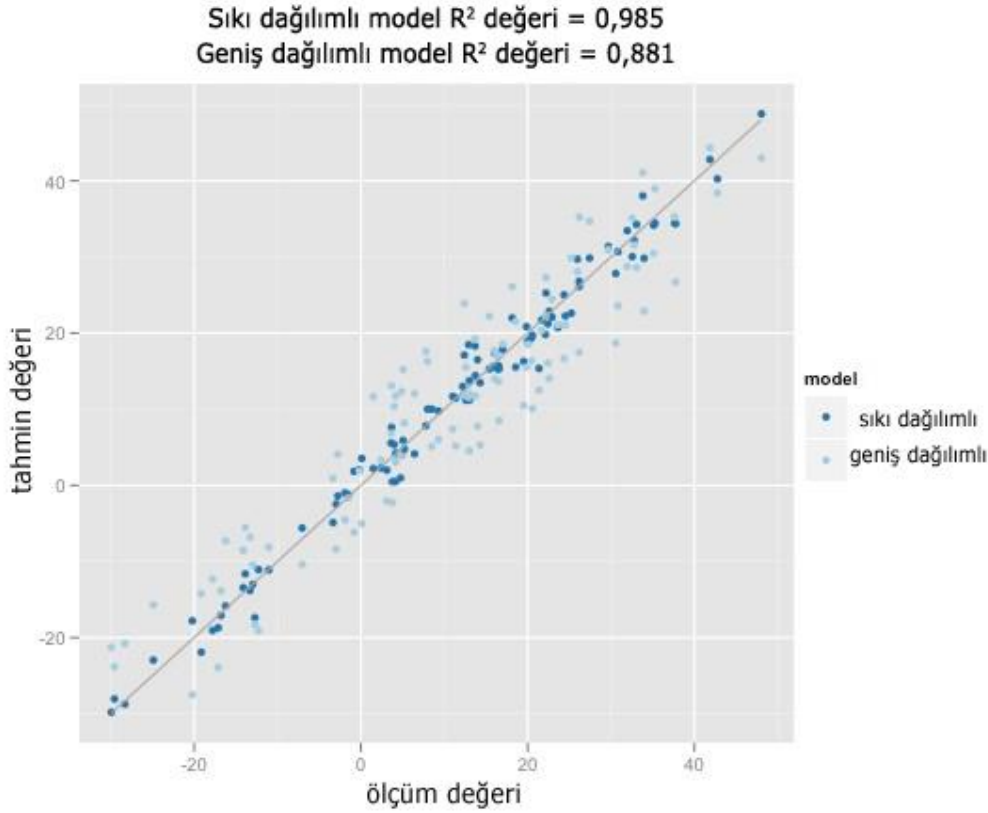
R yani Kolerasyon Katsayısı; (Correlation Coefficient) x ile y arasındaki değişimin bir göstergesidir. Yani bir istatistiksel analiz modelinde x ile y arasındaki doğrusal ilişkinin gücünü ifade eder. x ile y arasındaki kolerasyon güçlü olduğunda, doğrusallık y'deki değişimi daha iyi açıklayacaktır.

Kolerasyon ile Regresyon birbiriyle bağlantılı olsa da farkları mevcuttur. Kolerasyonda iki değişken arasında neden sonuç ilişkisi bulunmak zorunda değildir. Sadece iki değişken arasındaki ilişkinin yönü ve değişim gücü arasında bilgi verir. -1 ile +1 arasında değerler alır. +1 değer alması modelinin mükemmel bir pozitif doğrusallık içinde olduğunu gösterir. -1 değer alması ise modelin mükemmel negatif doğrusal ilişki içinde olduğunu gösterir (ters orantılı ilişki). R değerinin 0 olması değişkenler arasında ilişki olmadığını gösterir. Regresyonda ise iki veya daha fazla değişken arasında neden sonuç ilişkisine bağlı olarak bir denklem yazılır ve bağımlı değişken üzerinde, bağımsız değişkenlerin etkisi incelenir.

R² yani Belirleme Katsayısı (Coefficient of Determination ya da Determinasyon Katsayısı) ise; x ile y arasındaki kolerasyonun karesidir. Bir diğer anlamda; doğrusal bir modelde açıklanmaya çalışılan sonuç değişkeni varyasyonunun¹ yüzdesini ifade eder. Yani y değişkenindeki varyansın regresyon modeli ile nasıl açıklandığının bir ölçüsüdür. (Regresyon modelinin gerçeği ne denli yansıtılabildiğinin yüzde olarak ölçütüdür.)

R² hesabı, regresyon denkleminin verilerle olan uyumunu gösterir. Sonuçların 0 ile 1 arasında çıkması beklenir. R² değeri 1'e (%100) ne kadar yaklaşırsa modelin o kadar gerçeğe yakın olduğu anlaşılır. %85 ile %100 arasında çıkan bir değer modelin performans değeri açısından verilerimize uygun olduğu anlamına gelir. Şekil 4.1.'de iki farklı R² değerinin regresyon çizgisi üzerindeki dağılımları gösterilmiştir

¹Varyasyon: Ufak değişimler veya yayılım. Veri kümesinin ne kadar değiştiğinin açıklanmasının bir yolu.



Şekil 4.1. R^2 değerlerinin regresyon çizgisi üzerinde gösterimi (Quora, 2018)

4.2. Ortalama Mutlak Hata (OMH-MAE)

Ortalama Mutlak Hata; regresyon modelleri için kullanılan kayıp fonksiyonlarından (loss function) biridir. Tahmin edilen değer ile gerçek değer arasındaki mutlak farkın toplanmasıdır. Bir dizi tahmin serisindeki hataların ortalama büyüklükleri ölçülür, yönlerine dikkat edilmez. 0 ile ∞ arasında değer alır. 0'a yakın sonuç vermesi model performansının iyi olduğu anlamına gelir. Aşağıdaki şekilde hesaplanır:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

4.3. Ortalama Karesel Hata (OKH-MSE)

Ortalama Karesel Hata; bir regresyon çizgisinin bir dizi noktaya ne kadar yakın olduğunu anlatır. Bunu, noktaların regresyon çizgisine düşey uzaklıklarını alıp karelerini oluşturarak yapar. Burada karelerinin kullanılmasının en önemli nedenlerinden biri; regresyon çizgisinin üstündeki ve altındaki değerlerinin toplamının 0'a eşit olabilme ihtimalidir.

