



**İSKENDERUN TEKNİK**  
ÜNİVERSİTESİ

**YÜKSEK  
LİSANS  
TEZİ**

**GÜNLÜK BUHARLAŞMA  
MİKTARININ YAPAY SİNİR  
AĞLARI METOTLARI VE  
KLASİK YÖNTEMLERLE  
TAHMİNİ**

**SÜREYYA DOĞAN**

**İNŞAAT MÜHENDİSLİĞİ  
ANABİLİMDALI**

**HAZİRAN 2020**





**GÜNLÜK BUHARLAŞMA MİKTARININ YAPAY SİNİR AĞLARI METOTLARI  
VE KLASİK YÖNTEMLERLE TAHMİNİ**

**Süreyya DOĞAN**

**YÜKSEK LİSANS**

**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

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

**HAZİRAN 2020**

Süreyya DOĞAN tarafından hazırlanan “GÜNLÜK BUHARLAŞMA MİKTARININ YAPAY SİNİR AĞLARI METOTLARI VE KLASİK YÖNTEMLERLE TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Prof. Dr. Fatih ÜNEŞ  
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

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

.....  
.....

**Başkan:** Unvanı Adı SOYADI  
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

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

.....  
.....

**Üye:** Unvanı Adı SOYADI  
Anabilim Dalı, Üniversite Adı (Örnek: Endüstri Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi)

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

.....  
.....

**Üye:** Unvanı Adı SOYADI

Anabilim Dalı, Üniversite Adı (Örnek: Endüstri Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi)

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

.....  
.....

Tez Savunma Tarihi:

.../.../...

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.

Süreyya DOĞAN  
25/06/2020



# GÜNLÜK BUHARLAŞMA MİKTARININ YAPAY SİNİR AĞLARI METOTLARI VE KLASİK YÖNTEMLERLE TAHMİNİ

(Yüksek Lisans Tezi)

Süreyya DOĞAN

ISKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2020

## ÖZET

Buharlaşma, hidrolojik ve meteorolojik çalışmaların önemli bir parametresi olarak karşımıza çıkmaktadır. Buharlaşma tahmininin doğru yapılması ise su kaynaklarının geliştirilmesi, kontrol edilmesi ve yönetimi gibi çeşitli amaçlar için önem taşımaktadır. Bu çalışmada FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini ( $ET_0$ ) yapılmış, bu metoda göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir. Hargreaves-Samani, ve Turc denklemleri gibi ampirik yöntemler ile Yapay Sinir Ağları (YSA), Radyal Tabanlı Yapay Sinir Ağları (RTYSA), Çoklu Doğrusal Regresyon (ÇDR) yöntemleri ve Oto-regresif modelin AR(p) performansları karşılaştırılarak buharlaşma miktarı tahmini yapılmıştır. Çalışma alanı olarak Güney Carolina (ABD) Anderson bölgesindeki Hartwell gölünde bulunan bir istasyon seçilmiştir. Günlük ortalama buharlaşma miktarı tahmini için ortalama günlük hava sıcaklığı ( $T_{mean}$ ), en yüksek ( $T_{max}$ ) ve en düşük günlük hava sıcaklıkları ( $T_{min}$ ), rüzgâr hızı ( $u$ ), güneşlenme miktarı (SR) ve bağıl nem (RH) kullanılmıştır. Bütün günlük veriler eğitim ve test verisi olarak ikiye ayrılmıştır. YSA optimizasyonu için geriye yayılma ilkesine göre çalışan, ileri beslemeli (feedforward-back-propagation) YSA modeli kullanılmıştır. YSA, RTYSA, ÇDR yöntemi ve AR(p) model sonuçları geleneksel Hargreaves-Samani, ve Turc yöntemlerinin sonuçları ile karşılaştırılmıştır. Sonuç olarak, YSA modelinin buharlaşma miktarı tahmininde diğer yöntemlerden daha iyi performans gösterdiği belirlenmiştir.

Anahtar Kelimeler :Buharlaşma, YSA , RTYSA ,ÇDR , AR(p), Ampirik Denklemler  
Sayfa Adedi :68  
Danışman :Prof. Dr. Fatih ÜNEŞ

DAILY EVAPOTRANSPIRATION ESTIMATION USING ARTIFICIAL NEURAL  
NETWORKS AND CLASSICAL METHODS

(M. Sc. Thesis)

Süreyya DOĞAN

ISKENDERUN TECHNICAL UNIVERSITY  
ENGINEERING AND SCIENCE INSTITUTE

June 2020

ABSTRACT

Evaporation is regarded as an important parameter of hydrological and meteorological studies. Correct evaporation estimation is crucial for various purposes such as development, control and management of water resources. In this study, daily evaporation estimation ( $ET_0$ ), has been made according to Penman-Monteith method recommended as the standard method by FAO (Food and Agriculture Organization), and evaporation estimates found according to Penman Monteith method were accepted as reference. The evaporation amount by comparing the performances of Artificial Neural Networks (ANN), Radial Based Artificial Neural Networks (RBNN), Multiple Linear Regression (MLR) methods and Auto-regressive model AR (p) with empirical methods such as Hargreaves-Samani, and Turc equations has been estimated. A station in Hartwell lake in Anderson region, South Carolina (USD) was chosen as the study area. Average daily air temperature ( $T_{mean}$ ), highest ( $T_{max}$ ), and lowest daily air temperatures ( $T_{min}$ ), wind speed (u), sunshine amount (SR) and relative humidity (RH) were used for the estimation of the average daily evaporation amount. All daily data are divided into training and test data. The feedforward-back-propagation ANN model working according to the principle of back propagation has been used for the optimization of ANN. ANN, Radial Based Artificial Neural Networks (RBNN), Multiple Linear Regression (MLR) method and Auto-regressive model AR (p) results were compared with the results of traditional Hargreaves-Samani, and Turc method. The comparison has shown that the ANN model performed better than other methods in estimating the evaporation amount.

Key Words :Evaporation, ANN, RBNN, MLR, AR (p), Empirical Equations  
Number of Pages :68  
Supervisor :Prof. Dr. Fatih ÜNEŞ

## TEŐEKKÜR

Tez alıőmam aőamasında tecrübesi ve bilgi birikimi ile alıőmayı yönlendiren deęerli hocam Prof. Dr. Fatih ÜNEŐ'e teőekkürlerimi sunarım. Ayrıca her daim desteęini hissettięim ve bir abi olarak gördüęüm Arő. Gör. Bestami TAŐAR'a en içten duygularım ile sonsuz teőekkürlerimi sunarım. Tez alıőmam sürecinde yardımlarından dolayı deęerli hocam Do. Dr. Mustafa DEMİRĐI'ye de teőekkürü bor bilirim. Bana her daim güvenen inanan ve yanımda olan hayatımdaki en fazla teőekkürü hak eden babam Ziya DOĖAN ve annem Kadriye DOĖAN'a ve deęerli arkadaşlarıma, sonsuz teőekkürler ederim.



## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET .....	vi
ABSTRACT .....	iv
TEŞEKKÜR .....	v
İÇİNDEKİLER .....	vi
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ .....	vi
SİMGELER VE KISALTMALAR.....	vi
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. ÖNCEKİ ÇALIŞMALAR.....</b>	<b>5</b>
<b>3. MATERYAL ve YÖNTEM .....</b>	<b>12</b>
3.1.Çalışma Alanı .....	12
3.2. Kullanılan Modeller .....	18
3.2.1.Ampirik yöntemler.....	19
3.2.2. Yapay sinir ağları metodu (YSA) .....	21
3.2.3.Radyal tabanlı yapay sinir ağları metodu (RTYSA) .....	35
3.2.4. Zaman serileri analizi (ZSA) .....	37
3.2.5. Çoklu doğrusal regresyon (ÇDR) .....	38
<b>4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....</b>	<b>39</b>
4.1. Model Performansında Kullanılan İstatistiksel Parametreler .....	39
4.2. Model Sonuçları.....	40
4.2.1. Hargreaves-Samani model sonuçları .....	40
4.2.2. Turc model sonuçları.....	43
4.2.3. Yapay sinir ağları (YSA) model sonuçları.....	46
4.2.4. Radyal tabanlı yapay sinir ağları metodu (RTYSA) model sonuçları .....	48



	<b>Sayfa</b>
4.2.5. AR(1) ve AR(3) model sonuçları.....	51
4.2.6. Çoklu doğrusal regresyon (ÇDR) model sonuçları.....	56
<b>5. SONUÇ ve ÖNERİLER.....</b>	<b>61</b>
<b>KAYNAKLAR.....</b>	<b>63</b>
<b>ÖZGEÇMİŞ.....</b>	<b>67</b>



**ÇİZELGELERİN LİSTESİ**

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 3.1. Hartwell gölüne ait büyüklükler .....	12
Çizelge 3.2. Biyolojik sinir yapısı ile yapay sinir ağı karşılıkları .....	24
Çizelge 4.1 Günlük Buharlaşma Miktarının Tahmininde Kullanılan Model Sonuçlarının Karşılaştırılması.....	59



## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Hidrolojik çevrim .....	1
Şekil 1.2. Class A tipi buharlaşma tavaşı. ....	3
Şekil 3.1. Çalışılan istasyondaki Hartwell gölü .....	13
Şekil 3.2. Çalışılan istasyonun konumu .....	14
Şekil 3.3. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük maksimum hava sıcaklık (°C) miktarı değişimleri .....	15
Şekil 3.4. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük minimum hava sıcaklık(°C) miktarı değişimleri .....	15
Şekil 3.5. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki Günlük ortalama hava sıcaklık (°C) miktarı değişimleri.....	16
Şekil 3.6. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük solar radyasyon (Mj/m <sup>2</sup> ) miktarı değişimleri .....	16
Şekil 3.7. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük nisbi nem (%) değişimleri.....	17
Şekil 3.8.Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük ortalama rüzgar hızı (m/s) değişimleri .....	17
Şekil 3.9.Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük buharlaşma miktarı(mm) değişimleri .....	18
Şekil 3.10. Yapay sinir ağlarının gelişimi tarihçe zaman çizelgesi .....	21
Şekil 3.11. Nöron yapısı .....	24
Şekil 3.12. Basit bir YSA yapısı .....	25
Şekil 3.13. Doğrusal aktivasyon fonksiyonu. ....	26
Şekil 3.14. Adım aktivasyon fonksiyonu .....	27
Şekil 3.15. Sigmoid aktivasyon fonksiyonu .....	27
Şekil 3.16. Yapay sinir hücresi .....	28
Şekil 3.17. Genel bir geri yayılım ağ yapısı .....	31
Şekil 3.18. Çok tabakalı algılayıcı (perceptron) .....	33

<b>Şekil</b>	<b>Sayfa</b>
Şekil 3.19. İleri beslemeli bir ağ için geri yayılım akış şeması .....	34
Şekil 3.20. RTYSA'nın yapısı .....	36
Şekil 4.1. Günlük buharlaşma miktarı eğitim verileri için Hargreaves-Samani yöntemine ait saçılım grafiği .....	41
Şekil 4.2. Günlük buharlaşma miktarı eğitim verileri için Hargreaves-Samani yöntemine ait ölçüm ve dağılım grafiği .....	41
Şekil 4.3. Günlük buharlaşma miktarı test verileri için Hargreaves-Samani yöntemine ait saçılım grafiği. ....	42
Şekil 4.4. Günlük buharlaşma miktarı test verileri için Hargreaves-Samani yöntemine ait ölçüm ve dağılım grafiği .....	43
Şekil 4.5. Günlük buharlaşma miktarı eğitim verileri için Turc yöntemine ait saçılım grafiği .....	44
Şekil 4.6. Günlük buharlaşma miktarı eğitim verileri için Turc yöntemine ait ölçüm ve dağılım grafiği. ....	44
Şekil 4.7. Günlük buharlaşma miktarı test verileri için Turc yöntemine ait saçılım grafiği .....	45
Şekil 4.8. Günlük buharlaşma miktarı test verileri için Turc yöntemine ait ölçüm ve dağılım grafiği .....	45
Şekil 4.9. Günlük buharlaşma miktarı eğitim verileri için YSA yöntemine ait saçılım grafiği. ....	46
Şekil 4.10. Günlük buharlaşma miktarı eğitim verileri için YSA yöntemine ait ölçüm ve dağılım grafiği .....	47
Şekil 4.11. Günlük buharlaşma miktarı test verileri için YSA yöntemine ait saçılım grafiği .....	47
Şekil 4.12. Günlük buharlaşma miktarı test verileri için YSA yöntemine ait ölçüm ve dağılım grafiği. ....	48
Şekil 4.13. Günlük buharlaşma miktarı eğitim verileri için RTYSA yöntemine ait saçılım grafiği .....	49
Şekil 4.14. Günlük buharlaşma miktarı eğitim verileri için RTYSA yöntemine ait ölçüm ve dağılım grafiği .....	49
Şekil 4.15. Günlük buharlaşma miktarı test verileri için RTYSA yöntemine ait saçılım grafiği .....	50

<b>Şekil</b>	<b>Sayfa</b>
Şekil 4.16. Günlük buharlaşma miktarı test verileri için RTYSA yöntemine ait ölçüm ve dağılım grafiği .....	50
Şekil 4.17. Günlük buharlaşma miktarı eğitim verileri için AR(1) yöntemine ait saçılım grafiği .....	51
Şekil 4.18. Günlük buharlaşma miktarı eğitim verileri için AR(1) yöntemine ait ölçüm ve dağılım grafiği.....	52
Şekil 4.19. Günlük buharlaşma miktarı eğitim verileri için AR(3) yöntemine ait saçılım grafiği .....	52
Şekil 4.20. Günlük buharlaşma miktarı eğitim verileri için AR(3) yöntemine ait ölçüm ve dağılım grafiği .....	53
Şekil 4.21. Günlük buharlaşma miktarı test verileri için AR(1) yöntemine ait saçılım grafiği ....	54
Şekil 4.22. Günlük buharlaşma miktarı test verileri için AR(1) yöntemine ait ölçüm ve dağılım grafiği .....	54
Şekil 4.23. Günlük buharlaşma miktarı test verileri için AR(3) yöntemine ait saçılım grafiği .....	55
Şekil 4.24. Günlük buharlaşma miktarı test verileri için AR(3) yöntemine ait ölçüm ve dağılım grafiği.....	55
Şekil 4.25. Günlük buharlaşma miktarı eğitim verileri için ÇDR yöntemine ait saçılım grafiği .....	56
Şekil 4.26. Günlük buharlaşma miktarı eğitim verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği .....	57
Şekil 4.27. Günlük buharlaşma miktarı test verileri için ÇDR yöntemine ait saçılım grafiği.....	57
Şekil 4.28. Günlük buharlaşma miktarı test verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği .....	58

## SİMGELER VE KISALTMALAR

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

### Simgeler

**et**

### Açıklamalar

Evapotranspirasyon

**$et_0$**

Referans Evapotranspiration

**r**

Korelasyon katsayısı

**rh**

Bağıl Nem

**$r^2$**

Determinasyon katsayısı

**sr**

Solar Radyasyon

**t**

Sıcaklık

**tm**

Günlük Ortalama Sıcaklık

**tmax**

Günlük Maksimum Sıcaklık

**tmean**

Günlük Ortalama Sıcaklık

**tmin**

Günlük Minimum Sıcaklık

**u**

Rüzgâr Hızı

### Kısaltmalar

**AR(p)**

Oto-regresif model

**BM**

Uyarlamalı sinirsel bulanık çıkarım sistemi

**CIMIS**

Kaliforniya Sulama Yönetimi Bilgi Sistemi

**ÇLR**

Çoklu Lineer Regresyon

**FAO**

Food and Agriculture Organization

**FG**

Bulanık genetik yaklaşım

**GEP**

Gen ekspresyon programlama

**GFNN**

Genelleştirilmiş birinci dereceden sinir ağı

**GHNN**

Genelleştirilmiş yüksek dereceli sinir ağı

**GMLR**

Genelleştirilmiş çok doğrusal regresyon

**GRNN**

Genelleştirilmiş regresyon sinir ağları

**GT**

Gama Test

**İBGYYSA**

İleri beslemeli geri yayımlı yapay sinir ağı

**Kısaltmalar****Açıklamalar****KKOH**

Ortalama karesel hataların karekökü

**LSSVM-GT**

En küçük kareler destek vektör makinesi-gama testi

**MOH**

Mutlak ortalama hata

**OKH**

Ortalama karesel hata

**PET**

Potansiyel buharlaşma transpirasyonu

**PM**

Penman-Monteith

**RBNN**

Radial Based Artificial Neural Networks

**RTYSA**

Radyal Tabanlı Yapay Sinir ağları

**USGS**

United States geological survey

**YSA**

Yapay sinir ağı

## 1. GİRİŞ

Su canlı yaşamı ve yaşamın sürdürülebilmesi için temel bir madde olup büyük önem arz etmektedir. Su yoksa hayatta yoktur, dünyamızın yaşanabilir bir yer olmasını sağlayan suyun varlığıdır. Dünya var olduğundan bu yana yer küredeki kullanılabilir tatlı suyun sürdürülebilirliğinin nedeni doğadaki su döngüsü, diğer deyişle hidrolojik çevrimdir. Yeryüzündeki deniz, okyanus ve göller ile yer altı sularının atmosfere giderek yeniden yeryüzüne dönmesi olarak tanımlayabileceğimiz su döngüsü kısaca bu şekilde ifade edilebilir. Yeryüzünde ki okyanuslar, denizler, göller ve yer altı suları hareket ederek, şekil değiştirerek, kullanılarak yeniden yeryüzüne döner. Doğadaki su döngüsünde beş basamak bulunur. Bunlar, yoğunlaşma, yağış, toprağa geçiş, yüzeysel akış ve buharlaşmadır. Buharlaşmanın hidrolojik çevrim içerisindeki yeri Şekil 1.1’de gösterilmiştir.



Şekil 1.1. Hidrolojik çevrim (USGS,2019)



Buharlařma, kısaca yeryüzünde sıvı ve katı halde deęişik Őekil ve Őartlarda bulunan suyun meteorolojik faktörler etkisiyle atmosfere gaz halinde dönüőü olarak tarif edilir. Su yüzeyindeki moleküller yeterli bir kinetik enerjiye sahip olduklarında, kendilerini tutmaya çalıőan dięer moleküllerin çekim etkisinden kurtularak sudan havaya fırlarlar. Su yüzeyi civarında sudan havaya ve havadan suya doęru sürekli bir moleköl akımı vardır. Sudan havaya geçen moleküllerin sayısı daha fazla ise bu olaya "buharlařma" adı verilir.

Su yüzeyinden su buharına dönüőme ile meydana gelen su kayıplarına buharlařma (evaporasyon), bitkilerden meydana gelen su kaybına terleme (transpirasyon), bitkilerden ve toprak + su yüzeyinden meydana gelen su kaybına ise evapotranspirasyon adı verilir. Yapılan çalıőmalara göre atmosferdeki su buharının yaklaşık %90'ı buharlařmadan, kalan %10'u ise bitkilerin terlemesinden (transpirasyon) kaynaklanmaktadır (USGS, 2016)

Buharlařmaya etki eden faktörler güneő radyasyonu, rüzgâr hızı, su derinlięi, havanın nem miktarı, sıcaklık ve atmosfer basıncıdır.

