

**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**METEOROLOJİK VERİLERİ KULLANARAK**  
**AYLIK TAVA BUHARLAŞMASINI TAHMİN**  
**ETMEK İÇİN YAPAY ZEKA**  
**METOTLARININ UYGULANMASI**

**Ayşe ÖZEL**

**YÜKSEK LİSANS**

**İnşaat Mühendisliği Anabilim Dalı**

**Ağustos-2018**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Ayşe ÖZEL tarafından hazırlanan "Meteorolojik Verileri Kullanarak Aylık Tava Buharlaşmasını Tahmin Etmek İçin Yapay Zeka Metotlarının Uygulanması" adlı tez çalışması 13/08/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü İnşaat Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Doç. Dr. Şerife Yurdağül KUMCU

#### Danışman

Doç. Dr. Meral BÜYÜKYILDIZ

#### Üye

Dr. Öğr. Üyesi Alpaslan YARAR

### İmza

.....  
.....  
.....

Yukarıdaki sonucu onaylıyorum.

Prof. Dr. Yakup KARA  
LEE Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

  
Ayşe ÖZEL

Tarih: 13.08.2018

# ÖZET

## YÜKSEK LİSANS TEZİ

### METEOROLOJİK VERİLERİ KULLANARAK AYLIK TAVA BUHARLAŞMASINI TAHMİN ETMEK İÇİN YAPAY ZEKA METOTLARININ UYGULANMASI

Ayşe ÖZEL

Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç Dr. Meral BÜYÜKYILDIZ

2018, 75 Sayfa

Jüri

Doç. Dr. Meral BÜYÜKYILDIZ  
Doç. Dr. Şerife Yurdağül KUMCU  
Dr. Öğr. Üyesi Alpaslan YARAR

Bu çalışmada aylık açık yüzey buharlaşma tahmini amaçlanmıştır. Aylık buharlaşmayı tahmin etmek için, Türkiye'deki Konya Kapalı Havzası'nda Devlet Meteoroloji İşleri tarafından işletilen üç istasyonun (Konya, Karaman, Aksaray) toplam yağış, ortalama sıcaklık, minimum sıcaklık, maksimum sıcaklık, ortalama rüzgâr hızı, ortalama nispi nem, ortalama buhar basıncı ve ortalama atmosferik basınç meteorolojik verileri yapay zeka tekniklerine input olarak kullanılmıştır. İstasyonların aylık buharlaşma tahmini için, MLP-SCG, MLP-GDX, RBNN, GRNN, ANFIS,  $\epsilon$ -DVR'yi içeren yapay zeka metodları kullanılmıştır. Sonuçlar, FAO-Penman-Monteith, Priestley-Taylor, Meyer ve Romanenko ampirik denklemlerinin sonuçlarıyla karşılaştırılmıştır. Geliştirilen modellerin uygulanabilirliğini değerlendirmek için, Nash-Sutcliffe etkinlik katsayısı (NSE), ortalama mutlak hata (MAE) ve karekök ortalama karesel hata (RMSE) kullanılmıştır.

Üç istasyonun sonuçlarına göre, en başarılı yapay zeka metodu, Karaman ve Aksaray istasyonlarında  $\epsilon$ -DVR, Konya istasyonunda ise MLP-SCG modeli olmuştur. Buharlaşma tahmini için, kullanılan yapay zeka metodları arasında en kötü performans, Karaman ve Konya istasyonunda GRNN, Aksaray istasyonunda ise ANFIS metodlarında elde edilmiştir.

Kullanılan ampirik denklemlerin sonuçları, FAO-Penman-Monteith denkleminin üç istasyonda da diğer ampirik denklemlerden daha başarılı olduğunu göstermiştir.

Uygulanan modeller karşılaştırıldığında ise buharlaşma tahmini için yapay zeka metodlarının ampirik denklemlere oranla daha başarılı olduğu sonucuna varılmıştır.