Mesafelerin karelerinin alınması bu ihtimali ortadan kaldırır. Böylece Ortalama Mutlak Hata gibi 0 ile ∞ arasında değer alırlar. Burada mutlak değer kullanılmamasının nedeni, uzaklıkların karelerini alarak noktaları regresyon çizgisine daha da yaklaştırarak daha iyi sonuçlar alabilmektir. Hata yönüne karşı da duyarsız olacağı için, modelin OMH gibi 0'a yakın sonuçlar vermesi performansının iyi olduğu anlamına gelecektir. Hesaplaması aşağıdaki şekilde yapılır:

$$\text{MSE} = \frac{1}{n} \sum_i^n (y_i - \hat{y}_i)^2 \quad (4.2)$$



5. ARAŞTIRMA BULGULARI VE TARTIŞMA

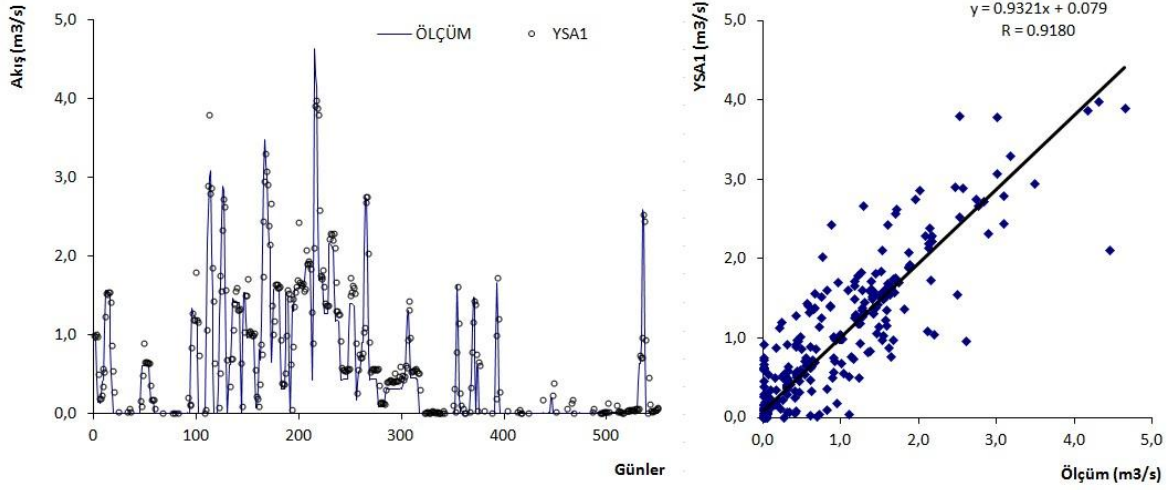
Yağış - akış ilişkisi için yapılan bu çalışma kapsamında, 01104480 numaralı istasyondan toplam 731 günlük veri toplanmıştır. Elde edilen veriler kullanılarak İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA), Çoklu Doğrusal Regresyon (ÇDR) ve Otoregresif Hareketli Ortalamalar Modeli (ARMA) olarak üç farklı çalışma yapılmıştır. Çalışmada verilerin 550 adedi yani %75'i eğitim sürecinde, kalan 181 adedi ise test aşamasında kullanılmıştır. Çalışmadaki üç model için üçer adet de değerlendirme yapılmıştır. Modellerin tahmin sonuçları R^2 Hesabı / R Square Calculation, Ortalama Mutlak Hata / Mean Absolute Error (OMH / MAE) ve Ortalama Karesel Hata / Mean Square Error (OKH / MSE) kriterlerine göre değerlendirilmiştir.

Modellerde sıcaklık (T), yağış (P) ve akış (Q) verileri ile bunların geri zamanlı verileri girdi verisi olarak kullanılmıştır ve Çizelge 5.1.'de gösterildiği gibidir.


Çizelge 5.1. Modellerde kullanılan girdi verileri

MODEL	GİRDİ VERİSİ
YSA1	T, P, Q, Q_{t-1}
YSA2	$T, P, P_{t-1}, Q, Q_{t-1}$
YSA3	$T, P, P_{t-1}, Q, Q_{t-1}, Q_{t-2}$
ÇDR1	T, P, Q, Q_{t-1}
ÇDR2	$T, P, P_{t-1}, Q, Q_{t-1}$
ÇDR3	$T, P, P_{t-1}, Q, Q_{t-1}, Q_{t-2}$
ARMA(1,1)	T, P, Q, Q_{t-1}
ARMA(2,2)	$T, P, P_{t-1}, Q, Q_{t-1}$
ARMA(3,3)	$T, P, P_{t-1}, Q, Q_{t-1}, Q_{t-2}$

Oluşturulan üç modelin eğitim ve test grafikleri YSA, ÇDR ve ARMA için sonraki sayfada gösterildiği gibidir.