Hava sıcaklıęı arttıkça, su yüzeyindeki buhar basıncı(ew) ile hava basıncı (ea) arasındaki fark büyür ve buna baęlı olarak buharlařma miktarı da artar. Suyun buharlařma ile su yüzeyinden atmosfere gönderilmesi için rüzgâra da gerek duyulmaktadır. Rüzgârlı havalarda havanın hareketi artacaęından, su yüzeyi yakınlarında suya doymuő olan hava buradan uzaklařarak daha az rutubetli bölgeye gelir. Sonuç olarak, rüzgâr, hava sirkülasyonunu saęlayarak buharlařma miktarının artmasına yol açar Radyasyon en önemli atmosferik etmenlerden biridir. Radyasyon moleküllerin su yüzeyinden kopmasına neden olan enerjiyi saęlar. Güneő ışınımından kaynaklı radyasyonun artması ile buharlařma artmaktadır Su derinlięi ise Őöyle etki etmektedir: Yaz döneminde derin sularda sıę sulara nazaran buharlařma daha azdır. Bu durum kış döneminde tam tersi Őeklindedir. Atmosfer basıncındaki artış su moleküllerinin hareketini zorlaőtırır ve buharlařmayı güçleőtirir. Hava basıncının artması buharlařmayı az da olsa azaltır. Yüksek kot farklarının olduęu bölgelerde atmosfer basıncı daha etkin bir faktördür Suda erimiő tuzlar ve su yüzeyindeki kimyasal maddeler buharlařmayı azaltırlar.

Serbest su yüzeyinden buharlařmanın belirlenmesinde en çok kullanılan yöntemlerden birisi buharlařma tavaı (evaporimetre) denen, metal kaplar ile yapılandır. En çok kullanılan buharlařma tavaı tipi: A sınıfı tava olup, alanı 1 m<sup>2</sup>, derinlięi 25 cm'dir. Tava 20 cm derinlikte su ile doldurulup su yüzeyindeki alçalma bir Limnimetre ile ölçölerek

buharlařma miktarı belirlenir. Ancak tavadaki buharlařma miktarı ile büyük bir su kütlesindeki (bir hazne, bir göl, bir baraj vb.) buharlařma miktarı birbirinden farklıdır. Bu farklılığın sebebi ise havadaki suyun hava sıcaklığındaki deęişmelerden daha çabuk etkilenmesidir.



řekil1.2. Class A Tipi buharlařma tavası (Korkmaz,2015).

Hidrolojik döngünün en önemli parametrelerinden biri olan ET tarımsal, iklimsel ve hidrolojik çalışmalarda belirleyici bir parametre olarak dikkate alınmalıdır. ET deęerinin belirlenebilmesi için çok sayıda metot önerilmiştir. “Aerodinamik denklemler ile oransal ilişkiler kullanılarak yapılan hesaplamalar genelde ET için en doğru sonuçları vermektedir.” (Jensen ve Breuning-Madsen,1990). “Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) ET için Penman Monteith 3 (PM) denklemini standart bir denklem olarak kabul etmiştir.” (Allen ve ark., 1998).

Buharlařma miktarının tahmini mühendislik açısından büyük önem taşımaktadır. Yeryüzünde canlıların yaşayabilmesi için suyun kullanılması ve kontrol altına alınması insanlığın önemli ilgi alanlarından biri olmuştur. Bu sebeple insanlar, suyu tanımak, oluşturabileceęi tehlikeleri önlemek, suyun hareketini yöneten kanunları belirlemek, ve sudan en iyi şekilde faydalanmak istemişlerdir.

Hidrolojinin konusu yerkürede mevcut suyun dağılımını, çevrimini, fiziksel ve kimyasal özelliklerini, çevreyle ve canlılarla olan karşılıklı ilişkilerini incelemek olmuştur. İnşaat

mühendisleri suyun en etkili kullanımını ve değerlendirilmesi ile ilgili çalışmalarda hidroloji bilimi ile birlikte hareket ederek barajlar inşa etmişlerdir. Enerji üretimi, içme suyu temini , sulama suyu temini ve akarsuların düzenlenmesi gibi pek çok amaca hizmet eden barajlar ekonomik yararlarına rağmen büyük yatırım gerektiren yapılardır. Günümüzde inşa edilmiş birkaç yüz metre yükseklikte, hacmi milyonlarca metreküp kapasiteye ulaşmış ve kilometrelerce uzunlukta olan barajlar mevcuttur. İnşa edilen barajların haznesindeki su miktarının belirlenmesinde, işletilmesinde ve tasarrufunda en önemli parametrelerden biri buharlaşma olmuştur.

Sulama planlaması, nehir akışı tahmini, hidrolojik modelleme ve sulama sistemi tasarımında dahil olmak üzere pek çok uygulamada buharlaşma önemli bir parametre olarak karşımıza çıkmaktadır. Buharlaşmanın tahmini su kaynaklarının izlenmesi, ölçülmesi ve yönetimi için önemlidir. Buharlaşmanın doğru olarak tahmin edilmesi, su kaynaklarının iyi bir şekilde planlanmasını ve yönetilmesini sağlar.

## 2. ÖNCEKİ ÇALIŞMALAR

Günümüze kadar bir çok araştırmacı, yıllık, aylık ve günlük buharlaşmanın ölçülmesi, hesabı ve tahmini üzerine çalışmalar yapmıştır. Winter ve Ark. (1995), Günlük tava buharlaşmasının, mahsul yönetimi kararlarını verirken ve mahsulün hava koşullarına verdiği cevabın, modellemede önemli bir değişken olduğunu gözlemlemişlerdir. Bununla birlikte, günlük tava buharlaşmasının daha uzun zaman dilimlerinde doğru ve tutarlı bir şekilde ölçülmesi için girdi olarak, ölçülen hava değişkenlerini kullanarak günlük tava buharlaşmasını tahmin etmek için yapay sinir ağı (YSA) modelleri geliştirmişlerdir. Günlük tava buharlaşma modellerini geliştirmek için Roma, Plains ve Watkinville, Georgia'dan alınan 1992 - 1996 yılları arası, 2044 hava durumu verisi kullanılmışlardır. 1997 ve 1998 yılları arasında 720 günlük bu bölgelerden alınan ek hava durumu verileri, modeller için belirlenen bağımsız değerlendirme verileri olarak kullanılmıştır. Bu araştırmada ölçülen değişkenler günlük yağış, sıcaklık, bağıl nem, güneş radyasyonu ve rüzgar hızı gözlemleridir. Günlük tava buharlaşması, çoklu lineer regresyon ve Priestley-Taylor metodu kullanılarak da tahmin edilmiş ve YSA modellerinin sonuçları ile karşılaştırılmıştır. Girdi olarak mevcut tüm değişken veriler kullanılarak tahmin edilen tava buharlaşmanın YSA modelinin, ortalama karesel hata miktarına göre en doğru model olduğunu görmüşlerdir.. YSA modelleriyle hesaplanan tava buharlaşması tahminlerinin, çoklu doğrusal regresyon modeliyle veya Priestley-Taylor denklemi ile tahmin edilen tava buharlaşmasından daha doğru çıktığını gözlemlemişlerdir. Gelecekteki yapılacak tahminlerde, YSA modelinin, otomatik meteoroloji istasyonu ağının eksik tava buharlaşma verilerini tahmin etmek için kalite kontrol prosedürünün bir parçası olarak dahil edilmesine referans olacağını tespit etmişlerdir.

Asmar ve arkadaşları (1999), Ölü Deniz'i Kızıldeniz'e bir kanal üzerinden bağlayacak geniş kapsamlı bir proje için, Ölü Deniz'deki buharlaşmayı tahmin etmek için bir yöntem gerektiğinden, standart yöntemlerin uygulanamadığı bir hipersalin gölü için buharlaşma tahmini yapmışlardır. Buharlaşmanın hesabında Penman ve Dalton formüllerine dayanan iki yöntem incelenmişlerdir. Burada türetilen yöntem, buharlaşmayı tuzluluk, nem, hava sıcaklığı ve rüzgâr hızının bir işlevi olarak tahmin eden değiştirilmiş bir Penman modelidir. Su sıcaklığı gibi diğer parametreler dolaylı olarak modele dahil edilmiştir. Elde edilen sonuçlara göre, önceki ölçümlerle karşılaştırarak tatmin edici bir sonuç sağlandığını görmüşler ve yöntemi doğrulamışlardır.

Terzi ve Keskin (2005), buharlaşma tahminine alternatif bir yaklaşım amacıyla Eğirdir Gölü'ndeki günlük buharlaşma tahmini için meteorolojik verilerle Yapay Sinir Ağları (YSA)metodu kullanarak modeller geliştirmişlerdir. Bu modelleri yaparken 2001-2002 yıllarına ait günlük su sıcaklığı, hava sıcaklığı, güneş radyasyonu, nisbi nem, hava basıncı ve rüzgâr hızı parametrelerini kullanmışlardır. Bu yöntemlerle birlikte temel buharlaşma tahmini metodu olan Penman metodunu kullanılmışlardır.YSA modeli ve Penman metodunun tava buharlaşma değeri ile uyum içerisinde olduğunu gözlemlemişlerdir.

Işık ve Sandalcı.(2007), çalışmalarında ileri beslemeli geri yayımlı (İBGYYSA) ve radyal temelli yapay sinir ağı (RTYSA) modeli kullanılarak Sapanca Gölü için günlük buharlaşma miktarı tahmini yapmışlar ve Penman-Monteith (PM) modeli ile karşılaştırmışlardır. Buharlaşma miktarı tahminini minimum ve maksimum sıcaklığa, bağıl neme, gerçek güneşlenme süresine, maksimum güneşlenme süresine ve rüzgâr hızına bağlı olarak İBGYYSA ve RTYSA modellerine uygulamışlardır. İBGYYSA yönteminin ölçülen günlük buharlaşma miktarına en yakın sonucu verdiğini tespit etmişlerdir.

Dai ve arkadaşları (2008), referans evapotranspirasyon ( $ET_0$ ) hesaplaması için Çin'in İç Moğolistan bölgesindeki kurak (batı), yarı kurak (orta) ve nemli (doğu) bölgeleri ayırmış, bu bölgedeki 135 meteoroloji istasyonundan ölçülen , yani hava sıcaklığı (T), bağıl nem (RH), rüzgar hızı (u) ve solar radyasyon (SR), iklimsel girdi parametreleri alınarak YSA modelleri oluşturmuşlardır. Çalışmadan elde edilen YSA ve çoklu doğrusal regresyon (ÇLR) model ile elde edilen tahminler arasında bir karşılaştırma yapılmıştır. Sonuçlar, iklim verileri kullanılarak oluşturulan YSA'ların  $ET_0$ 'ı başarıyla tahmin ettiğini ve YSA'ların  $ET_0$ 'ı ÇLR'lerden daha iyi tahmin ettiğini göstermiştir. Modeller arasında yapılan değerlendirmede dört girişi olan YSA modelinin, üç girişi olanlardan daha doğru sonuçlar verdiğini tespit etmişlerdir.

Landeras ve arkadaşları (2008), Kuzey İspanya'daki referans evapotranspirasyon ( $ET_0$ ) tahmin etmek için YSA modelleri, ampirik ve yarı ampirik denklemleri kullanmışlardır.  $ET_0$  değerlerinin yüksek maliyetli doğrudan ölçme teknikleri ile hesaplanabileceğini ya da matematiksel modeller oluşturularak tahmin edilebileceğini belirtmişlerdir. Çalışmada farklı YSA modellerini oluşturmak için ölçülen ortalama hava sıcaklığı ( $T_{mean}$ ), ölçülen en yüksek hava sıcaklığı ( $T_{max}$ ), ölçülen en düşük hava sıcaklığı ( $T_{min}$ ), solar radyasyon (SR),bağıl nem (RH) ve rüzgâr hızı (u) parametreleri kullanılarak farklı girdi kombinasyonları denenmiştir. Yedi farklı YSA modeli 10 farklı kalibre edilmiş ampirik ve

yarı ampirik denklem sonuçları ile istatistiksel hata hesapları kullanılarak karşılaştırılmıştır. Çalışma sonunda 4 farklı istasyon için oluşturulan modeller ve yapılan hesaplar YSA modellerinin ampirik denklemlerden daha iyi sonuç verdiğini ortaya çıkarmıştır.

Kişi (2010), yaptığı çalışmasında bulanık genetik yaklaşım (FG) ile referans buharlaşmayı modellemiştir. Çalışmada, Kaliforniya merkezli Windsor, Oakville ve Santa Rosa'daki üç istasyondan ölçülen sıcaklık (T), solar radyasyon (SR),bağıl nem (RH) ve rüzgâr hızı (u) meteorolojik verileri modelde girdi parametreleri olarak kullanılmıştır. Referans buharlaşma değerleri FAO 56 Penman-Monteith denklemi kullanılarak bulunmuştur. Çalışmada FG sonuçları Penman, Hargreaves, Ritchie ve Turc metotları ile kıyaslanmıştır. Bunlara ek olarak sonuçlar ayrıca oluşturulan bir YSA modeli ile de kıyaslanmıştır. Çalışmada karşılaştırma yöntemi olarak ortalama karesel hataları (OKH), kök ortalama karesel hata değeri (KOKH) ve determinasyon katsayısı istatistikleri kullanılmıştır. Bütün bunlar incelendiğinde bütün girdi parametrelerinin kullanıldığı FG1 modelinin diğer ampirik denklemlerden ve sadece SR ile T parametrelerini girdi olarak kullanan FG2 modelinden daha doğru sonuçlar verdiği görülmüştür. Benzer bir istatistiksel inceleme YSA ve FG modelleri içinde yapılmış sonuç olarak YSA ile FG yaklaşımının yaklaşık olarak aynı sonuçları verdiği tespit edilmiştir. Ancak hata miktarları ve determinasyon katsayısında ki ufak değişiklikler nedeniyle FG modelin daha iyi bir yöntem olduğu kanısına varılmıştır.

Üneş (2011), çalışmalarında, Tahtaköprü barajındaki aylık buharlaşma miktarının tahminini, Yapay Sinir Ağları (YSA) metodunu kullanarak araştırmıştır. Elde edilen sonuçlara göre; baraj haznesi aylık buharlaşma miktarının tahmininde kullanılan YSA model çözüm sonuçlarının, ölçüm değerleri ile uyumlu sonuçlar verdiğini görmüştür.

Shiri ve arkadaşları (2011), çalışmalarında ABD Illinois Eyaletindeki farklı coğrafi konumda bulunan üç hava istasyonundan, günlük referans evapotranspirasyonu, ölçülen sıcaklık (T), solar radyasyon (SR),bağıl nem (RH) yüzey toprak sıcaklığı ve toplam yağış gibi günlük meteorolojik verilere bağlı olarak 2005-2008 yılları arası yaklaşık 3 yıllık veri kullanarak ölçmüşlerdir. Günlük  $ET_0$ 'ı tahmin etmek için uyarlanabilir nöro-bulanık çıkarım sistemini (BM) ve yapay sinir ağlarını (YSA) kullanmışlardır. Modeller, determinasyon katsayısı ( $R^2$ ), kök ortalama kare hatası (KKOH), varyans katsayısı (VAF), verimlilik katsayısı ( $E_1$ ) ve anlaşılma endeksi ( $d_1$ ) gibi istatistiksel parametreler

kullanılarak değerlendirilmiştir. Sonuçlar hem uygulanan BM hem de YSA modellerinin özellikle iklim parametreleri sınırlı olduğunda, mevcut iklim verileri kullanılarak yapılan ET tahmin işlemlerinde oldukça iyi performans gösterdiğini göstermiştir.

Dalkılıç ve arkadaşları (2014), çalışmalarında günlük buharlaşma tahmin modelleri elde etmişlerdir. Yapılan araştırmada Ampirik Penman denklemini kullanarak, Levenberg-Marquardt algoritmasını " çalışmalarında ileri beslemeli geri yayımlı (İBGYYSA), radyal temelli yapay sinir ağı (RTYSA) ve genelleştirilmiş regresyon sinir ağları (GRYSA). modelinde kullanılarak, modelleri karşılaştırmışlardır. Modeller karşılaştırıldığında, sinir ağı modellerinin sonuçlarının Penman'dan istatistiksel olarak daha anlamlı olduğunu fark etmişlerdir.

Terzi ve Ergin (2014), çalışmalarında Türkiye'deki Kızılırmak Nehri için aylık ortalama akış miktarı tahmini için otoregressif (AR) modelleme ve gen ekspresyon programlama (GEP), radyal temel fonksiyon ağı ve ileri beslemeli sinir ağları ve uyarlamalı sinirsel bulanık çıkarım sistemi (BM) teknikleri içeren veri odaklı teknikler kullanmışlardır. Modellerin geliştirilmesinde 1955'ten 1995'e kadar süren aylık nehir akış ölçümlerini dikkate almışlardır. Geliştirilen modellerin doğruluğunu değerlendirmek için korelasyon katsayısı ve kök ortalama kare hata performans kriterleri kullanılmışlardır. Geliştirilen modellerin sonuçları bu kriterler kullanılarak yapılan akış ölçümleriyle karşılaştırıldığında, AR (2) modelinin tüm gelişmiş modeller arasında en iyi performansı verdiğini, GEP ve BM modellerinin veri güdümlü tekniklerde iyi performans gösterdiği sonucuna ulaşmışlardır.

Keshtegar ve arkadaşları (2017), Çankırı, Ankara ve Kırıkkale gözlem istasyonlarındaki iklimsel kullanarak günlük buharlaşma tahmini yapmışlardır. İklimsel veri olarak Hava Sıcaklığı, Solar Radyasyon, Bağıl Nem, Rüzgâr hızı parametrelerinden faydalanarak Yapay Sinir Ağı (YSA), Bulanık Mantık (BM) ve M5 model tree (M5 Ağacı) yöntemlerini kullanmış ve buharlaşma tahmini yapmışlardır.

Gümüş ve arkadaşları (2018), aylık ortalama buharlaşma tahminini elde etmek amacıyla Bulanık Mantık (BM), Yapay Sinir Ağı (YSA), ve Gen Ekspresyon Programlama (GEP) yöntemlerini kullanılmışlardır. Nem(%), aylık ortalama sıcaklık ( $C^0$ ), rüzgâr hızı (m/s), güneşlenme şiddeti ( $cal / cm^2$ ), basınç (hPa), ve güneşlenme süresi (saat) meteorolojik verileri kullanılarak, Adana istasyonundaki aylık ortalama buharlaşma miktarını tahmin

etmişlerdir.. Farklı girdi parametreleri kombinasyonları oluşturularak, ANFIS YSA ve GEP metotları kullanılarak elde edilen sonuçlar ile karşılaştırılmıştır. Elde edilen sonuçlar doğrultusunda, kullanılan tüm metotların buharlaşma tahmininde kabul edilebilir derecede başarılı olduğu ancak BM metodunda 6 girdili kombinasyonunun, oluşturulan diğer modellere göre en başarılı sonucu verdiği belirlenmiştir.