Şekil 5.1. YSA model 1 eğitim sonuçları için dağılım ve saçılım grafikleri

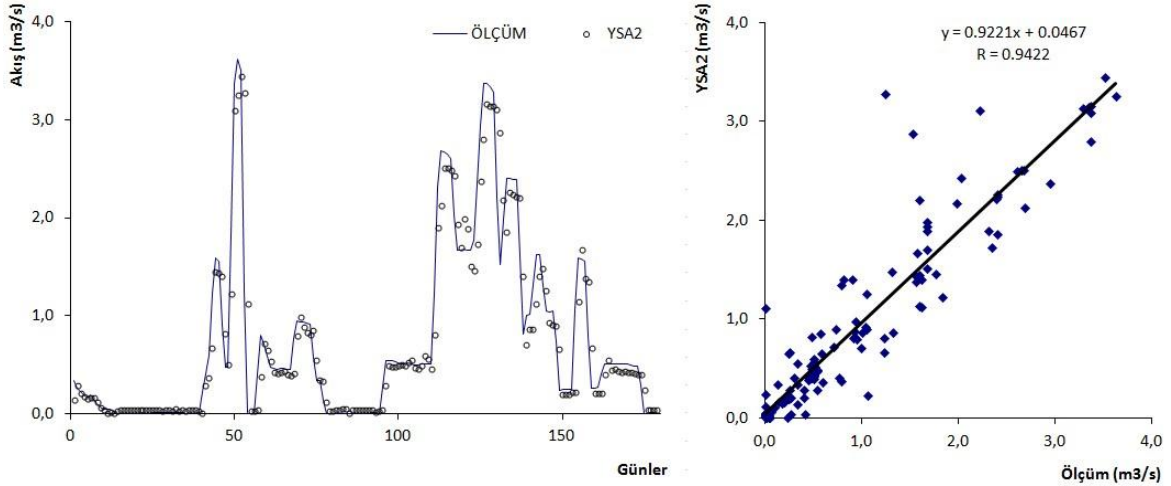


Şekil 5.2. YSA model 1 test sonuçları için dağılım ve saçılım grafikleri

1 numaralı YSA modelinde günlük sıcaklık, yağış, akış ve akışın geri zamanlı verileri (Q_{t-1}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9238$ olarak elde edilmiştir. Bu nedenle modelden elde edilen tahmin sonuçları gerçek verilere yakın gibi görülse de, Şekil 5.2.'de de görüldüğü üzere, veriler regresyon çizgisi dışına saçılma eğilimi göstermektedir.




Şekil 5.3. YSA model 2 eğitim sonuçları için dağılım ve saçılım grafikleri

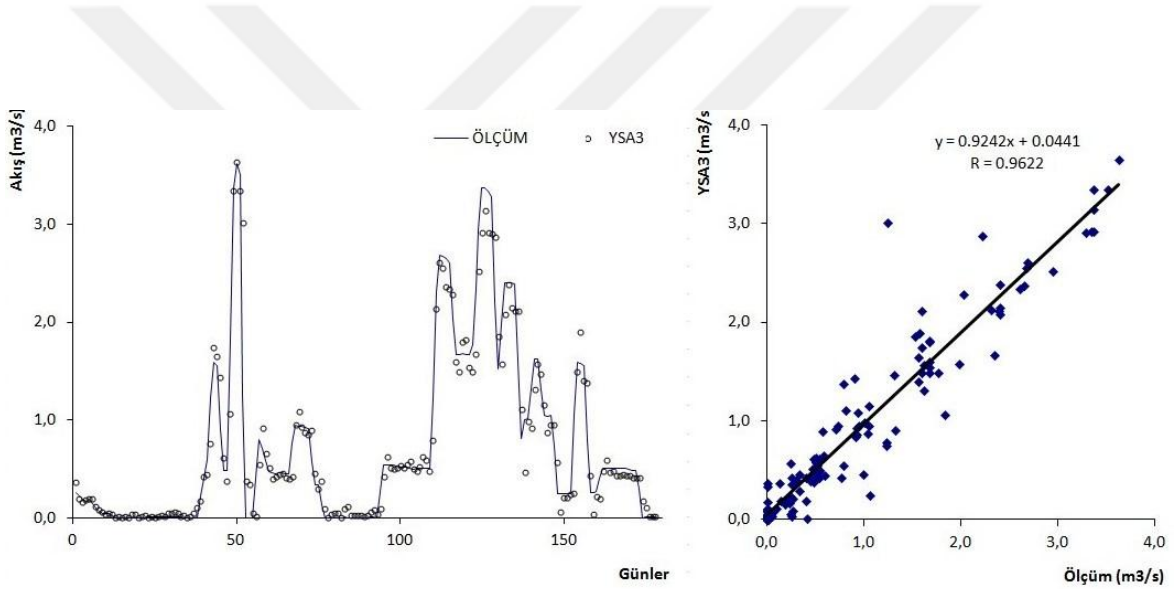


Şekil 5.4. YSA model 2 test sonuçları için dağılım ve saçılım grafikleri

2 numaralı YSA modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9422$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere yakınlık göstermektedir. Fakat R^2 Determinasyon Katsayısı 0,8877 olarak elde edilmiştir ve 1'e daha da yaklaştırılabilir. Şekil 5.4.'teki saçılım grafiğinde verilerin tam olarak regresyon çizgisi etrafına toplanmadığı gözlemlenebilmektedir.

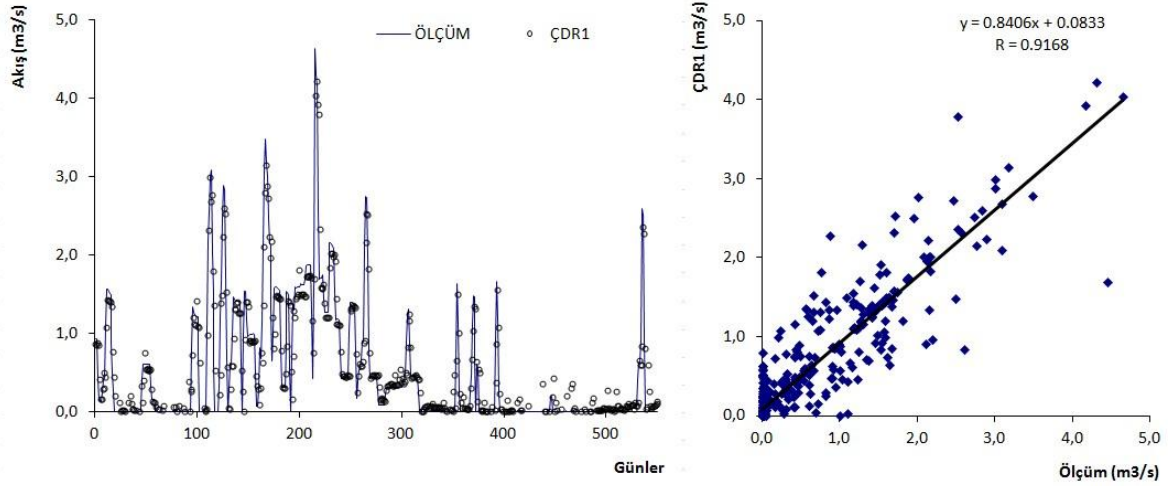


Şekil 5.5. YSA model 3 eğitim sonuçları için dağılım ve saçılım grafikleri

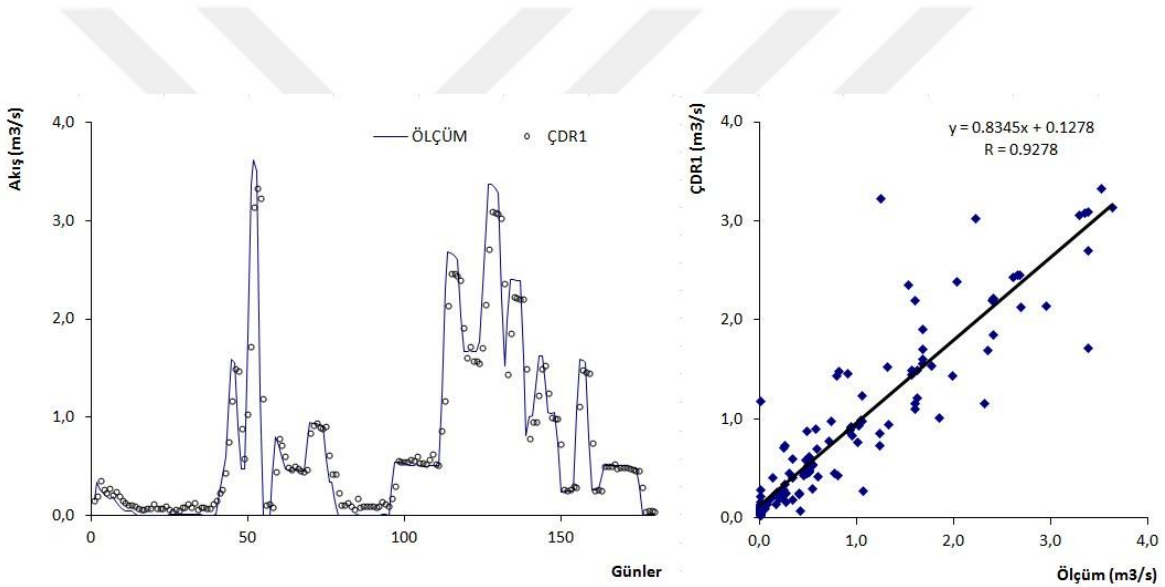


Şekil 5.6. YSA model 3 test sonuçları için dağılım ve saçılım grafikleri

3 numaralı YSA modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1} , Q_{t-2}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9622$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere çok büyük yakınlık göstermektedir. R^2 Determinasyon Katsayısı ise 0,9258 olarak elde edilmiş ve 1'e en yakın sonucu veren model olmuştur. Şekil 5.6.'da da görüldüğü üzere verilerin regresyon çizgisi etrafındaki dağılımı, diğer iki modele göre daha sıktır.




Şekil 5.7. ÇDR model 1 eğitim sonuçları için dağılım ve saçılım grafikleri

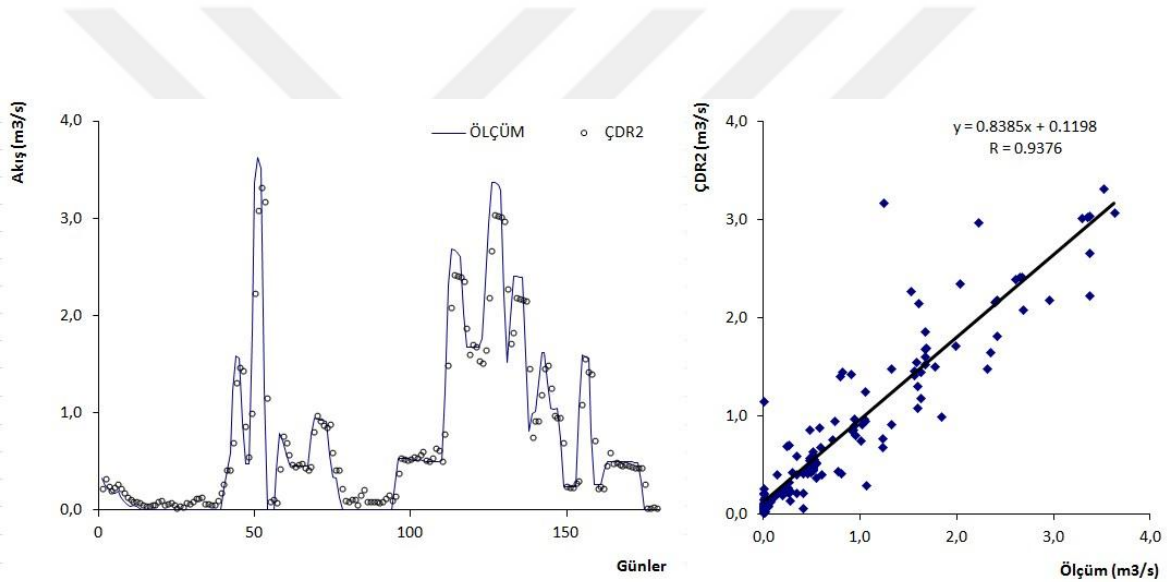


Şekil 5.8. ÇDR model 1 test sonuçları için dağılım ve saçılım grafikleri

1 numaralı ÇDR modelinde günlük sıcaklık, yağış, akış ve akışın geri zamanlı verileri (Q_{t-1}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9278$ olarak elde edilmiştir. Bu nedenle modelden elde edilen tahmin sonuçları gerçek verilere yakın gibi görülse de, Şekil 5.8.'de de görüldüğü üzere, veriler regresyon çizgisi dışına saçılma eğilimi göstermektedir.




Şekil 5.9. ÇDR model 2 eğitim sonuçları için dağılım ve saçılım grafikleri




Şekil 5.10. ÇDR model 2 test sonuçları için dağılım ve saçılım grafikleri

2 numaralı ÇDR modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9376$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere yakınlık göstermektedir. Fakat R^2 Determinasyon Katsayısı 0,8790 olarak elde edilmiştir ve 1'e daha da yaklaştırılabilir. Şekil 5.10.'daki saçılım grafiğinde verilerin tam olarak regresyon çizgisi etrafına toplanmadığı gözlemlenebilmektedir.