Taşar ve arkadaşları (2018), çalışmalarında, buharlaşma miktarı tahmininde çalışma alanı olarak Massachusetts, U.S.A (Cambridge Hazne ve havzası) seçmişler ve günlük ortalama buharlaşma miktarı tahmini yapmak için çalışma alanından alınan ortalama günlük hava sıcaklığı (Tmean), rüzgâr hızı (u), güneşlenme miktarı (SR) ve bağıl nem (RH) verilerini kullanmışlardır. Ritchie, Hargreaves-Samani, ve Turc denklemleri gibi ampirik (klasik) yöntemler ile Yapay sinir ağları (YSA) yöntemlerini karşılaştırmak için buharlaşma miktarı tahmin etmeye çalışılmışlardır. YSA optimizasyonu için hataların geriye yayılma ilkesine göre çalışan geriye beslemeli ağ algoritması kullanılmışlardır. YSA sonuçlarını, geleneksel Hargreaves-Samani, Ritchie ve Turc yöntemlerinin sonuçları ile karşılaştırmışlardır. Karşılaştırma sonucunda, YSA modelinin buharlaşma miktarı tahmininde geleneksel yöntemlerden daha iyi performans ortaya koyduğunu gözlemlemişlerdir.

Adamala ve arkadaşları (2018), çalışmalarında, Hindistan'daki dört tarımsal ekolojik bölgedeki farklı konumlardaki elde edilmiş iklim verilerini kullanarak tava buharlaşmasını ( $E_p$ ) tahmin etmek için geliştirilmiş yüksek dereceli sinir ağı (GHNN) modellerini geliştirmeyi amaçlamışlardır. GHNN modellerinin geliştirilmesi için girdi olarak hava sıcaklığı, bağıl nem, rüzgar hızı ve güneş radyasyonu gibi günlük iklim verilerinin farklı kombinasyonlarını kullanmışlardır. Gelişmiş GHNN'lerin karşılaştırması, geliştirilmiş birinci dereceden sinir ağı (GFNN) ve geliştirilmiş çoklu doğrusal regresyon (GMLR) modelleri ile yapılmış, GHNN'lerin, GFNN'lerle birlikte GMLR modellerinden daha iyi performans gösterdiğini tespit etmişlerdir. Ayrıca, genelleme kabiliyetini test etmek için model geliştirme ve model test yerlerine GHNN'ler uygulamışlardır. Test sonuçlarına dayanarak, GHNN modellerinin iyi bir genelleme yeteneğine sahip olduğunu görmüşlerdir.

Seifi ve Riahi (2018), çalışmalarında, İran'ın Zahedan istasyonunun kurak koşulları altında günlük  $ET_0$ 'ı tahmin etmek için En küçük kareler destek vektör makinesi-gama testi (LSSVM-GT) ile hibrid bir model önermişlerdir. Modellerde en iyi giriş vektörlerini seçmek için gama testi kullanılmışlardır. Farklı RBF çekirdekleri, doğrusal ve polinom



içeren LSSVM-GT modeli tarafından tahmin edilen  $ET_0$ , YSA-GT, BM-GT ve ampirik denklemleri içeren diğer hibrit yaklaşımlarla karşılaştırılmıştır. Gama testi, minimum ve maksimum hava sıcaklığı ve rüzgar hızındaki iklim değişkenlerinin en önemli parametreler olduğunu tespit etmişlerdir. LSSVM modeli, benzer meteorolojik girdi değişkenleri kullanıldığında, BM ve YSA modellerinden daha iyi performans gösterdiği sonucuna ulaşmışlardır. Ayrıca, üç LSSVM, BM ve YSA modelinin performansı, Blaney-Criddle ve Hargreaves-Samani gibi deneysel denklemlerden daha iyi olduğunu gözlemlemişlerdir. Genel performansların karşılaştırmasına dayanarak, geliştirilen LSSVM-GT yaklaşımının, İran'ın kurak bölgelerinde yüksek hassasiyetle olumlu tahminler sunma konusunda oldukça yetenekli olduğu sonucuna ulaşmışlardır.

Majumder ve Kumar (2019) Bhagalpur'da FAO-Penmann Monteith (1998), Thornthwaite, Papadakis, Jensen-Haise, Modified Jenson ve Haise deneysel yöntemlerini kullanarak aylık buharlaşma tahmini yapmışlardır. Bhagalpur için 2014-2017 yılları arasındaki 4 yıllık hava durumu verileri, aylık buharlaşma tahmini farklı ampirik yöntemler kullanarak hesaplamışlardır. Tava buharlaşmasını diğer yöntemlerle kıyaslamışlardır. Genel performansların karşılaştırmasına dayanarak, kullanılan Jensen-Haise yönteminin olumlu tahminler sunma konusunda oldukça yetenekli olduğu sonucuna ulaşmışlardır.

Ammar, G. A., Hayek, S. B., ve Mayassah (2019). araştırmalarında, günlük meteorolojik verileri kullanarak Tartous'ta bulunan AL-BASEL rezervuarından günlük buharlaşma tahmininde yapay sinir ağlarının (YSA) kullanılmasının etkinliğini araştırmayı amaçlamışlardır.. Matematiksel model, ağ girişi olarak ortalama hava sıcaklığı, ortalama bağıl nem, güneş radyasyonu, ortalama rüzgâr hızı kullanılarak bir Amerikan pan tava sınıfından ölçülen günlük buharlaşma miktarı bu dört meteorolojik parametreye dayanarak yapılmıştır.. Performans doğruluğunu kontrol etmek için ağ modellemesi yapmışlardır. Hata geri yayılma algoritması kullanılarak çok katmanlı bir yapay sinir ağı inşa edilmiş ve gizli katmanların sayısı seçilerek ve her bir katmanda kullanılan nöronların sayısı ve aktivasyon işlevleri araştırılmıştır. Çalışmada yapay sinir ağının YSA yapısının (4-28-1), korelasyon katsayısının değeri ( $R=0,844$ ) ve kök ortalama değerini göz önünde bulundurarak çalışma alanındaki günlük buharlaşmayı yüksek doğrulukla tahmin edilebildiğini gözlemlemişlerdir.. Kare hata test veri setinin (1,15 mm / gün) olduğu sonucuna ulaşılmışlardır Bu çalışmada açıkça günlük buharlaşmayı tahmin etmek için YSA hata geri yayılım tekniğini kullanmanın mümkün olabileceğini tespit etmişlerdir.

Bu tez çalışmasında, günlük buharlaşma tahmini için yapay zekâ tekniklerinden yapay sinir ağları (YSA) ve Radyal tabanlı yapay sinir ağları (RTYSA) teknikleri kullanılmıştır. Kullanılan bu tekniklerle Oto-regresif AR(p) modeli elde edilmiştir. Bu tez çalışmasının amacı YSA, RTYSA ve Oto-regresif AR(p) modelleri ile elde edilen sonuçların, geçmişte kullanılan klasik ampirik yöntemlerden Hargreaves Samani ve Turc metotları ile karşılaştırılarak modellerin uygulanabilirliği ve geçerliliği araştırmaktır.



### 3. MATERYAL VE YÖNTEM


#### 3.1. Çalışma Alanı

Bu çalışmada kullanılan veriler, ABD'nin güneydoğusunda bulunan Güney Carolina Eyaleti, Near Anderson'daki ölçüm istasyonlarından alınmıştır. Bu bölge, ılıman subtropikal iklim kuşağında bulunup, yazlar çok sıcak ve nemli, kışları ise ılık ve yumuşak geçmektedir. Bu çalışmada kullanılan istasyon ( USGS İstasyon no:02187010) 34°30'30" kuzey enlemi ve 82°51'19" doğu boylamı üzerinde yer alıp, Güney Atlantik WSC Clemson Saha Ofisi tarafından yönetilmektedir. Bu çalışmada kullanılan istasyonun bulunduğu Hartwell Gölü, Savannah, Tugaloo ve Seneca Nehir'lerinde Georgia ve Güney Carolina'yı çevreleyen insan yapımı bir rezervuardır. Hartwell gölü, ABD'nin güneydoğusundaki en büyük rekreasyon(Boş zaman değerlendirme etkinliklerinin yapıldığı) göllerinden biridir. Göl, Tugaloo ve Seneca Nehirlerinin Savannah'yı oluşturmak için birleştiği yerin yedi mil (11 km) altında, Savannah Nehri üzerinde bulunan Hartwell Barajından oluşturulmuştur. Tugaloo'ya 49 mil (79 km) ve Seneca'ya normal havuz kotunda 45 mil (72 km) kadar uzanan göl, 962 mil (1,548 km) kıyı şeridi ile yaklaşık 56 000 dönüm (230 km<sup>2</sup>) sudan oluşmaktadır. Hartwell projesi 76 450 dönüm (309 km<sup>2</sup>) toprak ve su içeren alana etki etmektedir.


Çizelge 3.1. Hartwell gölüne ait büyüklükler (Wikipedia,2019).

<b>Yüzey alanı</b>	56 000 dönüm
<b>Ortalama derinlik</b>	45 ft (14 m)
<b>Maximum derinlik</b>	185 ft (56 m)

Şekil 3.1 ve Şekil 3.2'de bu çalışmada kullanılan verilerin alındığı Hartwel Gölünün genel görünümü ve seçilen bölgenin dünya üzerindeki ve yakın ölçekli görünümünün verildiği haritalar verilmiştir.




Şekil 3.1. Çalışılan istasyonun bulunduğu Hartwell gölü (Wikipedia,2019).



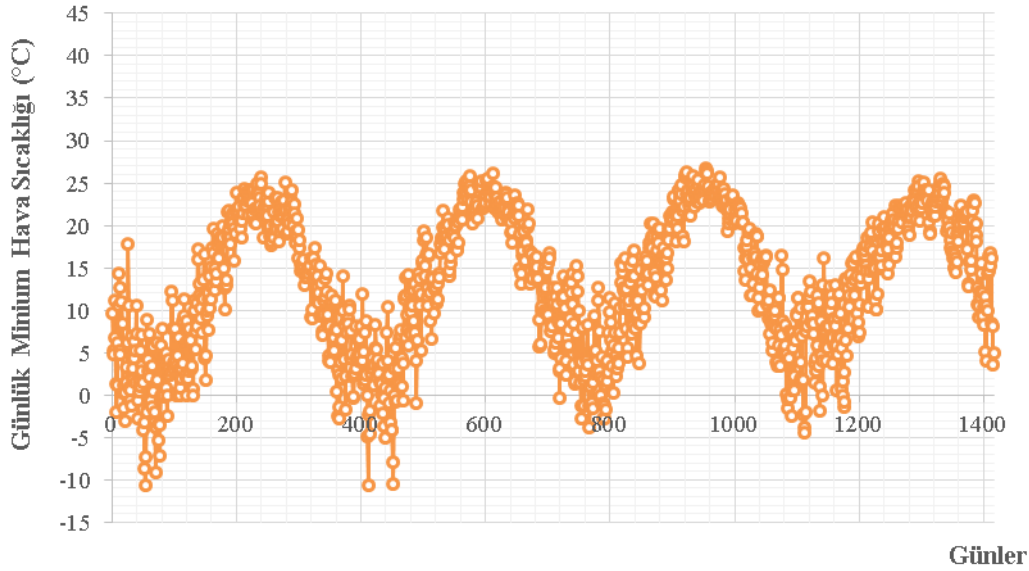
Şekil 3.2. Çalışılan istasyonun konumu (Google Maps,2019).

Bu çalışmada kullanılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki 4 yıllık toplamda 1416 tane günlük meteorolojik ölçüm verisi kullanılmıştır. Günlük ortalama buharlaşma miktarı tahmini için ortalama günlük hava sıcaklığı ( $T_{mean}$ ), en yüksek ( $T_{max}$ ) ve en düşük günlük hava sıcaklıkları ( $T_{min}$ ), rüzgâr hızı ( $u$ ), güneşlenme miktarı ( $SR$ ) ve bağıl nem ( $RH$ ) kullanılmıştır. Modelin oluşturulmasında ve kalibrasyonunda, tüm verilerin %80'i eğitimde ve kalan %20'si test için kullanılacaktır. 1416 tane günlük meteorolojik ölçüm verisinin 1133 günlük ölçüm değerleri eğitim için,


283 günlük ölçüm verisi test için kullanılmıştır. Veriler USGS (United States Geological Survey) ve [www.usclimatedata.com](http://www.usclimatedata.com) web sayfalarından alınmıştır Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük veri miktarı değişimleri Şekil 3.3, Şekil 3.4, Şekil 3.5, Şekil 3.6, Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da verilmiştir.




Şekil 3.3. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük maksimum hava sıcaklığı (°C) miktarı değişimleri



Şekil 3.4. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük minimum hava sıcaklığı (°C) miktarı değişimleri




Şekil 3.5. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük ortalama hava sıcaklık ( $^{\circ}\text{C}$ ) miktarı değişimleri




Şekil 3.6. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük solar radyasyon ( $\text{Mj}/\text{m}^2$ ) miktarı değişimleri





Şekil 3.7. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük nisbi nem (%) miktarı değişimleri




Şekil 3.8. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük ortalama rüzgar hızı (m/s) değişimleri

Bu çalışmada FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini ( $ET_0$ ) yapılmış, Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir. Penman Monteith metoduna göre günlük ortalama buharlaşma tahmini yapmak için ortalama günlük hava sıcaklığı ( $T_{mean}$ ), en yüksek günlük hava sıcaklığı ( $T_{max}$ ), en



düşük günlük hava sıcaklığı ( $T_{\min}$ ), rüzgâr hızı ( $u$ ), güneşlenme miktarı ( $SR$ ) ve bağıl nem ( $RH$ ) parametreleri kullanılmıştır. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki referans günlük buharlaşma miktarı değişimleri şekil 3.9'da gösterilmiştir.



Şekil 3.9. Çalışılan istasyondaki Hartwell gölüne ait 2013-2017 yılları arasındaki günlük buharlaşma miktarı(mm) değişimleri

Hartwell Gölü'nün kuraklık ve su miktarı olarak 9 Aralık 2008'de en düşük seviyesine, 194,31 metreye (637,49 feet) ulaşmıştır. Gölün en kurak 2. zamanı ise yine 2008 yılı olmuştur 1989 yılında ise en düşük 3. seviyeye ulaşmıştır. Çalışılan istasyondaki göle ait en yüksek göl yüksekliği, 8 Nisan 1964'te ulaşılan 202,8 m'dir (665,4 feet). Genel olarak ortalama göl yüksekliği 200,4 m'dir (200,4 m).

### 3.2. Kullanılan Modeller

Bu çalışmada FAO (Food and Agriculture Organization) tarafından standart metod olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini ( $ET_0$ ) yapılmış, Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir. Hargreaves-Samani, ve Turc denklemleri gibi ampirik yöntemler ile Yapay Sinir Ağları (YSA), Radyal Tabanlı Yapay Sinir Ağları (RTYSA), Çoklu Doğrusal Regresyon (ÇDR) yöntemleri ve Oto-regresif modelin  $AR(p)$  performansları karşılaştırılarak buharlaşma miktarı tahmin edilmeye çalışılmıştır. Çalışma alanı olarak South Carolina

(USD) Anderson bölgesindeki Hartwell gölü civarındaki bir istasyon tercih edilmiştir. Günlük ortalama buharlaşma miktarı tahmini için ortalama günlük hava sıcaklığı ( $T_{mean}$ ), en yüksek ( $T_{max}$ ) ve en düşük günlük hava sıcaklıkları ( $T_{min}$ ), rüzgâr hızı ( $u$ ), güneşlenme miktarı ( $SR$ ) ve bağıl nem ( $RH$ ) kullanılmıştır

### 3.2.1. Ampirik yöntemler

Bu çalışmada FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini yapılmış ( $ET_0$ ), Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir. Ayrıca, Hargreaves-Samani, ve Turc denklemleri gibi ampirik (geleneksel) yöntemlerde buharlaşma tahmininin de kullanılmıştır.

#### Penman-Monteith (PM) yöntemi

Amerika Birleşik Devletleri de dâhil olmak üzere dünyanın çoğu yerinde uygun kabul gören ve iklimsel hava parametrelerinin bir fonksiyonu olarak referans evapotranspiration ( $ET_0$ ) endeksinin oluşturulmasında FAO-PM yöntemi kullanılmıştır ve bu yöntem ise hava durumu verileri ile yapılmıştır.

Bu çalışmada FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini yapılmış ( $ET_0$ ), Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir

Jensen, vd. (1990), tarafından belirtildiği üzere PM denklemi (3.1) aşağıdaki gibidir.

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (3.1)$$

Bu denklemde  $ET_0$  : referans evapotranspirasyonu [ $mm \ g\ddot{u}n^{-1}$ ],  $R_n$ : bitki yüzeyinde net radyasyonu [ $MJ \ m^{-2} \ g\ddot{u}n^{-1}$ ],  $G$ : toprak ısı akısı yoğunluğunu [ $MJ \ m^{-2} \ g\ddot{u}n^{-1}$ ],  $T$ : 2m yükseklikteki ortalama günlük hava sıcaklığını [ $^{\circ}C$ ], ( $U_2$ ): 2 m yükseklikteki rüzgâr hızını [ $m/s$ ],  $e_s$ : doymuş buhar basıncını [ $kPa$ ],  $e_a$ : mevcut buhar basıncını [ $kPa$ ], ( $e_s$ ) - ( $e_a$ ): doymuş buhar basıncı açığı [ $kPa$ ],  $\Delta$ ; buhar basıncı eğrisi eğimini [ $kPa \ ^{\circ}C^{-1}$ ],  $\gamma$ : psikrometrik sabitini [ $kPa \ ^{\circ}C^{-1}$ ] ifade etmektedir.

### Hargreaves-Samani denklemi

Hargreaves ve Samani (1985) buharlaşma miktarı tahmini yapmak için deneysel çalışmışlardır. Gelişmekte olan ülkelerdeki mahsul su ihtiyacını tahmin etmek için eksiksiz ve güvenilir iklim verilerinin kıtlığı göz önüne alındığında, bu denklem, kullanışlı olabilmektedir. Hargreaves ve Samani denklemleri (3.2) aşağıdaki gibidir.

$$ET=0,0135R_s \cdot 0.408(T_{mean}+17,8) \quad (3.2)$$

Yukarıda denklem (3.2)'de verilen güneşlenme miktarı ( $R_s$ ) yi bulmak için Dünya dışından gelen güneşlenme miktarı ( $R_a$ ) arasındaki ampirik ilişki şu şekilde (3.3) ifade edilmiştir;

$$R_s=0.16R_a \cdot \sqrt{T_{max} + T_{min}} \quad (3.3)$$

**ET:** buharlaşmayı [ $mm \text{ gün}^{-1}$ ],  **$T_{mean}$ :** günlük ortalama sıcaklığı [ $^{\circ}C$ ],  **$R_s$ :** günlük güneşlenme miktarını [ $MJ \text{ m}^{-2} \text{ gün}^{-1}$ ],  **$T_{max}$ :** günlük maksimum sıcaklığı [ $^{\circ}C$ ],  **$T_{min}$ :** günlük minimum sıcaklığını [ $^{\circ}C$ ], ifade etmektedir.