Şekil 5.11. ÇDR model 3 eğitim sonuçları için dağılım ve saçılım grafikleri

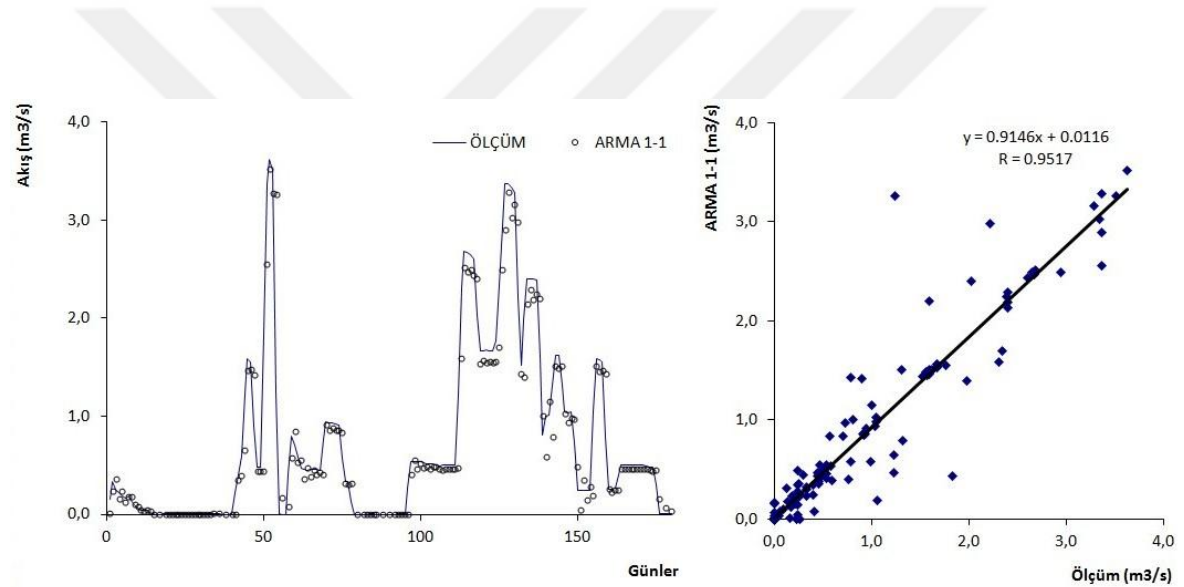


Şekil 5.12. ÇDR model 3 test sonuçları için dağılım ve saçılım grafikleri

3 numaralı ÇDR modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1} , Q_{t-2}) girdi verisi olarak kullanılıp, korelasyon katsayısı $R=0,9557$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere çok büyük yakınlık göstermektedir. R^2 Determinasyon Katsayısı ise 0,9133 olarak elde edilmiş ve 1'e en yakın sonucu veren model olmuştur. Şekil 5.12.'de de görüldüğü üzere verilerin regresyon çizgisi etrafındaki dağılımı, diğer iki modele göre daha sıktır.




Şekil 5.13. ARMA(1,1) eğitim sonuçları için dağılım ve saçılım grafikleri




Şekil 5.14. ARMA(1,1) test sonuçları için dağılım ve saçılım grafikleri

1 numaralı ARMA(1,1) modelinde günlük sıcaklık, yağış, akış ve akışın geri zamanlı verileri (Q_{t-1}) girdi verisi olarak kullanılarak ARMA zaman serisi 1 kez ötelenmiş ve modelin korelasyon katsayısı $R=0,9517$ olarak elde edilmiştir. Bu nedenle modelden elde edilen tahmin sonuçları gerçek verilere yakın gibi görülsede, Şekil 5.14.'te de görüldüğü üzere, veriler regresyon çizgisi dışına saçılma eğilimi göstermektedir.




Şekil 5.15. ARMA(2,2) eğitim sonuçları için dağılım ve saçılım grafikleri

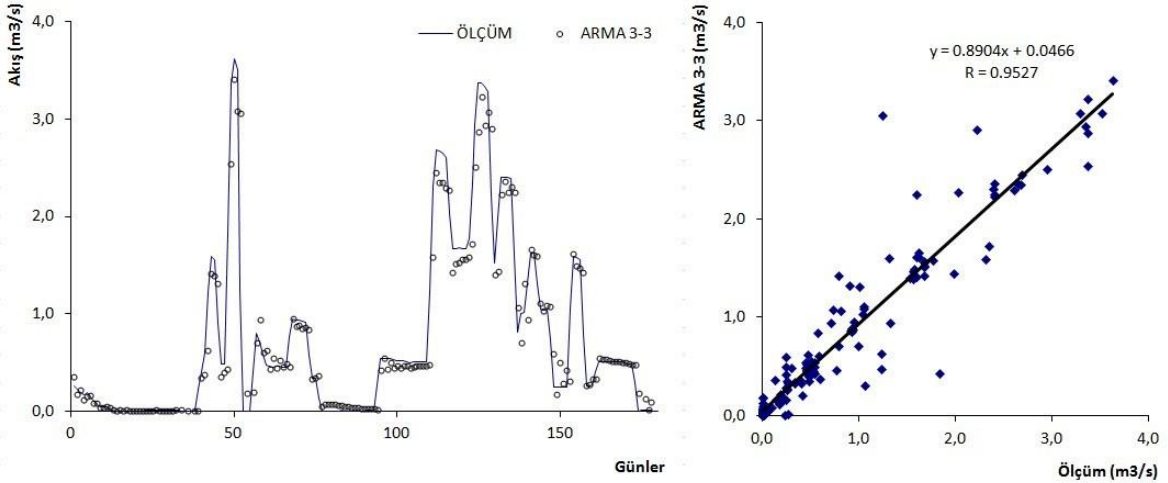


Şekil 5.16. ARMA(2,2) test sonuçları için dağılım ve saçılım grafikleri

2 numaralı ARMA(2,2) modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1}) girdi verisi olarak kullanılarak ARMA zaman serisi 2 kez ötelenmiş ve modelin korelasyon katsayısı $R=0,9523$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere yakınlık göstermektedir. Fakat R^2 Determinasyon Katsayısı 0,9070 olarak elde edilmiştir ve 1'e daha da yaklaştırılabilir. Şekil 5.16.'daki saçılım grafiğinde verilerin tam olarak regresyon çizgisi etrafına toplanmadığı gözlemlenebilmektedir.