### Turc denklemi

Bu denklemi Turc (1961) tarafından bulunmuştur. Turc denklemi, nemli koşullar altında referans buharlaşma transpirasyonunu ( $ET_0$ ) tahmin etmek için kullanılan en basit ampirik denklemlerden biridir. Turc denklemi, tüm nemli yerlerde güvenilir bir hesaplama sunduğu ve yerel iklim koşullarına en ayarlanabilir olduğu kanıtlanmıştır.

Turc denklemleri (3.4), (3.5) aşağıdaki gibidir.

$$RH > \%50 \text{ ise } ET = 0,0133 \times \frac{T_m}{T_m+15} \times (R_s + 50) \quad (3.4)$$

$$RH < \%50 \text{ ise } ET = 0,0133 \times \frac{T_m}{T_m+15} \times (R_s + 50) \times \left(1 + \frac{(50-RH)}{70}\right) \quad (3.5)$$


Bu ifadelerde, **ET:** buharlaşmayı [ $mm \text{ gün}^{-1}$ ],  **$R_s$ :** güneşlenme miktarını [ $MJ \text{ m}^{-2} \text{ gün}^{-1}$ ],  **$T_m$ :** ortalama sıcaklığı [ $^{\circ}C$ ],  **$RH$ :** bağıl nemi [%] ifade etmektedir.

Burada bağıl nem ( $RH$ )'in %50 den küçük veya büyük olmasına bağlı olarak buharlaşma miktarı ( $ET$ ) farklılık göstermektedir.

### 3.2.2. Yapay sinir ağıları metodu (YSA)

YSA modeli, elimizde var olan birçok probleme uygulanabilir bir yöntemdir. Bu yöntem çalışmalardan bağımsız ve oldukça derindir. Her olayda kullanılabilir. Bu sebeple, yapay sinir ağıları yöntemi, inşaat, makine ve tıptan mikro elektriğe kadar birçok farklı ve geniş alanda uygulanabilmektedir.

Yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve W.A. Pitts tarafından 1943 yılında yayınladıkları bir makaleyle atılmıştır. Daha sonra 1954 yılında B.G. Farley ve W.A. Clark tarafından bir ağ kullanılarak uyarılara tepki veren ve adapte olabilen bir model oluşturulmuştur. 1960 yılı ise ilk neural bilgisayarın ortaya çıkış yılıdır. 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, ancak başarılı sonuçların alınması 1970 ve 1980'lerde termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına kadar gecikmiştir. 1985 yapay sinir ağlarının oldukça tanındığı, yoğun araştırmaların başladığı yıl olmuştur (Mehra ve Wah, 1990). Şekil 3.10'da YSA'ların gelişiminin tarihçesi gösterilmiştir.



Şekil 3.10. Yapay sinir ağlarının gelişimi tarihçe zaman çizelgesi (Öztemel,2006).

Yapay Sinir Ağları (YSA) özellikle doğrusal olmayan sistemlerde, geleneksel sistemlere göre oldukça fazla üstünlüklere sahiptirler.

Yapay Sinir Ağları (YSA) Avantajları şunlardır:


- 1) Yapay sinir ağlarının en önemli özelliklerinden birisi gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir, yani doğrusal olmayışıdır. YSA' nın temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. YSA'lar bu özellikleri ile doğrusal olmayan karmaşık problemlerin çözümünde önemli araçlardan biri haline gelmiştir.

- 2) Günümüzde kullanılan bilgi işleme yöntemleri genelde seri, sıralı işlemlerden oluşmaktadır. Seri işlemcilerde herhangi bir birimin yavaş olması tüm sistemi yavaşlatırken, YSA'ların sahip olduğu paralellik sayesinde yavaş bir birim sistemin çalışması sırasında herhangi bir soruna yol açmamaktadır. Bu durum YSA'ların daha hızlı ve güvenilir olmasını sağlamaktadır.
- 3) Geleneksel hesaplama yöntemlerinde bir problemin çözülebilmesi için probleme uygun bir algoritma geliştirilmesi ve programlama yolu ile hesaplama yapılması gerekmektedir. Genellikle bu tür algoritmaların çözüm yeteneği uzmanın kod yazma yeteneği ile sınırlıdır. Bu tür algoritmaların zorluğu ve her problem türüne göre farklı algoritma yazılma ihtiyacı nedeniyle geleneksel yöntemler karmaşık problemlerin çözümünde kullanılamazlar. Herhangi bir nesneyi bilgisayara geleneksel yöntemlerle öğretmek için nesnenin mümkün olan tüm açılardaki ve uzaklıklardaki görüntülerini, mümkün olan tüm değişik kombinasyonları ile birlikte göstermeniz gerekmektedir. YSA'ların öğrenme sistemi ise insan beyninin çalışma şekline benzemektedir. Öğrenme, özellikleri verilen örnekler yoluyla yapay sinir ağının kendisi tarafından sağlanmakta ve YSA'lar, örnekleri kullanarak probleme ilişkin genelleme yapabilecek yeteneğe ulaşmaktadır. Bu özelliği sayesinde geleneksel yöntemler için karmaşık olan sorunlara çözüm üretilebilmektedir. Ayrıca, insanların kolayca yapabildiği ancak geleneksel yöntemler için imkânsız olan basit işlemler için de uygun olmaktadır. Geleneksel sistemlerden ayrıldığı bir başka nokta ise sürekli öğrenmedir. YSA'lar kendisine gösterilen yeni örnekleri öğrenebilmeleri ve yeni durumlara adapte olabilmeleri sayesinde sürekli olarak yeni olayları öğrenebilmesi mümkündür
- 4) Geleneksel hesaplama yöntemlerinde bilgi, veri tabanlarında veya program kodlarının içinde saklanmaktadır. Yapay sinir ağlarında ise bilgi, nöronlar arasındaki ağırlıklı bağlantılarda saklanmaktadır. Yani bilgi ağa dağıtılmış durumdadır ve ağın bütünü, öğrendiği olayın tamamını göstermektedir. Bu nedenle yapay sinir ağlarının dağıtılmış bellekte bilgi saklayabilmektedirler.
- 5) Yapay sinir ağları istatistiksel yöntemlerin aksine sınırsız sayıda değişken ve parametre ile herhangi bir ekstra dönüşüme ihtiyaç duymadan çalışabilmektedir. Bu sayede mükemmel bir tahmin doğruluğu ile genel çözümlere ulaşılabilir.
- 6) Yapay sinir ağları, kullanıldığı problemdeki değişikliklere göre ağırlıklarını ayarlayabilmektedir. Yani belirli bir problemi çözmek amacıyla eğitilen bir yapay sinir ağı, problemdeki değişimlere göre tekrar eğitilebilmekte, değişimler devamlı

ise gerçek zamanda da eğitime devam edilebilmektedir. Bu özelliği ile yapay sinir ağları, uyarlamalı (adaptive) örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılabilirler.

- 7) Yapay sinir ağları, geleneksel sistemlerin aksine, kendileri eğitildikten sonra eksik bilgiler ile çalışabilmekte ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilmektedirler. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmemektedir. Performansın düşmesi eksik olan bilginin önemine bağlı olmaktadır. Hangi bilginin önemli olduğunu ağın kendisi eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağın performansı düşük olunca, kayıp olan bilginin önemli olduğu, performans düşmez ise eksik bilginin önemli olmadığı sonucuna varılmaktadır.
- 8) YSA'lar, kendi kendine öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlar için genelleme yapabilmektedirler. Yani, hatalı (gürültülü) veya kayıp veriler için çözüm üretebilmektedir. YSA'lar, daha önce görmedikleri veriler veya eksik veriler hakkında karar verirken genelleme yapabilmektedirler.
- 9) Hata toleransına sahiptirler. YSA'ların eksik bilgilerle çalışabilmeleri ve bazı hücreleri bozulsa dahi çalışabilmeleri, onları hatalara karşı toleranslı yapar. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir. Ayrıca toplam işlem yükünü paylaşan işlemci elemanların birbirleri arasındaki yoğun bağlantı yapısı sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, yapay sinir ağları yöntemi en karmaşık problemlere bile uygulanabilmekte ve tatminkâr çözümler sağlayabilmektedir.

Gerçek sinir hücresinde, sinir hücresine diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücelere aksonlarla iletilir; uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar. Sinaptik boşluk içinde yer alan “sinaptik kesecikler”, gelen uyarımların diğer hücelere dendritler aracılığıyla geçmesini sağlayan elemanlardır. Sinaptik boşluğa, “sinaptik kesecikler” tarafından sağlanan nöro-iletken maddenin dolması uyarımların diğer hücelere geçişini sağlar. Hücelere gelen uyarımlarla uyumlu olarak hücreler arasındaki mevcut sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir.



Şekil 3.11. Nöron yapısı

Nöronlar, çeşitli şekilleri olmasına rağmen, bir uçtan diğerine, dendrit' ten akson'a doğru elektrik sinyali iletirler. Genel bir ifade ile bir elektrik sinyali alır ve başka bir elektrik sinyali çıkarır. Bu sinyaller daha sonra diğer bir nörona iletilir.

Çizelge 3.2. Biyolojik Sinir Yapısı İle Yapay Sinir Ağı Karşılıkları (Koç, 2004)

<b>Biyolojik Sinir Sistemi</b>	<b>Yapay Sinir Sistemi</b>
Sinapslar	Ağırlıklar
Nöron	İşlemci eleman
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Yapay nöron çıkışı

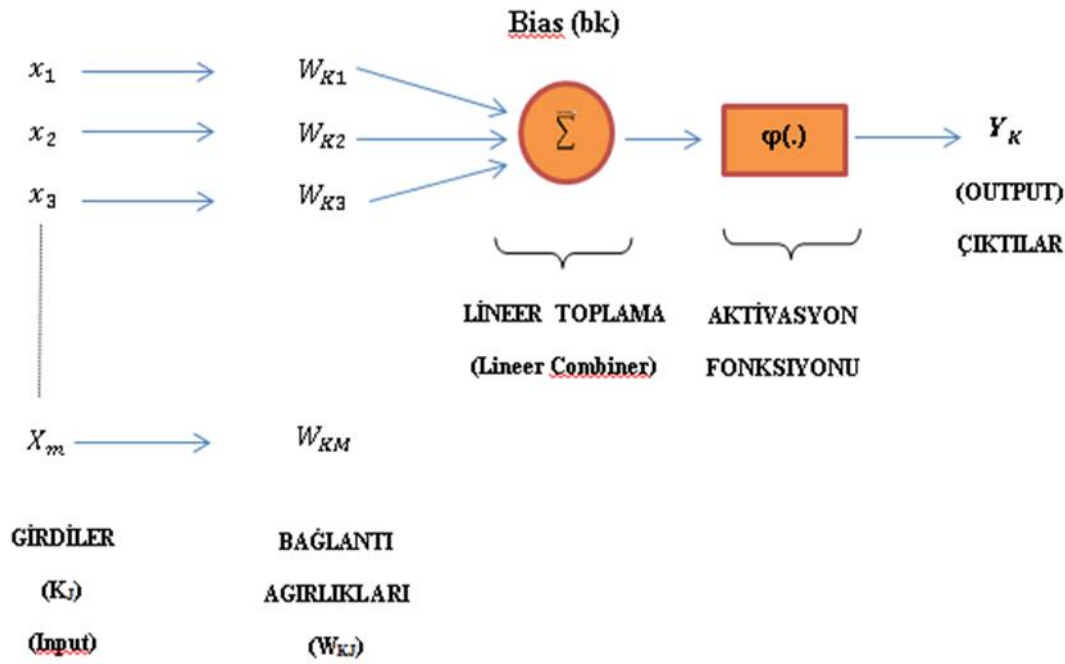
### Bir nöronun modeli

Bir yapay sinir ağının temelini oluşturan bilgi işleme birimi nörondur. Snopsis (bağlantı elemanları): Bunların her biri kendi etkinlik veya ağırlık derecesiyle tanımlanır. Özellikle bir  $k$  nöronuna bağlanan ( $j$ ) snopsisinin girdi kümesindeki bir  $X_j$  elemanı,  $W_{kj}$  bağlantı ağırlık katsayısı (snoptik weight) ile çarpılır.

Nöronların ağırlıklı çarpımları ve nöronların bağlantılarının ağırlık etkisiyle bağlı değişen bias (dış etkileri yansıtan) terimi ile toplanır. Bu işlem lineer birleştirmenin (Lineer combiner) oluşturulması olarak tanımlanır.

Yani gözlemler, nöronların hızlı bir şekilde tepki göstermediğini, bunun yerine girdiyi

belirli bir eşik değerini aşana kadar bastırıldığını ve bunun bir çıkışı tetiklediğini vurgulamaktadır. Yani, herhangi bir çıktı üretilmeden önce erişilmesi gereken bir eşik değeri (threshold) vardır. Eşik değerini dikkate alarak çıktı üreten fonksiyonlara “Activation Function” denir. Aktivasyon fonksiyonunun amacı, bir nöronun çıkışına non-linearity getirmektir. Çünkü gerçek verilerin çoğu doğrusal değildir. Nöronların bu doğrusal olmayan ilişkiyi sağlaması istenir.



Şekil 3.12. Basit bir YSA yapısı

Şekil 3.12’deki,  $x_1, x_2, x_3, \dots, x_m$ , Girdileri;  $w_{K1}, w_{K2}, w_{K3}, \dots, w_{KM}$ , K nöronunun bağlantı ağırlığını;  $b_K$  bias terimini;  $\varphi(.)$  aktivasyon fonksiyonunu;  $Y_K$  ise çıktı değerini ifade etmektedir.

Girdi (input) sinyallerinden dolayı oluşan lineer birleşen çıktısı (Lineer birleşim toplamı),  $V_K$ , aşağıda denklem (3.6)’da ki eşitlik ile ifade edilmektedir.

$$V_K = \sum_{j=1}^M w_{Kj} \cdot x_j \quad (3.6)$$

Çıktı değeri ise;

$$Y_K = \varphi(V_K + b_K) \quad (3.7)$$



olarak belirlenir. Burada bias terimi (dış etken parametresi veya aktivasyon fonksiyonunun girdilerinin artması ya da azalmasının etkisini katmak amacıyla kullanılan bir sabittir),  $b_K$  bu çalışmada 1 olarak alınmış ve; aşağıdaki denklem (3.8) elde edilmiştir

$$Y_K = \varphi(V_K) \quad (3.8)$$

Tipik olarak aktivasyon fonksiyonu sonucunda bir nöronun çıktısının normalize edilmiş genlik alanı, kapalı bir birim aralığı olarak  $[0-1]$  veya  $[-1, 1]$  arasında alınabilir (Ciğizoğlu,2004)


### Aktivasyon fonksiyonları

Bir nöronun çıktılarının genliğini sınırlamak için birçok tip aktivasyon fonksiyonu, " $\varphi(V)$ ", vardır. Bunlar arasında, en çok kullanılan aktivasyon fonksiyonları; Adım Aktivasyon Fonksiyonu, Doğrusal Aktivasyon Fonksiyonu (Purelin), Sigmoid Aktivasyon Fonksiyonu ve Eşik Değer Fonksiyonu 'dur.

### Doğrusal aktivasyon fonksiyonu

Doğrusal problemleri çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Çıktı girdiye bağlı olarak, Şekil 3.13'te görüldüğü gibi doğrusal olarak değişir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak kabul edilir. Bu fonksiyonun değişim aralığı -1 ile 1 arasındadır. Doğrusal fonksiyon denklem (3.9)'da ki gibi gösterilebilir.

$$y = x \quad (3.9)$$




Şekil 3.13. Doğrusal aktivasyon fonksiyonu.

### Adım aktivasyon fonksiyonu

Aktivasyon fonksiyonların en basiti ise Adım Aktivasyon Fonksiyonu 'dur.

Gelen Net girdinin belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır. Matlab de kullanılan eşik fonksiyonu Şekil 3.14'te verilmiştir




Şekil 3.14. Adım aktivasyon fonksiyonu

### Sigmoid fonksiyonu:

Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir. YSA teorisinin önemli bir özellik gösteren farklılaştırılabilir bir işlevidir. Denklem (3.10)' da gösterildiği gibi işlev görmektedir.

$$y = \frac{1}{1+e^{-x}} \quad (3.10)$$




Şekil 3.15. Sigmoid Aktivasyon Fonksiyonu

### Eşik değer fonksiyonu

Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.

### Yapay sinir ağ yapısı

Yapay sinir ağları yapay sinir hücrelerinin birbirine bağlanmasıyla oluşan yapılardır. Yapay sinir ağları üç ana katmanda incelenir. Bunlar Giriş Katmanı, Ara Katmanlar ve Çıkış Katmanıdır. Yaygın simüle edilmiş bir nöron ve çok katmanlı bir sinir sistemi Şekil 3.16'da gösterilmiştir.



Şekil 3.16. Yapay sinir hücresi

Giriş Katmanı (Input Layer) Yapay sinir ağına dış dünyadan girdilerin geldiği katmandır. Bu katmanda dış dünyadan gelecek giriş sayısı kadar hücrenin bulunmasına rağmen genelde girdiler herhangi bir işleme uğramadan alt katmanlara iletilmektedir.

Ara Katman (Hidden Layer) giriş katmanından çıkan bilgilerin geldiği katmandır. Ara katman sayısı ağdan ağa değişebilir. Bazı yapay sinir ağlarında ara katman bulunmadığı gibi bazı yapay sinir ağlarında ise birden fazla ara katman bulunmaktadır. Ara katmanlardaki nöron sayıları giriş ve çıkış sayısından bağımsızdır. Birden fazla ara katman olan ağlarda ara katmanların kendi aralarındaki hücre sayıları da farklı olabilir. Ara katmanların ve bu katmanlardaki nöronların sayısının artması hesaplama karmaşıklığını ve süresini arttırmasına rağmen yapay sinir ağının daha karmaşık problemlerin çözümünde kullanılabilmesine olanak sağlar.

Çıkış Katmanı (Output Layer) ise ara katmanlardan gelen bilgileri işleyerek ağın çıktılarını üreten katmandır. Bu katmanda üretilen çıktılar dış dünyaya gönderilir. Geri beslemeli ağlarda bu katmanda üretilen çıktı kullanılarak ağın yeni ağırlık değerleri hesaplanır.

#### Yapay sinir hücrelerinin çıkışı

Hücresinin çıkış değeri aktivasyon fonksiyonu tarafından belirlenen çıkış değeri olarak tanımlanır. Üretilen çıkış değeri dışarıya veya buradan başka bir hücreye gönderilir. Bir sinir hücresi kendi çıkışını tekrardan kendisine giriş olarak da gönderme yapabilir. Gerçekte bir yapay sinir hücresinin tek bir çıkışı bulunmaktadır. Aynı değer birden fazla işlem elemanına giriş olarak gidebilmektedir.

Her bir yapay sinir hücresinde (düğümde) sadece bir çıkış işaretine izin verilir. Verilen bu işaret diğer yüzlerce sinir hücresinin girişi olabilir. Bu durum biyolojik sinir olaylarına benzemektedir. Biyolojik sinir yapısında da birçok giriş varken sadece bir çıkış etkinliği vardır. Bulunan düğüm çıkışı aktivasyon fonksiyonunun sonucuna eşdeğer sonuç verir.

#### Öğrenme algoritmaları

Bu çalışmada geriye beslemeli algoritma kullanılmıştır. Bu algoritma, doğru çözüme yaklaşımı hızlandırmak amacı ile en çok kullanılan algoritmalarından biridir (Kışı, 2004). YSA modelinin uygulanması amacı ile istenilen girdi, çıktı ve eğitim sınırlarına göre MATLAB yazılım dilinde bir alt program yazılarak günlük buharlaşma miktarı tahmini yapılmaya çalışılmıştır.

Literatürde birçok öğrenme algoritması bulunmaktadır. Bunlar içerisinde en genel algoritmalarından olan geri yayımlı öğrenme algoritması ve tez çalışmasında kullanılan, Levenberg-Marquardt öğrenme algoritması açıklanacaktır. En genel olarak kullanılan

algoritma danışmanlı öğrenmede kullanılan geri yayılım algoritmasıdır. Sebebi ise basit olması ve iyi bir öğrenme kapasitesine sahip olmasıdır. Bu özelliği onu birçok alana uygulanmasını sağlamıştır.

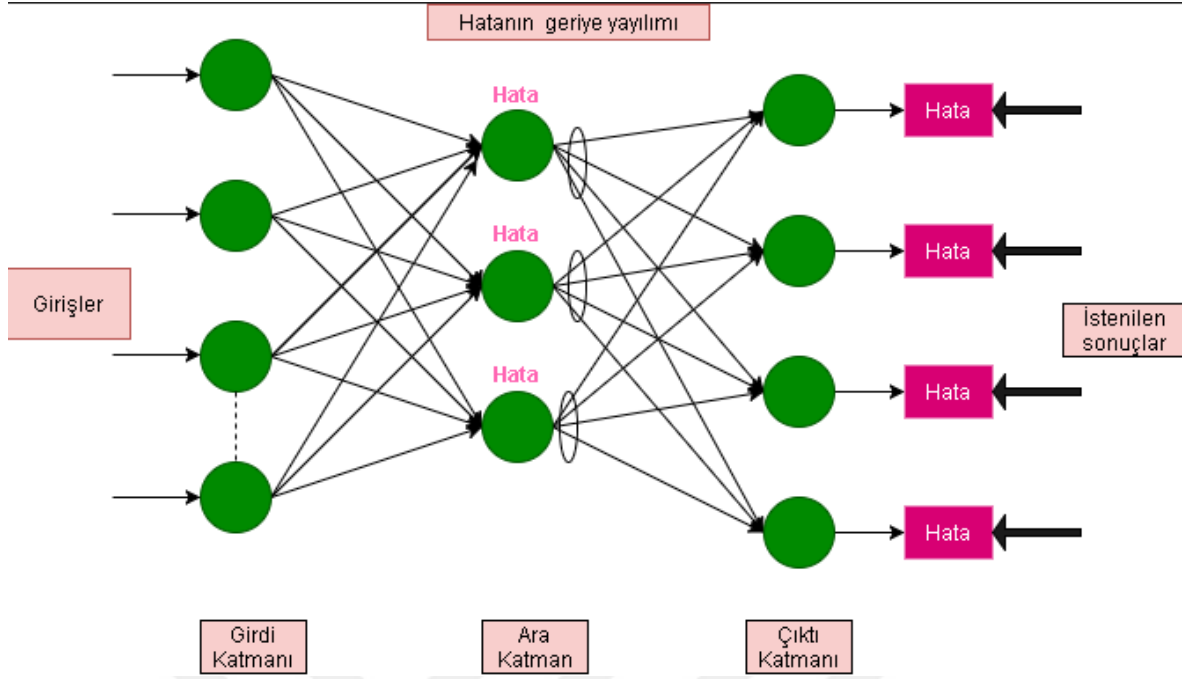
### Geri yayılım öğrenme algoritması

Geri yayılım ile öğrenen ağlar giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşmaktadırlar. Bu ağlar hiyerarşik yapıdadırlar. Bu katmanlardan gizli katman ve gizli katmandaki düğüm sayısı değiştirilebilir. Düğüm sayısı ile hatırlama yeteneği arasında ters orantı vardır. Düğüm sayısının artması ağın hatırlama yeteneğini artırmaktadır, fakat birlikte öğrenme işleminin süresini uzatmaktadır. Düğüm sayısının azaltılması ise eğitim süresini kısaltmakta fakat hatırlama yeteneğini azaltmaktadır.

Giriş katmanındaki düğümlerin her biri gizli katmandaki her bir düğüme, gizli katman birden fazla düğüm var ise bu katmandaki her bir düğüm kendisinden sonraki katmandaki her düğüme ve gizli katman çıkışındaki her düğüm çıkış katmanındaki her düğüme bağlıdır. Bir katmanda bulunan hiçbir düğüm kendi katmanındaki diğer bir düğüme bağlı olamaz. Her katmanın çıkış değerleri bir sonraki katmanın giriş değerlerine denk gelir. Bu şekilde giriş değerlerinin ağın girişinden çıkışına doğru sürekli ilerlemesine **ileri besleme** adı verilir. Geri yayılım ağında hatalar, ileri besleme aktarım fonksiyonunun türevi tarafından, ileri besleme mekanizması içinde kullanılan aynı bağlantılar aracılığıyla, geriye doğru yayılmaktadır (Daldal, 2013).

Geri yayılım öğrenme yöntemi, türevi alınabilir aktivasyon fonksiyonlarını çok katmanlı herhangi bir ağa uygulayabilir. Bu işlem sistem hatasını veya maliyet işlevini azaltma esasına dayanan bir optimizasyon işlemidir. Bu yöntem içerisinde ağırlık ayarlamaları yapıldığı için 'geri yayılım' ismi kullanılmıştır. Giriş örnekleri öğrenme aşamasında, ağa belirli bir sıra verilerek sunulur. Her bir çalışma örneği çıktı (çıkış) örneği hesaplanıncaya dek katmanlar boyu ileri yayılır. Hesaplanan çıktı daha sonra olması beklenen sonuçla karşılaştırılıp aradaki fark 'hata' olarak kabul edilir. Bulunan hatalar, katman katman sinaptik ayarlamaların yapıldığı geri besleme bağlantılarındaki 'girişler' olarak kullanılır. Geriye doğru olan bağlantılar sadece 'öğrenme fazı' için kullanılırken, ileri doğru olan bağlantılar hem öğrenme amacıyla hem de işlemsel fazlar için kullanılır (Daldal, 2013).

Şekil 3.17'de da geri yayılım çalışması için değiştirilmiş birçok katmanı bulunan ileri beslemeli ağı gösterilmiştir.



Şekil 3.17. Genel bir geri yayılım ağ yapısı

Bir YSA modelinde  $N$  tane (girdi parametre verisi) girdi verisi vardır. Bu verilerin her biri girdi değerlerinin bir kümesine sahiptir. Buna  $X_i$  dersek;  $X_i = (i=1,2,3,\dots,k)$  kadar ve çıktı düğümlerinde  $J_n$ , ( $n= 1, 2, 3,\dots, m$ ) kadar çıktı değeri vardır. Bu girdi değerleri gizli tabakalardaki  $W_{ij}$  ( $j=1,2,3,\dots,h$ ) ile çarpılır ve çıkan değerler düzenlenerek gizli tabakaların girdi değerleri olarak kullanılır.

$$H_j = \sum_{i=1}^k W_{ij} \cdot X_i \quad (3.11)$$

$H_j$  : (j)inci gizli tabakadaki girdi değerleridir.

$W_{ij}$  : (i)inci nöronun (j) inci nörona bağlantı, ağırlık katsayılarıdır.

Her bir gizli tabaka bir gizli tabaka, çıktısı üretmek için sigmoid fonksiyonu (veya diğer fonksiyon) ile dönüştürülür veya işleme tabii tutulur.  $H_{Oj}$  olarak gösterilen çıktılar elde edilir.

$$H_{Oj} = f(H_j) = \frac{1}{1 + \exp[-(H_j + \theta_j)]} \quad (3.12)$$

$H_j$  : Dügüm noktalarındaki girdi deęerleri

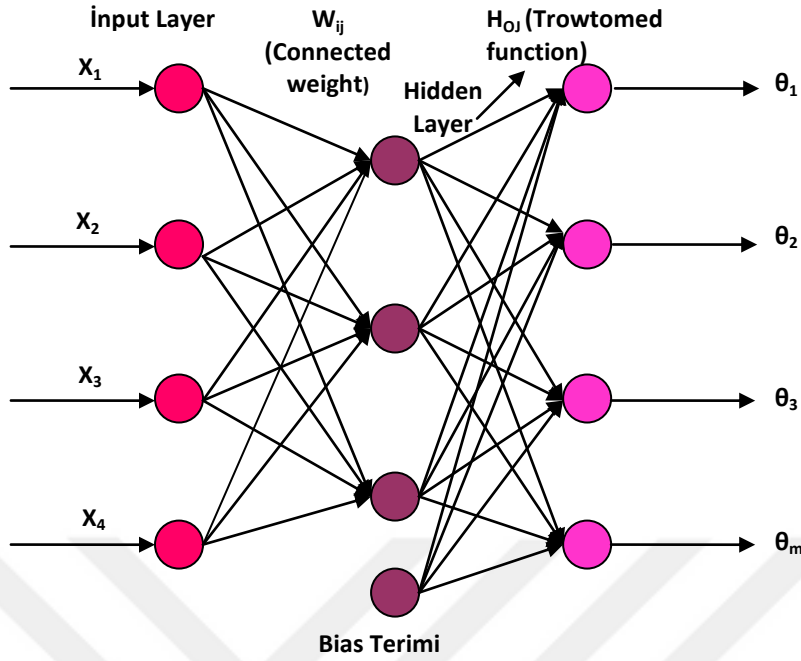
$f(H_j)$  : Çıktı düğüm noktası deęeri

$\theta_j$  : Bir başlangıç veya Bias terimi olarak alınabilir.

Threshold (başlangıç) fonksiyonu,  $(\theta_j)$  ağırlık katsayılarının eğitilmesine bir deęer (genelde 1 alınır) olarak etkitilebilir.  $H_{Oj}$  çıktı deęerleri ardışık tabakalarda girdi olarak da görev yapabilir. Birden fazla gizli tabaka alınması durumunda bu işlem çıktı tabakasına varıncaya kadar devam eder. Yani kaç tane ara tabaka var ise her ara tabakanın çıktısı sonrakinin girdisi (inputu) olarak alınır ve bu işlem çıktı tabakasına kadar devam eder. Bu işlemin tümüne ileri doğru hareket akışı denir. Eğer n tane çıktı düğümü için girdi olarak  $I_{On}$  alınırsa aşağıdaki gibi ifade edebiliriz.

$$\theta_n = \sum_{j=1}^k W_{jn} \cdot H_{jn} \quad (n = 1,2,3,\dots, m) \quad (3.13)$$

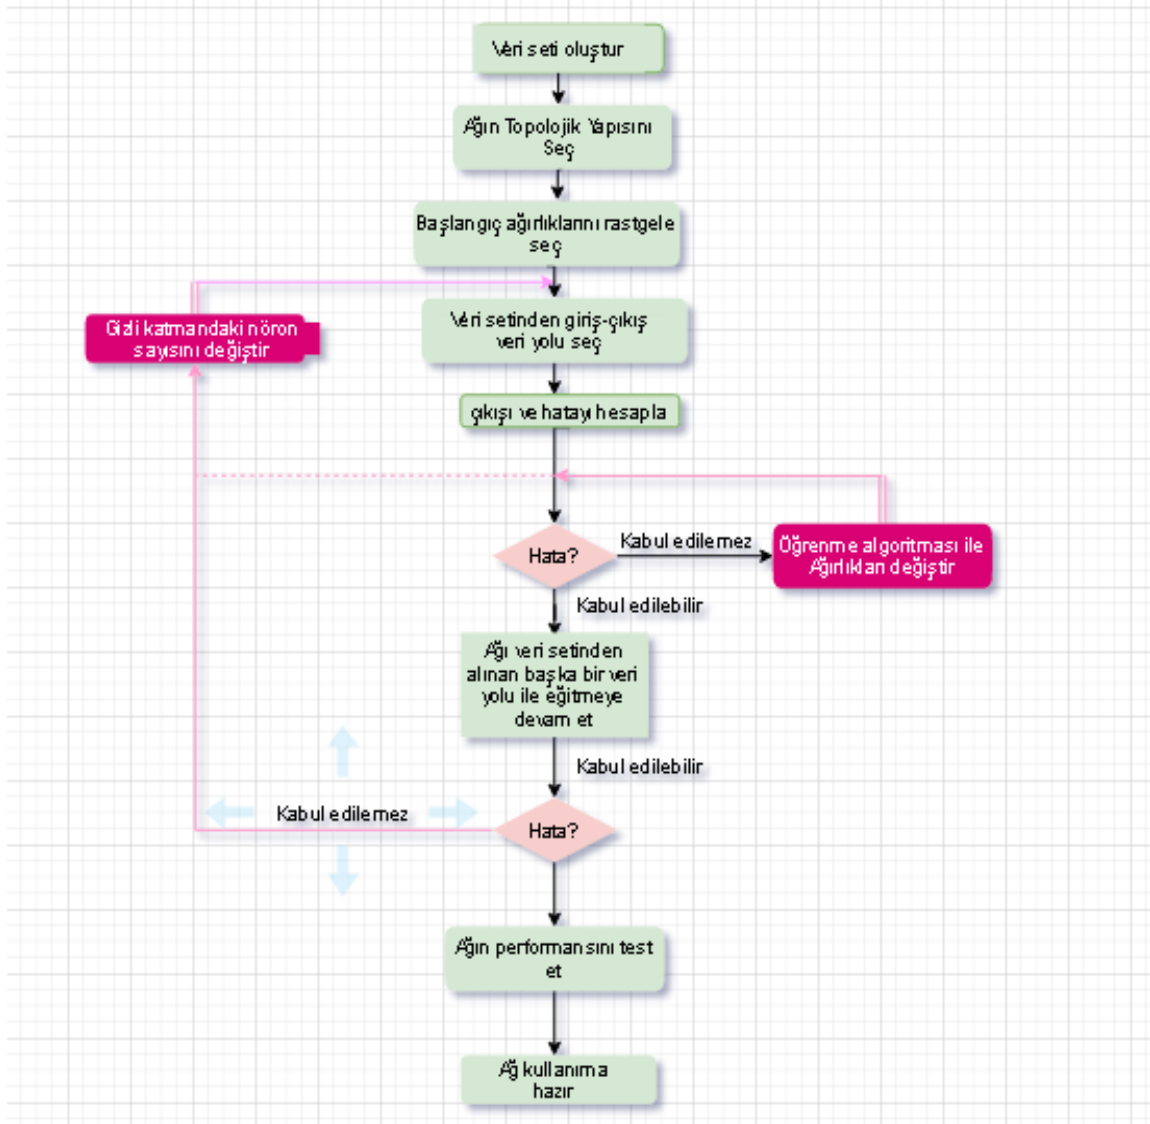
Bütün girdi deęerleri aktivasyon fonksiyonu ile yeniden tanımlanarak  $(O_n)$  sinir ağıının çıktı deęerleri belirlenir Şekil 3.18'de çok tabakalı algılayıcının genel formu verilmiştir Yakınsak çözüm için ardışık olarak iterasyonlar boyunca ağırlıkların deęiştirilmesi (hataların geriye yayılması) veya eğitime işlemlerinin geriye yayılması öğrenme algoritması ile başarılmaktadır. Çıktı tabakasındaki  $(O_n)$  deęerleri hedeflenen deęerler ile (elimizdeki bulmayı amaçladığımız ölçüm veya model sonuçları) aynı olmayacaktır. Belirli bir miktar hata içerecektir.



Şekil 3.18. Çok tabakalı algılayıcı (perceptron)

Geri yayımlı öğrenme kullanıldığında, gizli katmanın ağırlıkları sonraki katmanların hataları kullanılarak ayarlanır. Böylece çıkış katmanında hesaplanan hatalar son gizli katman ile çıkış katmanı arasındaki ağırlıklar ayarlanır. Aynı biçimde, bu işlem döngüsü ilk gizli katmana kadar tekrarlanır. Bu yolla hatalar katman katman ilgili katmanın ağırlık düzeltmeleri yapılarak geriye doğru yayılır. Tamamlanan çalışma süresi içinde 'toplam hata' en aza indirilinceye kadar bu işlemler devam eder. Şekil 3.19' da ileri beslemeli çok katmanlı bir ağ için geri yayılım öğrenme algoritmasının akış şeması gösterilmiştir.





Şekil 3.19. İleri beslemeli bir ağ için geri yayılım akış şeması

### Öğrenme oranı ( $Learning\ rate\ 0 \leq \eta \leq 1$ )

Öğrenme oranı  $\{0-1\}$  arasında belirlenir. Küçük bir öğrenme oranı “ $\eta$ ” için, bir iterasyondan diğerine çalışma ağındaki, iletişim ağırlık çarpanının ( $W_{ij}$ ) değişimi daha küçük olacaktır. Yani daha küçük “ $\eta$ ” değeriyle daha yavaş bir öğrenmenin oluşmasına sebep olacaktır. Diğer taraftan çok yüksek bir “ $\eta$ ” değeri seçildiğinde daha hızlı bir öğrenmenin oluşmasına sebep olur ve YSA modeliyle oluşan çalışma ağı, birbirine yakın bir sonuç vermeyebilir.

Momentum oranı katsayısı “ $\alpha$ ” (Momentum rate  $0 \leq \alpha \leq 1$ )

Momentum katsayısı olaya dâhil edilerek yakınsak (stable) ve doğru sonuca daha yakın bir değer elde edebiliriz. Momentum oranı, grafiklerin veya verilerin dönüm noktalarındaki hata yüzeylerinde modelin öğrenme işlemini sonlandırmasını önleyebilir. Yani momentum oranının en düşük olduğu zamanda YSA'nın iterasyona son vermesini önler.

Bir sonraki iterasyonda yayılacak hata miktarı aşağıdaki denklem (3.14) 'te verilmiştir.

$$\Delta W_{ji}(r) = \eta \cdot \delta_i \cdot X_j + \alpha \Delta W_{ji}(r-1) \quad (3.14)$$

Bu çalışmada YSA modelinin uygulanması amacı ile istenilen girdi, çıktı ve eğitim sınırlarına göre MATLAB yazılım dilinde bir alt program yazılarak günlük buharlaşma miktarı tahmini yapılmıştır. Levenberg-Marquardt geriye beslemeli algoritma kullanılmıştır.