Şekil 5.17. ARMA(3,3) eğitim sonuçları için dağılım ve saçılım grafikleri



Şekil 5.18. ARMA(3,3) test sonuçları için dağılım ve saçılım grafikleri

3 numaralı ARMA(3,3) modelinde günlük sıcaklık, yağış, akış ve yağışla akışın geri zamanlı verileri (P_{t-1} , Q_{t-1} , Q_{t-2}) girdi verisi olarak kullanılarak ARMA zaman serisi 3 kez ötelenmiş ve modelin korelasyon katsayısı $R=0,9527$ olarak elde edilmiştir. Modelden elde edilen tahmin sonuçları gerçek verilere diğer iki ARMA modelinden daha fazla yakınlık göstermektedir. R^2 Determinasyon Katsayısı ise 0,9076 olarak elde edilmiş ve 1'e en yakın sonucu veren ARMA modeli olmuştur. Şekil 5.18.'de de görüldüğü üzere verilerin regresyon çizgisi etrafındaki dağılımı, diğer iki modele göre biraz daha iyidir.


Çizelge 5.2.'de de gösterildiği üzere her yöntem için yapılan üç model arasında gerçeğe en uygun performansı 3 numaralı model göstermiştir. Determinasyon Katsayısı (R^2) 1'e çok yakın bir değer olarak gerçek verilerle tahmin edilen verilerin kolerasyonunun yüksek olduğunu göstermektedir. Ortalama Mutlak Hata değeri (MAE) sadece ARMA yöntemi için 1 numaralı modelde iyi sonuç verirken YSA ve ÇDR yöntemlerinde yine 3 numaralı modelde minimum sonuç vererek, gerçek verilerle tahmin verileri arasındaki farkın minimum olduğunu göstermiştir. Ortalama Karesel Hata değerinde (MSE) yine 3 numaralı model minimum sonuç vererek gerçek veriler ile tahmin verilerinin regresyon çizgisine yakın ve sık dağıldığını göstermiştir. Bu nedenle değerlendirme 3 numaralı model üzerinden yapılacaktır.

Çizelge 5.2. Modellere göre sonuçların uyumluluk ve istatistiksel hata değerleri

Model No	R^2			MAE			MSE		
	YSA	ÇDR	ARMA	YSA	ÇDR	ARMA	YSA	ÇDR	ARMA
1	0,8534	0,8608	0,9057	0,1756	0,1904	0,1369	0,1195	0,1126	0,0785
2	0,8877	0,8790	0,9070	0,1678	0,1861	0,1498	0,0917	0,0990	0,0811
3	0,9258	0,9133	0,9076	0,1389	0,1751	0,1445	0,0602	0,0726	0,0763

Çizelge 5.2. incelenecek olursa, 3 numaralı modelde değerlendirme kriterleri bakımından gerçek verilere en yakın sonuç veren yöntemin YSA yöntemi olduğu görülmektedir. ARMA sadece bir değerlendirme kriteri için (MAE) diğerlerinden iyi sonuç verirken YSA, bu kriter için ARMA'ya çok yakın sonuç vermeyi başarmış ve diğer iki değerlendirme kriterlerinde ise gerçek verilere ARMA ve ÇDR'den daha iyi yakınsama göstermiştir.

Çalışmada kullanılan üç modelin korelasyonları, regresyon çizgisi üzerinde karşılaştırmalı olarak Şekil 5.19.'da gösterilmektedir.



Şekil 5.19. YSA, ÇDR ve ARMA yöntemleri için karşılaştırmalı saçılım grafiği

YSA, ÇDR ve ARMA yöntemleri için, aralarında en iyi sonucu veren 3 numaralı modelin saçılım grafikleri Şekil 5.19.'da karşılaştırmalı olarak gösterilmektedir. Grafikte mavi renkli noktalar 3 numaralı YSA modelinin test sonucunu, yeşil noktalar 3 numaralı ÇDR modelinin test sonucunu, kırmızı noktalar ise ARMA(3,3) modelinin test sonucunu göstermektedir. Noktaların regresyon çizgisi üzerindeki saçılımına dikkat edilecek olursa; mavi renkli olan 3 numaralı YSA modelinin regresyon çizgisi üzerindeki saçılımı, ARMA ve ÇDR'ye kıyasla daha sıktır. Bu da yerinde ölçülen istasyon değerleri ile tahmin ettiğimiz modelleme değerleri arasında birbirine en yakın sonucu "YSA" yönteminin verdiğini onaylamaktadır.

6. SONUÇLAR VE ÖNERİLER

Bu çalışmada, Stony Brook Havzası üzerinde bulunan 01104480 numaralı gözlem istasyonuna ait 731 günlük yağış, akış ve sıcaklık verileri İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA), Çoklu Doğrusal Regresyon (ÇDR) ve Otoregresif Hareketli Ortalamalar (ARMA) yöntemlerinde girdi verisi olarak kullanılarak yeni akış değerleri tahmin edilmiştir. Elde edilen sonuçlar ile gerçek sonuçlar karşılaştırılarak yöntemler arasındaki ilişki incelenmiştir.

Modellemeler sırasında 731 adet verinin %75'i eğitim aşamasında, kalan %25'i ise test aşamasında kullanılmıştır. Bu verilerle daha iyi sonuçlar elde etmek bakımından yağış ve akışın geri zamanlı verileri de kullanılarak üç farklı durumu modelleyecek şekilde çalışma yapılmıştır. Modellerin istatistiksel performanslarını değerlendirmek için Determinasyon Katsayısı (R^2), Ortalama Karesel Hata (MSE-OKH) ve Ortalama Mutlak Hata (MAE-OMH) yöntemleri kullanılmıştır.

Çalışmalardan elde edilen veriler, kullanılan üç yöntemin de birbirine yakın sonuçlar verdiğini göstermiştir. Çoklu Doğrusal Regresyonun lineer durumlarda iyi sonuçlar verdiği hali hazırda bilinmekle birlikte; bu çalışmadaki gibi lineer olmayan durumlarda Yapay Sinir Ağları yönteminin Çoklu Doğrusal Regresyon yöntemine göre daha az hatayla gerçeğe daha yakın sonuçlar ortaya koyduğu görülmüştür. Yapay sinir Ağları yöntemi bu çalışmada gerçek verilere %92'nin üzerinde yakınlık göstermiştir. Otoregresif Hareketli Ortalamalar Yöntemi ise diğer iki yönteme kıyasla daha yüksek hata oranına sahiptir ve gerçek verilerle ilişkisi diğer yöntemlere göre daha zayıftır.