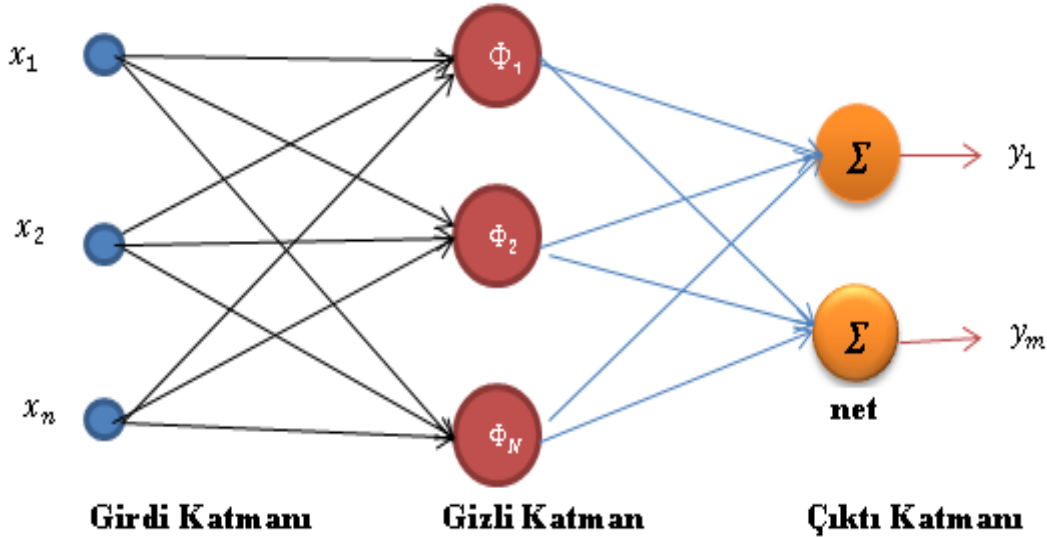
### 3.2.3. Radyal tabanlı yapay sinir ağları metodu (RTYSA)

Radyal Tabanlı Yapay Sinir Ağları (RTYSA), insan sinir sistemindeki nöronlarda görülen yerel etki tepki davranışlarından yola çıkılarak ilk olarak 1988 yılında geliştirilmiş ve filtreleme problemine uygulanarak YSA yöntemlerinden biri olarak literatüre girmiştir. Radyal tabanlı yapay sinir ağları (Radial Basis Neural Networks-RBNN), çok boyutlu uzayda eğri uydurma yaklaşımıdır. RTYSA modellerinin eğitimini çok boyutlu uzayda eğri uydurma yaklaşımı olarak görmek mümkündür. Bu nedenle RTYSA modelinin eğitim performansı, çıktı vektör uzayındaki verilere en uygun yüzeyi bulma ve dolayısıyla bir interpolasyon problemine dönüşmektedir. RTYSA modelleri genel olarak YSA yapısına benzer şekilde giriş katman, gizli katmanı ve çıktı katmanı olmak üzere 3 katman halinde gösterilmektedir (Şekil 3.20.). Gizli katmandaki nöronlarda genellikle aktivasyon fonksiyonu olarak radyal taban fonksiyonları ve bunların içinden doğrusal olmayan yapıya sahip Gauss Fonksiyonu kullanılır. Gizli katman, gizli düğümler denilen bilgi işlem birimleri dizilerinden oluşur. Her gizli düğüm,  $x$  giriş vektörü ile aynı boyutta olan bir parametre vektörü olan  $c$  merkez vektörünü bulunur. Bu vektörler arasındaki Öklid uzaklığı  $\|x - c_k\|$  ile tanımlanmaktadır. RTYSA modellerinde ağıın ürettiği çıktı ( $y$ ) değeri ise denklem 3.15' de görüldüğü gibi hesaplanabilmektedir.

$$\Phi_k(x) = \exp \left[ \frac{-\|x - c_k\|^2}{2\sigma_k^2} \right] \quad (3.15)$$

$$y_i = \sum_{k=1}^N w_{ik} \Phi_k(x, c_k) = \sum_{k=1}^N w_{ik} \Phi_k(\|x - c_k\|_2), i = 1, 2, 3, \dots, m \quad (3.16)$$

Burada  $x \in R^{n \times 1}$  ağı'n girdi vektörünü,  $\Phi_k(\cdot) \in R^+$  radyal tabanlı aktivasyon fonksiyonunu,  $c_k \in R^{n \times 1}$  girdi vektör uzayının bir alt setinden seçilen radyal tabanlı merkezleri,  $\|\cdot\|_2$  girdi vektörünün merkezden ne kadar uzak olduğunun bir ölçütü olan Öklidyen normunu,  $w_{ik}$  çıktı katmanındaki ağırlıkları,  $N$  ise gizli katmanda bulunan hücre sayısını ifade etmektedir.



Şekil 3.20. RTYSA'nın yapısı

RTYSA'nın başlıca özellikleri şunlardır:

1. Bunlar iki katmanlı ileri besleme ağlarıdır. Gizli düğümler radyal temel fonksiyonlarının bir setini uygular.
2. Çıktı düğümleri doğrusal toplam fonksiyonlarını uygularlar.
3. Ağ eğitimi iki aşamaya ayrılmıştır: önce girişten gizli katmana olan ağırlıklar belirlenir ve daha sonra gizli katmanlardan çıktı katmanına olan ağırlıklar belirlenir.
4. Eğitim / öğrenme çok hızlıdır.
5. Ağlar enterpolasyonda çok iyidir.

### 3.2.4. Zaman serileri analizi (ZSA)

Box-Jenkins tekniği; zaman serilerinde bir analiz ve tahmin yöntemi olan kesikli, doğrusal ve stokastik süreçlere dayanır. Box-Jenkins tahmin modelleri; Otoregresif (Auto Regressive-AR), Hareketli Ortalama (Moving Average - MA), Otoregresif - Hareketli Ortalama (Autoregressive-Moving Average - ARMA) ve Bütünlenen Otoregresif-Hareketli Ortalama (Autoregressive Integrated Moving Average - ARIMA) modelleridir. AR(p), MA(q) ve bunların birleşimi olan ARMA(p,q) modelleri durağan(stasyonier) süreçlere uygulanırken, ARIMA(p,d,q) modelleri durağan olmayan süreçler için kullanılmaktadır. Bu tez çalışmasında sadece AR(p) modelleri kullanılmıştır.

#### Otoregresif model AR(p)

Günlük buharlaşma miktarı serilerinin eğilim ya da sıçrama bileşeni bulunmadığı zamanlarda stasyonier (durağan) oldukları kabul görülebilir. Fakat zaman aralığı daha küçük alınırsa (mevsim, ay, hafta, gün) akım serileri stasyonier olmayacaktır. Stasyonier olmayan serilerin incelenmesi zor olduğundan, bunlar uygun bir dönüşümle stasyonier hale getirilmeye çalışılır.

Rasgele bir değişkenin aldığı değerlerin belirli bir zaman içerisinde aralıklarla ( $\Delta t$ ) izlenmesi halinde bir zaman serisi ( $X_1, X_2, \dots, X_i, \dots$ ) oluşur. Ardışık zamanlardaki  $X_i$  ve  $X_{i+1}$  değerleri arasında istatistik anlamda bir bağımlılık bulunması halinde  $X_i$  bir stokastik sürece dönüşür. AR(p) modelinde  $Y_t$  değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamının ve rassal (değeri bir deney sonucunda belirlenen değişken) hata teriminin doğrusal fonksiyonudur. AR(p) modelleri genel olarak aşağıdaki denklem (3.17)'de ki gibi gösterilir:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + \alpha_t \quad (3.17)$$

Burada  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  geçmiş gözlem değerlerini,  $\Phi_1, \Phi_2, \dots, \Phi_p$  geçmiş gözlem değerleri için katsayıları,  $\delta$  bir sabit değer,  $\alpha_t$  ise hata terimini ifade eder.

Burada i-inci günün buharlaşma miktarının bundan önceki p günün buharlaşma miktarıyla doğrudan doğruya bağımlı olduğu görülmektedir. Bu çalışmada MATLAB yazılımı kullanılarak günlük buharlaşma miktarı verilerine 1. Ve 3. mertebeden otoregresif model

uygulanmıştır. AR(1) modelinde girdi olarak 1 günlük zaman ötelemesi[  $E_{T-1}$ , mm],çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır

AR(3) modelinde girdi olarak 1 günlük zaman ötelemesi[  $E_{T-1}$ , mm], 2 günlük zaman ötelemesi[  $E_{T-2}$ , mm], 3 günlük zaman ötelemesi[  $E_{T-3}$ , mm],çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır. AR(1) ve AR(3) model sonuçları elde edilmiştir.

İnşaat Mühendisliğinde zaman serilerine özellikle hidrolojik uygulamalarda rastlanmaktadır. Bu bölümde günlük buharlaşma miktarı tahmini zaman serilerinin istatistik analizinde kullanılan metotlar tanıtılacaktır

### 3.2.5. Çoklu doğrusal regresyon (ÇDR)

Bir tane bağımlı değişken ile bununla ilişkisi olan bir dizi bağımsız değişken arasındaki ilişkiyi ortaya koymak için yapılan analizdir Çoklu Doğrusal Regresyon (ÇDR) yöntemi, bir bağımlı değişkenin ne kadar etkilendiğini ve etkilendiği, ilişkilendirildiği bağımsız değişkenlerin değerini bulmak amacıyla kullanılan bir yöntemdir.

ÇDR yöntemi genel olarak aşağıdaki denklem (3.18)'de ki gibi gösterilir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_j + \dots + \beta_p x_p + \varepsilon \quad (3.18)$$

Çoklu regresyon analizinde, y bağımlı değişkeni,  $x_1, x_2, \dots, x_p$  bağımsız değişkenleri arasındaki ilişkiyi gösterir Bu denklemdeki  $\beta_0, \beta_1, \beta_2, \beta_j, \dots, \beta_p$  regresyon katsayılarını ifade eder.  $x_j$  değişkenindeki bir birim değişikliğin sebebi herhangi bir  $\beta_j$  regresyon katsayısı, y değişkeninde beklenen değişime karşı, diğer değişkenlerin sabit tutulmasıyla oluşur.  $\beta_0$ 'a ise kesim noktası veya sabit denir ve tüm  $x_j$  değişken değerleri sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir.  $\varepsilon$  İse hata terimidir (Jüttner, 2003).

## 4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu bölümde, . FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini ( $ET_0$ ) yapılmış, Penman Monteith metodu referans olarak kabul edilerek bulunan buharlaşma tahmini sonuçları ile. Hargreaves-Samani, ve Turc denklemleri gibi ampirik (geleneksel) yöntemler ile Yapay Sinir Ağları (YSA) yöntemi, Radyal Tabanlı Yapay Sinir ağları (RTYSA), Çoklu Doğrusal Regresyon (ÇDR) yöntemi ve Oto-regresif AR(p) modelin performansları karşılaştırılarak buharlaşma miktarı sonuçları incelenmiştir. Çalışmada kullanılan modellerin karşılaştırılmasında kullanılan istatistiksel parametreler hakkında bilgi verilecek olup, diğer kısımlarda modellere ait sonuçların grafiksel gösterimi ve yorumlanması yapılacaktır.

### 4.1. Model Performansında Kullanılan İstatistiksel Parametreler

Model sonuçlarının değerlendirilmesinde determinasyon katsayısı ( $R^2$ ), ortalama karesel hataların karekökü (KKOH) ve mutlak ortalama hata (MOH) hesaplanmıştır.

Determinasyon katsayısı ( $R^2$ ), x ve y ikili değerleri arasındaki doğrusal bağıntının gücünü ölçer. Sonuçların 0 ile 1 arasında çıkması beklenir. . Bu durumda 1'e en yakın değer için yapılacak olan yorumlama en mantıklı ve uygun olanıdır. . ( $R^2$ ), 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.

$$(R^2) = \left( \frac{n\sum xy - (\sum x)(\sum y)}{\sqrt{(n\sum x^2) - (\sum x)^2} \sqrt{(n\sum y^2) - (\sum y)^2}} \right) \quad (4.1)$$

KKOH ve MOH, hataların ihtimallerini teşhis etmek için kullanılır. KKOH ve MOH sıfırdan sonsuza kadar gidebilir. Daha düşük değerler daha kullanışlı olduğu anlamına gelir.

MOH tahmin edilen değer ile gerçek değer arasındaki farkı dikkate almadan hataların ortalama büyüklüğünü ölçer. Hata oranları birim olarak ifade edilmektedir. Sıfırdan sonsuza kadar değer alabilir.

KKOH bir regresyon çizgisinin ne kadar yakın bir noktaya geldiğini ifade eder. Karelerinin ortalaması ne kadar küçük ise program gerçek veriye o kadar yakındır. Bunu noktalar arasındaki mesafeleri regresyon çizgisine alarak ve kareler oluşturularak yapar.

$$\mathbf{MOH} = \frac{1}{N} \sum_{i=1}^N |ET_{ölçüm} - ET_{tahmin}| \quad (4.2)$$

$$\mathbf{KKOH} = \sqrt{\frac{1}{N} \sum_{i=1}^N (ET_{ölçüm} - ET_{tahmin})^2} \quad (4.3)$$

Burada, n veri sayılarını ve ET günlük buharlaşma miktarını (mm), ifade etmektedir.

Sonuçlar, tahmin ve performans açısından karşılaştırmak için kullanılacaktır.


## 4.2. Model Sonuçları

Çalışmada FAO (Food and Agriculture Organization) tarafından standart metot olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini yapılmış ( $ET_0$ ), Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiştir. Hargreaves-Samani, ve Turc denklemleri gibi ampirik (geleneksel) yöntemler ile Yapay Sinir Ağları (YSA) yöntemi, Radyal Tabanlı Yapay Sinir ağları (RTYSA), Çoklu Lineer Regresyon (ÇLR) yöntemi ve Oto-regresif modelin AR(p) performansları karşılaştırılarak buharlaşma miktarı tahmin edilmeye çalışılmıştır. YSA optimizasyonu için geriye yayılma ilkesine göre çalışan ileri beslemeli (feedforward-back-propagation) YSA modeli kullanılmıştır. Bu modellere ait sonuçlar aşağıda verilmiştir.

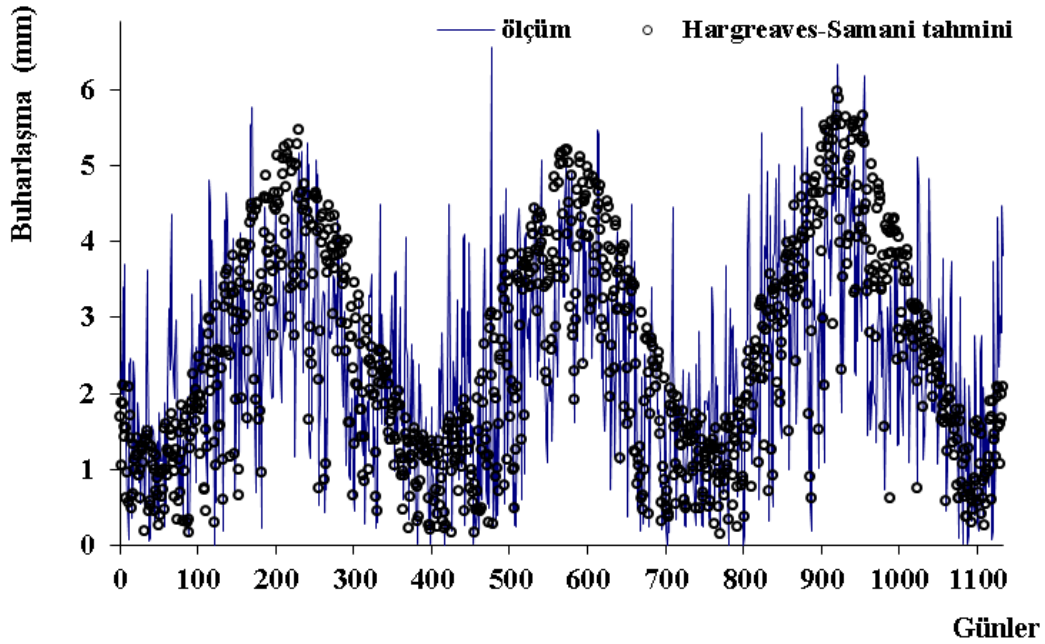
### 4.2.1. Hargreaves-Samani model sonuçları

Hargreaves-Samani modeli için 2013-2017 yıllarına ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133, test için ise geriye kalan 283 günlük ölçüm verisi kullanılmıştır.

Hargreaves-Samani modelinde girdi parametresi olarak günlük maksimum sıcaklık [ $T_{max}$ , °C], günlük minimum sıcaklık [ $T_{min}$ , °C], günlük ortalama sıcaklık [ $T_{mean}$ , °C], günlük güneşlenme miktarı [ $R_s$ , MJ  $m^{-2}gün^{-1}$ ], ölçümleri kullanılarak, günlük buharlaşma miktarı tahmin [ET, mm] edilmiştir. Şekil 4.1 ve 4.2'de Hargreaves-Samani modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir




Şekil 4.1. Günlük buharlaşma miktarı eğitim verileri için Hargreaves-Samani yöntemine ait saçılım grafiği



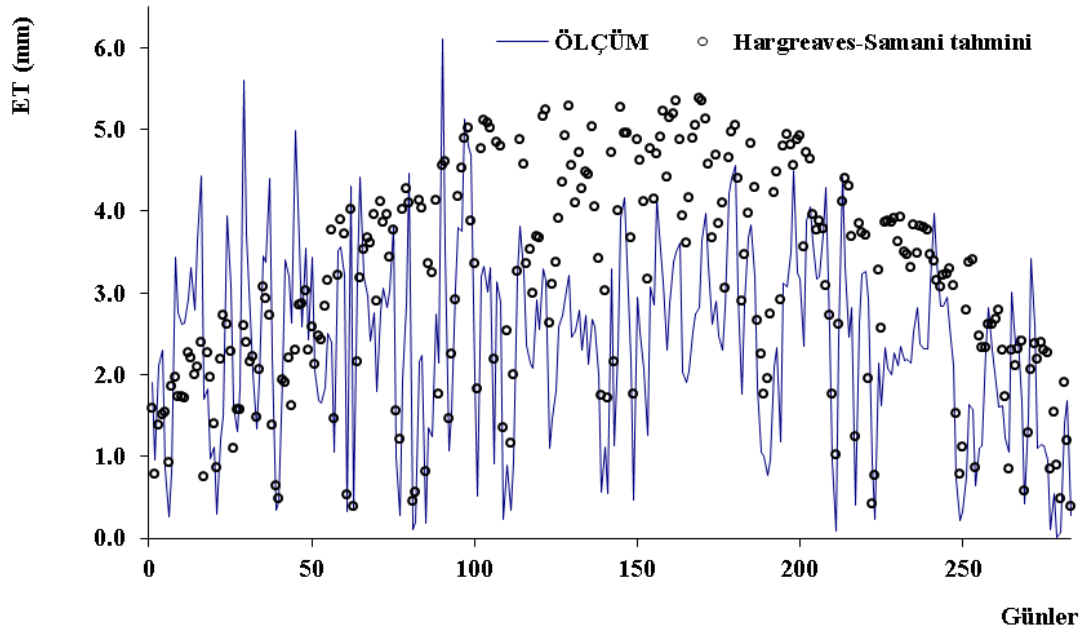
Şekil 4.2. Günlük buharlaşma miktarı eğitim verileri için Hargreaves-Samani yöntemine ait ölçüm ve dağılım grafiği



Şekil 4.1 ve Şekil 4.2 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,5947 olduğu tespit edilmiştir. Hargreaves-Samani modeli eğitim verilerinin analizi ile elde edilen, Hargreaves-Samani modeli test verileri dağılım ve saçılım grafikleri Şekil 4.3 ve Şekil 4.4'te verilmiştir



Şekil 4.3. Günlük buharlaşma miktarı test verileri için Hargreaves-Samani yöntemine ait saçılım grafiği




Şekil 4.4. Günlük buharlaşma miktarı test verileri için Hargreaves-Samani yöntemine ait ölçüm ve dağılım grafiği

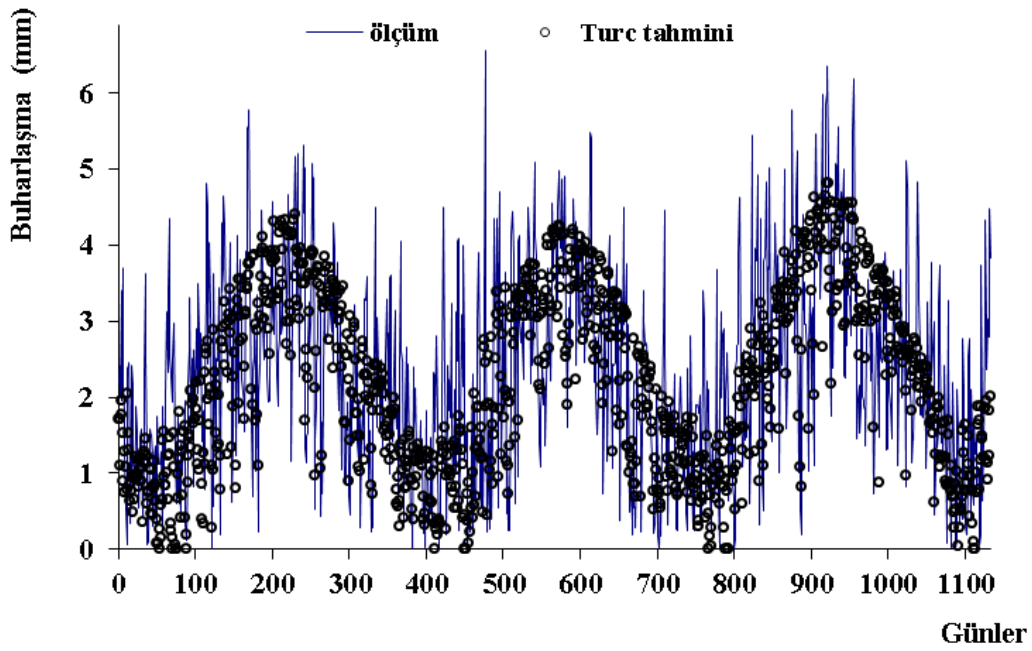
Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,4704 olarak elde edilmiştir.

#### 4.2.2. Turc model sonuçları

Turc modeli için 2013-2017 yıllarına ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi kullanılmıştır. Hargreaves-Samani modelinde girdi parametresi olarak günlük ortalama sıcaklık [ $T_{mean}, ^\circ\text{C}$ ], günlük güneşlenme miktarı [ $R_s, \text{MJ m}^{-2}\text{gün}^{-1}$ ], bağıl nem [RH, %] ifadeleri kullanılarak, günlük buharlaşma miktarı tahmini [ET, mm] yapılmıştır. Şekil 4.5 ve 4.6'da Turc modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.5. Günlük buharlaşma miktarı eğitim verileri için Turc yöntemine ait saçılım grafiği




Şekil 4.6. Günlük buharlaşma miktarı eğitim verileri için Turc yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.5 ve Şekil 4.6 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,5246 olduğu tespit edilmiştir. Turc modeli eğitim verilerinin analizi ile elde edilen, Turc modeli test verileri dağılım ve saçılım grafikleri Şekil 4.7 ve Şekil 4.8’de verilmiştir.



Şekil 4.7. Günlük buharlaşma miktarı test verileri için Turc yöntemine ait saçılım grafiği



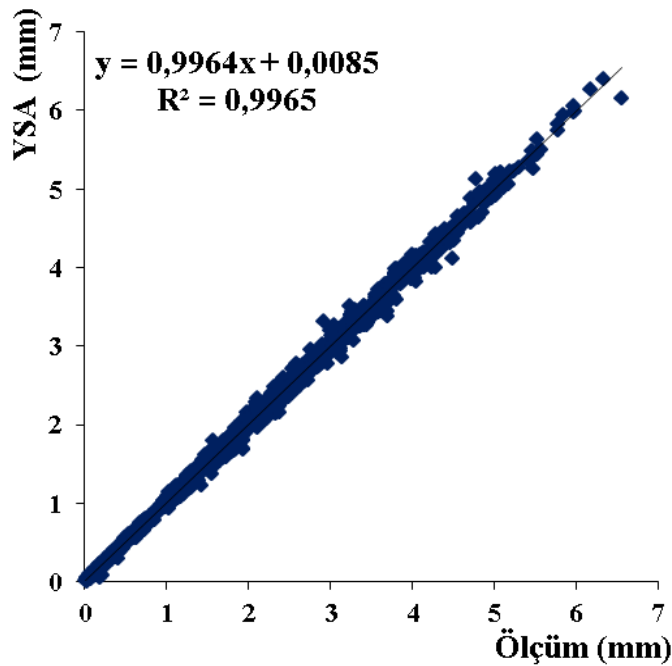
Şekil 4.8. Günlük buharlaşma miktarı test verileri için Turc yöntemine ait ölçüm ve dağılım grafiği

Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı(  $R^2$ ) 0,3757 olarak elde edilmiştir.


#### 4.2.3. Yapay sinir ağları (YSA) model sonuçları

Yapay Sinir Ağları (YSA) modeli için bütün modellerde kullanıldığı gibi 2013-2017 yıllarına ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi kullanılmıştır...

Yapay Sinir Ağları (YSA) modelinde girdi olarak günlük ortalama sıcaklık [ $T_{mean}$ , °C], günlük güneşlenme miktarı [ $R_s$ ,  $MJ\ m^{-2}gün^{-1}$ ], bağıl nem [RH, %] ve günlük ortalama rüzgar hızı [u, %] ifadeleri kullanılarak, çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır. Şekil 4.9 ve 4.10'da YSA modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir

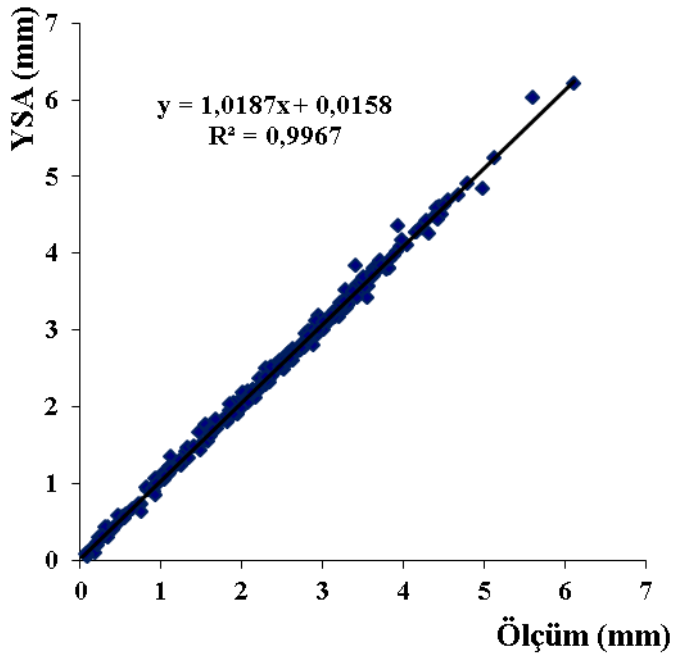


Şekil 4.9. Günlük buharlaşma miktarı eğitim verileri için YSA yöntemine ait saçılım grafiği




Şekil 4.10. Günlük buharlaşma miktarı eğitim verileri için YSA yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.9 ve Şekil 4.10 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,9965 olduğu tespit edilmiştir. YSA modeli eğitim verilerinin analizi ile elde edilen, YSA modeli test verileri dağılım ve saçılım grafikleri Şekil 4.11 ve Şekil 4.12'de verilmiştir



Şekil 4.11. Günlük buharlaşma miktarı test verileri için YSA yöntemine ait saçılım grafiği




Şekil 4.12. Günlük buharlaşma miktarı test verileri için YSA yöntemine ait ölçüm ve dağılım grafiği

Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,9967 olarak elde edilmiştir.


#### 4.2.4 Radyal tabanlı yapay sinir ağları (RTYSA) model sonuçları

Radyal Tabanlı Yapay Sinir Ağları (RTYSA) modeli için 2013-2017 yıllarına ait ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi kullanılmıştır...

Radyal Tabanlı Yapay Sinir Ağları (RTYSA) modelinde girdi olarak günlük ortalama sıcaklık [ $T_{mean}$ , °C], günlük güneşlenme miktarı [ $R_s$ ,  $MJ m^{-2} gün^{-1}$ ], bağıl nem [RH, %] ve günlük ortalama rüzgar hızı [ $u$ , %] ifadeleri kullanılarak, çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır. Şekil 4.13 ve 4.14'te günlük buharlaşma miktarı RTYSA modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.



Şekil 4.13. Günlük buharlaşma miktarı eğitim verileri için RTYSA yöntemine ait saçılım grafiği




Şekil 4.14. Günlük buharlaşma miktarı eğitim verileri için RTYSA yöntemine ait ölçüm ve dağılım grafiği

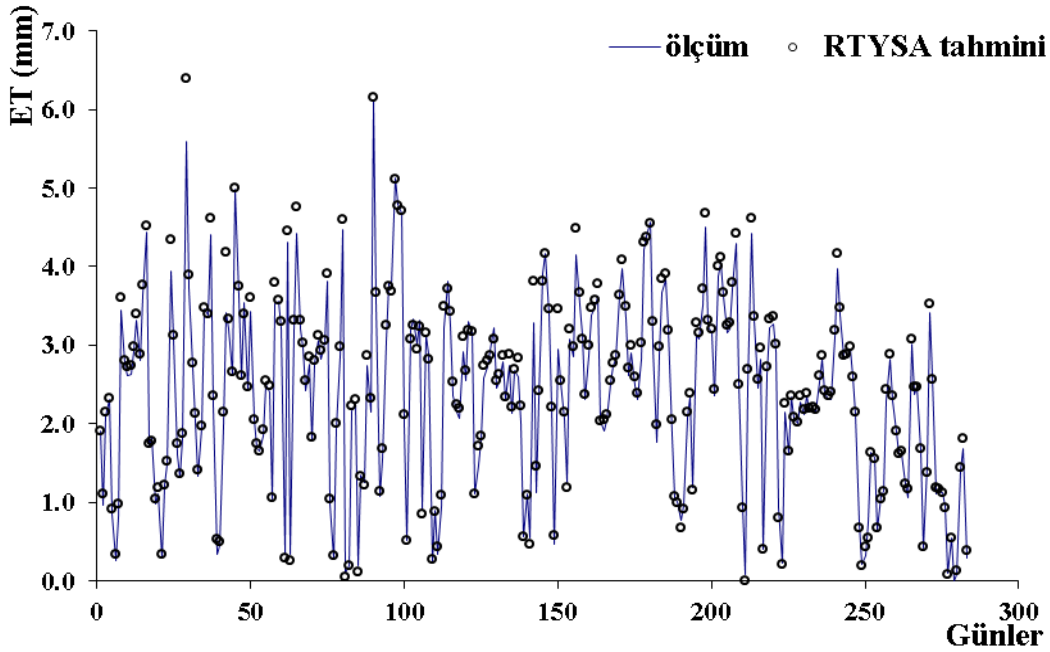
Şekil 4.13 ve Şekil 4.14 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,9936 olduğu tespit edilmiştir. RTYSA modeli eğitim verilerinin



analizi ile elde edilen, RTYSA modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.15 ve Şekil 4.16'da verilmiştir.



Şekil 4.15. Günlük buharlaşma miktarı test verileri için RTYSA yöntemine ait saçılım grafiği



Şekil 4.16. Günlük buharlaşma miktarı test verileri için RTYSA yöntemine ait ölçüm ve dağılım grafiği

Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,9922 olarak elde edilmiştir.


#### 4.2.5 AR(1) ve AR(3) model sonuçları

Bu çalışmada MATLAB yazılımı kullanılarak günlük buharlaşma miktarı verilerine 1. Ve 3. mertebeden otoregresif model uygulanarak AR(1) ve AR(3) modelleri elde edilmiştir.


AR(1) ve AR(3) modeli için 2013-2017 yıllarına ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi kullanılmıştır.

AR(1) modelinde girdi olarak 1 günlük zaman ötelemesi [ $E_{T-1}$ , mm], çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır

AR(3) modelinde girdi olarak 1 günlük zaman ötelemesi [ $E_{T-1}$ , mm], 2 günlük zaman ötelemesi [ $E_{T-2}$ , mm], 3 günlük zaman ötelemesi [ $E_{T-3}$ , mm], çıktı katmanı olarak ise günlük buharlaşma miktarı [ET, mm] alınmıştır. Şekil 4.17, Şekil 4.18, Şekil 4.19 ve 4.20'de AR(1) ve AR(3) modelleri eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.17. Günlük buharlaşma miktarı eğitim verileri için AR(1) yöntemine ait saçılım grafiği




Şekil 4.18. Günlük buharlaşma miktarı eğitim verileri için AR(1) yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.17 ve Şekil 4.18 eğitim verileri incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,4324 olduğu tespit edilmiştir.




Şekil 4.19. Günlük buharlaşma miktarı eğitim verileri için AR(3) yöntemine ait saçılım grafiği




Şekil 4.20. Günlük buharlaşma miktarı eğitim verileri için AR(3) yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.19 ve Şekil 4.20 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) 0,4295 olduğu tespit edilmiştir. AR(1) ve AR(3) modelleri eğitim verilerinin analizi ile elde edilen, AR(1) ve AR(3) modelleri test verileri dağılım ve saçılım grafikleri Şekil 4.21, Şekil 4.22, Şekil 4.23 ve Şekil 4.24'de verilmiştir.

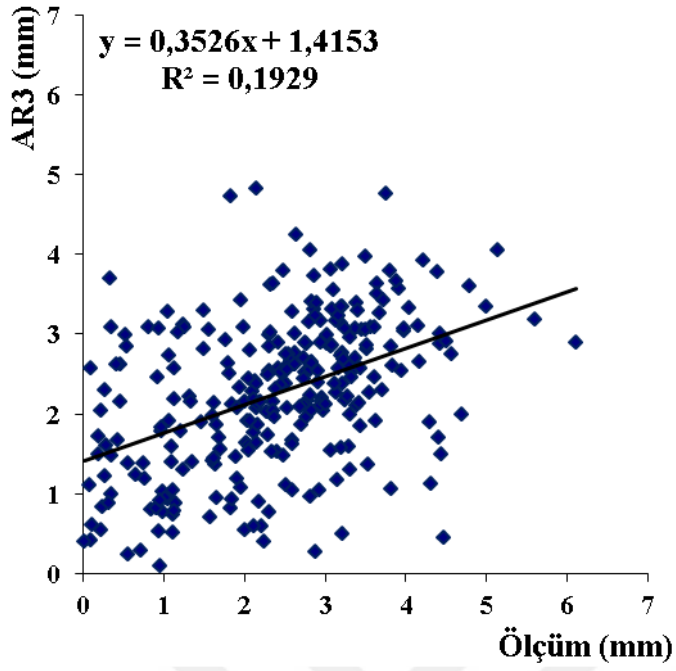


Şekil 4.21. Günlük buharlaşma miktarı test verileri için AR(1) yöntemine ait saçılım grafiği




Şekil 4.22. Günlük buharlaşma miktarı test verileri için AR(1) yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.21 ve Şekil 4.22 incelendiğinde Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,222 olarak elde edilmiştir.



Şekil 4.23. Günlük buharlaşma miktarı test verileri için AR(3) yöntemine ait saçılım grafiği




Şekil 4.24. Günlük buharlaşma miktarı test verileri için AR(3) yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.23 ve Şekil 4.24 incelendiğinde Test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,1929 olarak elde edilmiştir. Bu elde edilen determinasyon değerleri otoregresif modellerin günlük buharlaşma miktarını tahmin edemediğini göstermektedir.


#### 4.2.6 Çoklu doğrusal regresyon (ÇDR) model sonuçları

Çoklu Doğrusal Regresyon (ÇDR) modeli için de diğer yöntemlerde olduğu gibi 2013-2017 yıllarına ait 4 yıllık toplamda 1416 tane günlük meteorolojik veri kullanılmıştır. Çalışmada, tüm verilerin %80'i eğitim; %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi kullanılmıştır...

Çoklu Doğrusal Regresyon (ÇDR) modelinde girdi parametresi olarak günlük ortalama sıcaklık [ $T_{mean}$ , °C], günlük güneşlenme miktarı [ $R_s$ ,  $MJ m^{-2} gün^{-1}$ ], bağıl nem [RH, %] ve günlük ortalama rüzgar hızı [ $u$ , %] ifadeleri kullanılarak, günlük buharlaşma miktarı tahmini [ET, mm] yapılmıştır. Şekil 4.25 ve Şekil 4.26'da günlük buharlaşma miktarı ÇDR modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.25. Günlük buharlaşma miktarı eğitim verileri için ÇDR yöntemine ait saçılım grafiği




Şekil 4.26. Günlük buharlaşma miktarı eğitim verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.25. ve Şekil 4.26 incelendiğinde ölçüm ve model arasındaki determinasyon katsayısının ( $R^2$ ) eğitim verileri için 0,9414 olduğu tespit edilmiştir. ÇDR modeli eğitim verilerinin analizi ile elde edilen, ÇDR modeli test verileri dağılım ve saçılım grafikleri Şekil 4.27 ve Şekil 4.28’de verilmiştir.