Yapılan bu çalışmada kullanılan üç yöntemin de gerçek verilere olan yakınlıkları ortaya koyulmuştur. Elde edilen veriler göstermektedir ki; akış tahmini için bu üç yöntem arasında gerçek verilere yakınlığı ve istatistiksel hata oranının minimum seviyede olması bakımından en uygun yöntem "Yapay Sinir Ağı" yöntemidir.

Bu sonuçlara göre hidrolojik çalışmalarda, su planlamalarında ve yağış - akış ilişkilerinin tahmininde yapay zeka tekniklerinden biri olan Yapay Sinir Ağı yöntemini kullanmak; düşük hata oranı ve gerçek verilere olan yüksek yakınsaması ile iyi bir tercih olacaktır.

KAYNAKLAR

- Aci, M. (2006). Yapay Sinir Ağları ile Hidrolojik Modelleme. Yüksek Lisans Tezi, Celal Bayar Üniversitesi, 85 s., Manisa.
- Alp, M., ve Cıgızoğlu, H. (2004). Farklı Yapay Sinir Ağı Metodları ile Yağış - Akış İlişkisinin Modellenmesi. *İTÜ Mühendislik Dergisi*, Cilt: 3, Sayı: 1, 80-88.
- Altunkaynak, A., ve Başakın, E. (2018). Zaman Serileri Kullanılarak Nehir Akım Tahmini ve Farklı Yöntemlerle Karşılaştırılması. *Erzincan Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 11(1), 92-101.
- Beven, K. (1993). Prophecy, Reality and Uncertainty in Distributed Hydrological Modelling. *Advances in Water Resour.* Vol. 16, pp. 41-51.
- Can, M. (2012). Yapay Sinir Ağları ile Akım Tahmini: Mahmudiye Göleti Örneği. Doktora Tezi, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı.
- Cıgızoğlu, H., ve Alp, M. (2004). Rainfall-Runoff Modelling Using Three Neural Network Methods. *In International Conference on Artificial Intelligence and Soft Computing*, pp. 166-171, Springer, Berlin, Heidelberg.
- Elmas, Ç. (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). *Seçkin Yayıncılık*.
- Ergezer, H. (2003). Yüz Tanıma: Öz Yüzler, Yapay Sinir Ağları, Gabor Dalgacık Dönüşümü Yöntemleri. Yüksek Lisans Tezi, Başkent Üniversitesi.
- Fernando, D., ve Jayawardena, A. (1998). Runoff Forecasting Using RBF Networks with OLS Algorithm, *Journal of Hydrologic Engineering* 3(3), 203-209.
- Fırat, A. (2019). Yapay Sinir Ağları ile Ortalama Debi ve Maksimum Yağış Tahmini İstanbul Göksu Dere Örneği. Yüksek Lisans Tezi, Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü.
- Gemici, E., Ardiçlioğlu, M., ve Kocabaş, F. (2013). Akarsularda Debinin Yapay Zeka Yöntemleri ile Modellenmesi. *Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Fen Bilimleri Dergisi*, 29(2), 135-143.
- Gümüş, V., Soydan, N., Şimşek, O., Aköz, M., ve Kırkgöz, M. (2013). Yağış - Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması. *ÇÜ Müh.-Mim. Fak. Dergisi*, Vol. 28, No: 1, 37-49.
- Gümüş, V., Şimşek, O., Soydan, N., Aköz, M., ve Yenigün, K. (2016). Adana İstasyonunda Buharlaştırmanın Farklı Yapay Zeka Yöntemleri ile Tahmini. *DÜMF Mühendislik Dergisi*, 7(2), 309-318.

- İnternet: Hayes, A. Error Term, Investopedia. URL: <https://www.investopedia.com/terms/e/errorterm.asp> Son Erişim Tarihi: 2020
- Hsu, K., H.V., G., ve Sorooshian, S. (1995). Artificial Neural Network Modeling of The Rainfall-Runoff Process. *Water Resources Research* 31(10), 2517-2530.
- Kayım, H. (1985). İstatiksel Ön Tahmin Yöntemleri, Hacettepe Üniversitesi. İktisadi ve İdari Bilimler Fakültesi.
- Kumar, P., Praveen, T., ve Prasad, M. (2016). Identification of Critical Erosion Prone Areas Using Remote Sensing and GIS: A Case Study of Sarada River Basin. *Indian Journal of Science and Technology*, 9(32), 1-6.
- Lindström, G., Johansson, B., Persson, B., Gardelin, M., ve Bergström, S. (1997). Development and Test of The Distributed HBV-96 Hydrological Model, *J. of Hydrol.*, Vol. 201, pp. 272-288.
- Mason, J., Tem'ne, A., ve Price, R. (1996). A Neural Network Model of Rainfall-Runoff Using Radial Basis Function. *J. Hydrol. Res.*, 34, 537-548.
- McCulloch, S., ve Pitts, H. (1943). A Logical Calculus of the Ideas Immanent in Neural Net., *Bulletin of Mathematical Biophysics*, Vol. 5.
- Minns, A., ve Hall, M. (1996). Artificial Neural Network as Rainfall-Runoff Models. *Hydrol. Sci. J.*, 4(3), 399-417.
- Nabiyev, V. V. (2012). Yapay Zeka: İnsan-Bilgisayar Etkileşimi. *Seçkin Yayıncılık*.
- Nacar, S. (2014). Farklı Yapay Zeka Yöntemleri ile Günlük Akarsu Akım Değerlerinin Tahmini: Haldizen Deresi Örneği. Yüksek Lisans Tezi, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü.
- İnternet: Neuron. URL: <https://en.wikipedia.org/wiki/Neuron> Son Erişim Tarihi: 2020
- Oğul, E. (2006). Yağış - Akış İlişkisinin Yapay Sinir Ağı Yöntemleriyle Modellenmesi: Kurukavak Havzası Uygulaması. Yüksek Lisans Tezi, Anadolu Üniversitesi.
- Okkan, U., ve Mollamahmutoğlu, A. (2010). Yiğitler Çayı Günlük Akımlarının Yapay Sinir Ağları ve Regresyon Analizi ile Modellenmesi. *Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, (023), 33-48.
- Refsgaard, J. (1997). Parameterisation, Calibration and Validation of Distributed Hydrological Models, *J. of Hydrol.*, Vol. 198, pp. 69-97.
- Saplıoğlu, K., ve Çimen, M. (2010). Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21.
- Senthil Kumar, A., Sudheer, K., Jain, S., ve Agarwal, P. (2005). Rainfall-Runoff Modelling Using Artificial Neural Networks: Comparison of Network Types. *Hydrological Processes: An International Journal*, 19(6), 1277-1291.