Şekil 4.27. Günlük buharlaşma miktarı test verileri için ÇDR yöntemine ait saçılım grafiği





4.28. Günlük buharlařma miktarı test verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiđi

Şekil 4.27 ve Şekil 4.28 incelendiğinde test aşamasında, ölçüm ve model arasındaki determinasyon katsayısı ( $R^2$ ) 0,944 olarak elde edilmiştir. Modellere ait istatistiksel sonuçlar Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Günlük Buharlaştırma Miktarı Tahmininde Kullanılan Model Sonuçlarının Karşılaştırılması

Model İsimleri	Model Girdileri	MOH	KKOH	$R^2$
Hargreaves-Samani (Ampirik)	Tmax, Tmin, Tmean, Rs	1,0614	1,2345	0,4704
Turc (Ampirik)	Tm, RH, Rs	0,8791	1,0421	0,3757
<b>YSA</b>	<b>Tm, RH, Rs, u</b>	<b>0,0712</b>	<b>0,0943</b>	<b>0,9967</b>
<b>RTYSA</b>	<b>Tm, RH, Rs, u</b>	<b>0,0924</b>	<b>0,1338</b>	<b>0,9922</b>
AR (1)	$E_{T-1}$	0,8678	1,1786	0,2220
AR (3)	$E_{T-1}, E_{T-2}, E_{T-3}$	0,8533	1,1450	0,1929
<b>ÇDR</b>	<b>Tm, RH, Rs, u</b>	<b>0,2350</b>	<b>0,3201</b>	<b>0,9440</b>

**KKOH:** Ortalama karesel hataların karekökü, **MOH:** Mutlak ortalama hata  
 **$R^2$  :** Determinasyon katsayısı.

**Tmean, Tm:** günlük ortalama sıcaklık, **Tmax:** günlük maximum sıcaklık ( $^{\circ}\text{C}$ ), **Tmin:** günlük minimum sıcaklık ( $^{\circ}\text{C}$ ), **Rs:** günlük güneşlenme miktarı ( $\text{MJ m}^{-2}\text{gün}^{-1}$ ), **RH:** bağıl nem (%), **u:** günlük ortalama rüzgâr,  **$E_{T-1}$ :** 1 günlük zaman ötelemesi (mm),  **$E_{T-2}$ :** 2 günlük zaman ötelemesi (mm),  **$E_{T-3}$ :** 3 günlük zaman ötelemesi (mm),

Çizelge 4.1’de görüldüğü gibi, Otopregresif Modellerden AR(3) model sonucunda MOH: 0,8533;- KKOH: 1,1450; -  $R^2$ : 0,1929 olarak elde edilmiştir. AR(3) modeli tahminleri tüm modeller içerisinde en düşük performans göstermiştir

Hargreaves-Samani ve Turc yöntemleri kullanılarak buharlaşma miktarı tespit edilmiştir. Bu modeller değerlendirildiğinde Hargreaves-Samani (MOH1,0614; - KKOH: 1,2345; -  $R^2$ : 0,4704) yönteminin Turc yöntemine göre daha iyi performans gösterdiği bulunmuştur.

Yapay zekâ tekniklerinin en çok kullanılanlarından olan, YSA(Yapay Sinir Ağı) ve RTYSA( Radyal Tabanlı Yapay Sinir Ağı) modelleri kullanılmıştır. Bu modeller değerlendirildiğinde Yapay Sinir Ağı modeli en düşük MOH: 0,0712; - KKOH: 0,0943 ve en yüksek  $R^2$ :0,9967 değerleri ile modelinin diğer modele göre daha iyi performans gösterdiği görülmüştür.

Bu çalışmada, AR(1) (1 gün zaman ötelemeli) ve AR(3) (3 gün zaman ötelemeli) Otoregresif Modeller kullanılmıştır. Bu modeller değerlendirildiğinde AR(1) (MOH0,8678; - KKOH: 1,1786; -  $R^2$ : 0,2220) yönteminin AR(3) yöntemine göre daha iyi performans gösterdiği fakat buharlaşmayı modelleyemediği tespit edilmiştir.

Tüm model sonuçları değerlendirildiğinde YSA modelinin en düşük hata ve en yüksek determinasyon katsayısıyla en iyi performansı göstererek günlük buharlaşma tahmini için en uygun model olduğu tespit edilmiştir.

## 5.SONUÇ ve ÖNERİLER

Bu çalışmada ABD'nin güneydoğusunda bulunan Güney Carolina Eyaletindeki Near Anderson İstasyonuna ait iklim verileri kullanılarak, FAO (Food and Agriculture Organization) tarafından standart metod olarak önerilen Penman-Monteith metoduna göre günlük buharlaşma tahmini( $ET_0$ ), yapılmıştır. Penman Monteith metoduna göre bulunan buharlaşma tahminleri referans olarak kabul edilmiş, Hargreaves-Samani, ve Turc denklemleri gibi ampirik yöntemler ile Yapay Sinir Ağları (YSA), Radyal Tabanlı Yapay Sinir Ağları (RTYSA), Çoklu Doğrusal Regresyon (ÇDR) yöntemleri ve Oto-regresif modelin AR(p) performansları karşılaştırılmıştır.

Ortalama günlük hava sıcaklığı ( $T_{mean}$ ), en yüksek ( $T_{max}$ ) ve en düşük günlük hava sıcaklıkları( $T_{min}$ ), rüzgâr hızı (u), güneşlenme miktarı (SR) ve bağıl nem (RH) hidrolojik parametrelerini içeren modellerin oluşturulması amacı ile yaklaşık 4 yıla yakın günlük meteorolojik veri düzenlenerek kullanılmıştır. 2013-2017 yıllarına ait 1416 tane. verinin %80'i eğitim, %20'si test için ayrılmıştır. Eğitim için 1133 günlük veri, test için 283 günlük ölçüm verisi günlük ortalama buharlaşma miktarı tahmini için girdi verileri olarak kullanılmıştır. İstatistiksel performans değerlendirme ölçütü olarak determinasyon katsayısı( $R^2$ ), ortalama karesel hataların karekökü (KKOH) ve mutlak ortalama hata (MOH) kullanılmıştır.

Bu çalışmada Yapay Sinir Ağı (YSA) ve Radyal Tabanlı Yapay Sinir Ağıdır (RTYSA) olmak üzere iki yapay zekâ yöntemi kullanılmıştır. Çalışma sonucunda iki yapay zekâ yönteminin de uygulanabilir olduğu sonucuna varılmıştır. Uygulanan yapay zekâ yöntemleri ile çalışmada kullanılan tüm modeller arasında en iyi performanslar elde edilmiştir Söz konusu yapay zekâ yöntemlerinin günlük buharlaşma miktarının tahmini için yararlı bir tahmin aracı olabileceği önerilmiştir.

Tüm model sonuçları karşılaştırıldığında, AR(3) modeli tüm modeller içerisinde en yüksek hata ve en düşük determinasyon ile en düşük performans göstermiştir. En düşük hata ve en yüksek determinasyon ile en yüksek performansa Yapay Sinir Ağları (YSA) modeliyle ulaşılmıştır.

Çoklu Doğrusal Regresyon (ÇDR) modelinin, tahminlerin gözlenen değerlere yakınlığı dolayısıyla hata miktarlarının düşük olması açısından, günlük buharlaşma miktarı

tahmininde klasik yöntemler ve otoregresif modellere göre daha doğru sonuçlar verdiği görülmüştür.

Sonuç olarak, yapay zekâ yöntemleri su kaynaklarının optimum bir şekilde planlanması ve yönetilmesinde önemli bir rolü olan buharlaşmanın doğru olarak tahmin edilmesinde tavsiye edilebilir.



## KAYNAKLAR

- Adamala, S., Raghuwanshi, N. S., ve Mishra, A. (2018). Development of Generalized Higher-Order Neural Network-Based Models for Estimating Pan Evaporation. In *Hydrologic Modeling*, 55-71
- Allen, R. G., Pereira, L. S., Raes, D., ve Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage, 300(9), 56
- Armstrong, R. N., Pomeroy, J. W., ve Martz, L. W. (2008). Evaluation of three evaporation estimation methods in a Canadian prairie landscape. *Hydrological Processes: An International Journal*, 22(15), 2801-2815.
- Asmar, B. N., ve Ergenzinger, P. (1999). Estimation of evaporation from the Dead Sea. *Hydrological Processes*, 13(17), 2743-2750.
- Beale, M. H., ve Hagan, M. T., Demuth, H. B., (1996). *Neural Network Design* (PWS, Boston, MA). Google Scholar Google Scholar Digital Library Digital Library.
- Breuning-Madsen, H., ve Jensen, N. H. (1996). Soil map of Denmark according to the revised FAO legend 1990. *Geografisk Tidsskrift-Danish Journal of Geography*, 96(1), 51-59.
- Daldal, N. (2013). Enerji Hatları Üzerinden Haberleşmede İletişim Frekansı Etkisinin YSA İle Analizi Ve Bir Haberleşme Sisteminin Geliştirilmesi. T.C. Gazi Üniversitesi Fen Bilimleri Enstitüsü Elektrik Eğitimi Anabilim Dalı Doktora Tezi ANKARA
- Dalkiliç, Y., Okkan, U., ve Baykan, N. (2014). Comparison of different Ann approaches in daily pan evaporation prediction. *Journal of Water Resource and Protection*, 6(4),8.
- Debjyoti, B. ve Kumar, B. (2019). Estimation of monthly average pet by various methods and its relationship with pan evaporation at Bhagalpur, *Journal of Pharmacognosy and Phytochemistry* ; 8(1), 2481-2484
- Elmas, A. (2003). Late Cenozoic tectonics and stratigraphy of northwestern Anatolia: the effects of the North Anatolian Fault to the region. *International Journal of Earth Sciences*, 92(3), 380-396.
- Ertan, Ü., Göğüş, E., & Alpar, M. A. (2006). X-ray and infrared enhancement of anomalous X-ray pulsar 1E 2259+ 586. *The Astrophysical Journal*, 640(1), 435
- Fox, M. D., Snyder, A. Z., Vincent, J. L., Corbetta, M., Van Essen, D. C., ve Raichle, M. E. (2005). The human brain is intrinsically organized into dynamic, anticorrelated functional networks. *Proceedings of the National Academy of Sciences*, 102(27), 9673-9678.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.
- İnternet: Google Maps, URL: <https://www.google.com.tr/maps/> Son Erişim Tarihi:02.03.2020

- Gümüő, V., Soydan, N. G., SİMSEK, O., Aköz, M. S., ve KIRKGÖZ, M. S. (2013). Yağış-Akış İliőisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması. Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 28(1), 37-50.
- Gümüő, V. ,Şimşek, O. ,Soydan, N. G.,Yeniğün, K. , ve Yeniğün, K. (2016). Adana istasyonunda buharlaşmanın farklı yapay zeka yöntemleri ile tahmini. Mühendislik dergisi,7(2), 309-318
- Gümüő, V., Yeniğün, K., Toprak, Z. F., ve Baçi, N. O. (2018). Şanlıurfa ve Diyarbakır istasyonlarında sıcaklık tabanlı buharlaşma tahmininde YSA, ANFIS ve GEP yöntemlerinin karşılaştırılması. DÜMF Mühendislik Dergisi, 9(1), 553-562.
- Günler,M. (2012). Identification Of Facial Expressions Using Artificial Neural Networks (ANN) .Atılım Üniversitesi. Elektrik-Elektronik Bölümü Yüksek Lisans Tezi .ANKARA.
- Hamzaçebi, C., ve Kutay, F. (2004). Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yilina Kadar Tahmini. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 19(3).
- Hargreaves, G. H., ve Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. Applied engineering in agriculture, 1(2), 96-99.
- Juttner, A., Szabó, I., ve Szentesi, A. (2003, March). On bandwidth efficiency of the hose resource management model in virtual private networks. Twenty-second Annual Joint Conference of the IEEE Computer and Communications Societies, 1, 386-395.
- Keshtegar, B., Kisi, O., Arab, H. G., ve Zounemat-Kermani, M. (2018). Subset modeling. basis ANFIS for prediction of the reference evapotranspiration. Water resources management, 32(3), 1101-1116
- Korkmaz, M.S. (2015). Buharlaşma Kayıplarının Yüzer Fotovoltaik Paneller ile Azaltılması T.C. İstanbul Teknik Üniversitesi Meteoroloji Mühendisliği Anabilim Dalı Yüksek Lisans Tezi. İSTANBUL.
- Lazarou, S., Kabalci, E., Fulli, G., ve Colak, I. (2015). A survey on the contributions of power electronics to smart grid systems. Renewable and Sustainable Energy Reviews, 47, 562-579.
- Mehra, P., ve Wah, B. W. (1992, June). Adaptive load-balancing strategies for distributed systems. In Proc. 2nd Int'l Conf. on Systems Integration, 2(1), 666-675.
- Okkan, U., ve DALKILIÇ, H. Y. (2012). Radyal tabanlı yapay sinir ağları ile Kemer Barajı aylık akımlarının modellenmesi. Teknik Dergi, 23(112), 5957-5966.
- Pour-Ali Baba, A., Shiri, J., Kisi, O., Fard, A. F., Kim, S., ve Amini, R. (2013). Estimating Daily reference evapotranspiration using available and estimated climatic data by adaptive neuro- fuzzy inference system (ANFIS) and artificial neural network (ANN). Hydrology Research, 44(1), 131-146.

- Rashid, T., ve Heider, I. (2008). Life events and depression. *Ann Punjab Med Coll*, 2(1), 128-49.
- Saad, I.B.I. (2018). Karaçomak Barajı Havzasında Bazı Su Kalitesi Parametrelerine Yapay Sinir Ağı (YSA)Tekniklerinin Uygulanması. T.C. Kastamonu Üniversitesi Orman Mühendisliği Ana Bilim Dalı Doktora Tezi. KASTAMONU.
- Seifi, A., ve Riahi, H. (2020). Estimating daily reference evapotranspiration using hybrid gamma test-least square support vector machine, gamma test-ANN, and gamma test-ANFIS models in an arid area of Iran. *Journal of Water and Climate Change*, 11(1), 217-240.
- Shiri, J., Dierickx, W., Pour-Ali Baba, A., Neamati, S., ve Ghorbani, M. A. (2011). Estimating daily pan evaporation from climatic data of the State of Illinois, USA using adaptive neuro-fuzzy inference system (ANFIS) and artificial neural network (ANN). *Hydrology Research*, 42(6), 491-502.
- Taşar, B., Demirci, M., Kaya, Y. Z., Üneş, F. (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *DÜMF Mühendislik Dergisi*,9(1), 543 – 551.
- Terzi, O., ve Keskin, M. E. (2005). Modelling of daily pan evaporation. *J Appl Sci*, 5(2), 368-372.
- Terzi, Ö., ve Ergin, G. (2014). Forecasting of monthly river flow with autoregressive modeling and data-driven techniques. *Neural Computing and Applications*, 25(1), 179-188.
- Trajkovic, S., ve Kolakovic, S. (2009). Wind-adjusted Turc equation for estimating reference evapotranspiration at humid European locations. *Hydrology research*, 40(1), 45-52.
- İnternet: USGS. URL <https://www.usgs.gov/>. Son Erişim Tarihi:12.12.2019
- Üneş, F. (2011). YAPAY SİNİR AĞLARI YAKLAŞIMI İLE TAHTAKÖPRÜ BARAJINDAKİ AYLIK BUHARLAŞMA TAHMİNİ ÖZET. *e-Journal of New World Sciences Academy*, 6(1), 1A0132.
- Üneş, F., Demirci, M., Kaya, Y. Z., Taşar, B., Varçin, H. (2017). Evapotranspiration Estimation Using Support Vector Machines and Hargreaves-Samani Equation for St. Johns, FL, USA. “Environmental Engineering” 10th International Conference.
- Üneş, F., Doğan, S., Taşar, B., Kaya, Y., ve Demirci, M. (2018). The Evaluation and Comparison of Daily Reference Evapotranspiration with ANN and Empirical Methods. *Natural and Engineering Sciences*, 3(3), 54-64.
- Winter, T. C., Rosenberry, D. O., ve Sturrock, A. M. (1995). Evaluation of 11 equations for determining evaporation for a small lake in the north central United States. *Water Resources Research*, 31(4), 983-993.
- Xu, C- Y., and Singh, V. P. (2001) "Evaluation and generalization of temperature- based methods for calculating evaporation." *Hydrological processes*, 15(2), 305-319.



- Yaşar, M. (2004). Günlük Akışlardaki Boşlukların Yapay Sinir Ağları Kullanılarak Tamamlanması. T.C. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü. İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi. DENİZLİ.
- Yılmaz, M. T., ve Bulut, B. Türkiye'deki 2000-2015 yılları arasındaki buharlaşma ve terlemenin NOAH hidrolojik modeli ile incelenmesi. DÜMF Mühendislik Dergisi, 7(2), 225-235.
- Zhang, M. G., Li, W. H., ve Liu, M. Q. (2005, October). Adaptive PID control strategy based on RBF neural network identification. In 2005 International Conference on Neural Networks and Brain, 3, 1854-1857.



## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : DOĞAN  
Süreyya  
Uyruğu : T.C.  
Doğum tarihi ve yeri : 17.06.1994, Birecik  
Medeni hali : Bekâr  
Telefon : 05530554024  
e-mail : sryydgn1994@gmail.com



### Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek Lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2020
Lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2017
Lise	Mehmet Adil Çulcuoğlu Anadolu Lisesi	2011

### İş Deneyimi

Yıl	Yer	Görev
2018-2019	Atlas İnşaat	Mühendis
2017-2018	Turhaner Yapı Denetim	Mühendis

### Yabancı Dil

İngilizce

### Hobiler

Yüzme, Teknoloji, Spor

## DİZİN

---

**A**

Ampirik ·  
68,20,27,28,29,47,48,67,69

---

**B**

Buharlaştırma ·  
68,1,4,5,6,7,8,9,10,11,14,18  
19,39,58,59,60,61

---

**Ç**

ÇLR ·  
68,6,18,37,38,39,55,56,57,  
58,60

---

**H**

HİDROLOJİ ·  
68,1,3,4,37,60

---

**M**

Meteorolojik Veri ·  
68, iv ,18,37,38,39,55,56,57,  
58,60

---

**Model ·**

68,iv,4,5,6,7,8,9,10,11,12,14  
18,20,24,29,31,32,33,34,35,  
36,37,38,39,41,42,44,45,46,  
48,49,50,51,52,54,55,56,57,  
58,59,60,61

---

**O**

Otoregresif Model  
36,50,55,58,59

Ortalama Karesel Hataların  
karakökü ·  
68,7,38,39,58,59,60

Ortalama Mutlak Hata ·  
ix,38,39,50,59,60

---

**R**

RTYSA ·  
68,x68,6,8,IX,11,18,34,35  
38,39,58,59,60,

---

**Y**

Yapay Sinir Ağları ·  
68,6,7,9,10,11,18,20,21,22,  
27,28,34,38,39,45,47,60

---

**Tahmin·**

68,4,5,6,7,8,9,10,11,14,18,  
19,22,29,34,36,38,39,55,58,  
59,60,61



**TEKNOVERSİTE**