- Sherman, L. (1932). Stream Flow from Rainfall by the Unit-Graph Method, *Eng. News-Rec.*, 108, 501-505.
- Şahin, M. (2007). Karadeniz Bölgesindeki Yağış - Akış İlişkisinin Farklı Yapay Sinir Ağları Metotlarıyla Belirlenmesi, Yüksek Lisans Tezi, İTÜ Fen Bilimleri Enstitüsü.
- İnternet: The Water Cycle. URL: <https://www.usgs.gov/media/images/water-cycle-natural-water-cycle> Son Erişim Tarihi: 2019
- Turhan, E. (2012). Seyhan Havzası'nın Yağış - Akış İlişkisinin Yapay Sinir Ağları Yöntemi ile Modellenmesi, Yüksek Lisans Tezi, Adana.
- Turhan, E., ve Çağatay, H. (2016). Eksik Akım Verilerinin Tahmin Modelinin Oluşturulmasında Yapay Sinir Ağlarının Kullanımı: Asi Nehri-Demirköprü Akım Gözlem İstasyonu Örneği, *ÇÜ Müh.-Mim. Fak. Dergisi* 31(1), 93-106.
- Turhan, E., Çağatay Özmen, H., ve Çetin, A. (2016). Yapay Sinir Ağı Yöntemleri ile Aşağı Seyhan Ovası Alt Havzası Yağış - Akış İlişkisinin Modellenmesi ve Yağış-Kurak Dönemler Açısından İrdelenmesi.
- Uhlenbrook, S., Seibert, J., Leibundgut, C., ve Rodhe, A. (1999). Prediction Uncertainty of Conceptual Rainfall-Runoff Models Caused by Problems to Identify Model Parameters and Structure, *Hydrological Sciences. Journal des Sciences Hydrologiques*, Vol. 44(5), pp. 779-798.
- Yarar, A. (2010). Susurluk Havzası Yağış - Akış Verilerinin Modellenmesi, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Yaşar, M. (2004). Günlük Akışlardaki Boşlukların Yapay Sinir Ağı Kullanılarak Tamamlanması, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü.
- Yavuz, S., ve Deveci, M. (2012). İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi, *Erciyes Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yıldıran, A. (2019). Nehir Akışının Yapay Zeka ve Trend Analizi Metotları ile Tahmini, Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü.
- Yurdusev, M., Müserref, A., Turan, M., ve İçağa, Y. (2008). Akarçay Nehri Aylık Akımlarının Yapay Sinir Ağları ile Tahmini. *Celal Bayar Üniversitesi, Fen Bilimleri Dergisi*, 4(1), 73-88.
- İnternet: What is The Difference Between R and R Squared URL: <https://www.quora.com/what-is-the-difference-between-r-and-R-squared> Son Erişim Tarihi: 2018

DİZİN

A

ARMA · iv, v, vii, xi, xiii, 7, 31,
36, 43, 44, 45, 46, 47, 48

B

Birim Hidrograf · 3, 5, 6, 18

Ç

ÇDR · iv, vii, xi, xiii, 7, 9, 11, 13,
32, 36, 40, 41, 42, 46, 47, 48
Çoklu Doğrusal Regresyon · iv,
xii, 7, 13, 14, 15, 32

D

Determinasyon · xii, 8, 9, 10, 14,
32, 33, 38, 39, 41, 42, 44, 45,
46, 48

H

Hidrograf · 3, 4, 5, 6, 18

İ

İBGYSA · iv, vii, xiii, 6, 7, 8, 9,
11, 13, 28, 36, 48
İleri Beslemeli Geri Yayılımlı
Sinir Ağı · iv, x, xii, 6, 7, 8,
13, 14, 28, 36, 48,

K

Korelasyon · xii, 33, 46

O

OMH · vii, xiii, 34, 35, 36, 48
Ortalama Mutlak Hata · vii, xiii,
12, 34, 35, 36, 46, 48
OKH · vii, xiii, 8, 9, 10, 13, 34,
36, 48
Ortalama Karesel Hata · vii, xiii,
8, 9, 10, 11, 12, 14, 34, 36, 46,
48
Otoregresif Hareketli Ortalama ·
iv, vii, 7, 10, 15, 31, 36, 48

R

R^2 · vii, x, xii, 8, 9, 10, 11, 12,
13, 14, 32, 33, 34, 36, 38, 39,
41, 42, 44, 45, 46, 48

S

Stony Brook · x, iv, v, 7, 15, 16,
48

Y

YSA · iv, vii, x, xii, xiii, 6, 7, 8,
9, 10, 11, 12, 13, 14, 18, 20,
22, 24, 25, 28, 36, 37, 38, 39,
46, 47, 48
Yapay Sinir Ağı · vii, x, xiii, 8,
11, 12, 13, 18, 20, 21, 23, 29,
48, 49, 50, 51

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KESKİN, Levent
 Uyuşu : T.C.
 Doğum tarihi ve yeri : 08.05.1992, Seyhan
 Medeni hali : Bekar
 Telefon :
 Faks :
 e-mail : levent.keskin.mfbe17@iste.edu.tr



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2020
Lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2015
Lise	Şehit Temel Cingöz Lisesi	2010

İş Deneyimi

Yıl	Yer	Görev
2017-2018	Özdem İnşaat Ltd. Şti	Mühendis
2016-2017	Karataş Grup Elk. İnş. Tic. Ltd. Şti.	Mühendis
2016-2016	Ran İnşaat Taahhüt Tic. Ltd. Şti.	Mühendis
2015-2016	Uzman Yapı Denetim Ltd. Şti.	Mühendis

Yabancı Dil

İngilizce

Hobiler

Motor sporları, Fitness, Müzik, Bilim ve teknoloji



TEKNOVERSITE