**Anahtar Kelimeler:** Buharlaşma, İklim Değişikliği, Konya Kapalı Havzası, Yapay Zeka Metodları.

## **ABSTRACT**

### **MS THESIS**

# **APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS TO ESTIMATE MONTHLY PAN EVAPORATION USING METEOROLOGICAL DATA**

**Ayşe ÖZEL**

**THE GRADUATE EDUCATION INSTITUTE OF KONYA TECHNICAL  
UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN CIVIL ENGINEERING**

**Advisor: Assoc. Prof. Meral BÜYÜKYILDIZ**

**2018, 75 Pages**

**Jury**

**Assoc. Prof. Dr. Meral BÜYÜKYILDIZ  
Assoc. Prof. Dr. Şerife Yurdagül KUMCU  
Asst. Prof. Dr. Alpaslan YARAR**

In this study, it is aimed to estimate monthly open surface evaporation. The monthly meteorological data, total precipitation, average temperature, minimum temperature, maximum temperature, average wind speed, average relative humidity, average vapor pressure, average atmospheric pressure, of three stations (Konya, Karaman, Aksaray) operated by Turkish State Meteorological Service on Konya Closed Basin in Turkey are used as inputs to the artificial intelligence techniques to estimate monthly evaporation. Artificial intelligence methods consisting of MLP-SCG, MLP-GDX, RBNN, GRNN, ANFIS,  $\epsilon$ -DVR models are used for estimating the monthly evaporation of the stations. The results were compared with the results of FAO-Penman-Monteith, Priestley-Taylor, Meyer and Romanenko empirical equations. Nash-Sutcliffe efficiency coefficient (NSE), mean absolute error (MAE) and root mean square error (RMSE) were used for evaluating the applicability of developed models.

According to the results of three stations, the most successful artificial intelligence methods were obtained in  $\epsilon$ -SVR method at Karaman and Aksaray stations and MLP-SCG models in Konya station. For estimation of evaporation, the worst performance among artificial intelligence methods used was obtained at GRNN at Karaman and Konya stations and ANFIS at Aksaray station.

The results of the empirical equations used show that the FAO-Penman-Monteith is more successful than the other empirical equations in all three stations.

Comparison of the applied models reveals that the artificial intelligence methods perform better than the empirical equations for evaporation estimation.

**Keywords:** Evaporation, Climate Change, Konya Closed Basin, Artificial Intelligence Methods.

## ÖNSÖZ

Giderek artan su ihtiyacı karşısında su kaynaklarının korunması ve geliştirilmesi günümüzde bir zorunluluk haline gelmiştir. Bu kaynakların korunması ve geliştirilmesi için öncelikle elimizde bulunan kaynaklar bilinmeli ve bu doğrultuda projeler hayata geçirilmelidir.

Suyun, yeryüzünde birbirine dönüştüğü tüm halleri kapsayan bir olgu olan hidrolojik çevrim ve bu olgunun en aktif parametresi olan buharlaşma su kaynaklarının etkin bir şekilde planlanması ve yönetimi açısından büyük önem taşımaktadır.

Bu çalışmayı tamamlamamda bilgisini ve tecrübesini esirgemeyen danışmanım Doç. Dr. Meral BÜYÜKYILDIZ'a, yardımlarını esirgemeyen DSİ Kalite Kontrol ve Laboratuvar Şube Müdürü İbrahim PINARKARA'ya, dualarıyla yanımda olan annem Fatma PINARKARA'ya, bu süreçte her konuda anlayışıyla beni destekleyen eşim Mustafa ÖZEL'e ve minik kızım A. Mihrimah ÖZEL'e teşekkürü bir borç bilirim.

Ayşe ÖZEL  
KONYA-2018

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>4</b>
<b>3. BUHARLAŞMA</b> .....	<b>10</b>
3.1. Buharlaşmayı Etkileyen Faktörler .....	12
3.2. Buharlaşma Türleri ve Buharlaşma Miktarının Belirlenmesi .....	13
<b>4. MATERYAL VE YÖNTEM</b> .....	<b>21</b>
4.1. Çalışma Alanı ve Data .....	21
4.2. Yapay Sinir Ağları (YSA) .....	25
4.2.1. Yapay sinir ağlarının mimarisi .....	28
4.2.2. Yapay sinir ağlarının sınıflandırılması .....	29
4.2.2.1. Yapılarına göre ağ çeşitleri .....	29
4.2.2.2. Öğrenme yöntemine göre ağ çeşitleri .....	31
4.2.3. Genelleştirilmiş Regresyon Sinir Ağları (GRNN).....	33
4.2.4. Radyal Tabanlı Sinir Ağları (RBNN) .....	34
4.2.5. Çok Katmanlı Yapay Sinir Ağları (MLP).....	35
4.3. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS).....	36
4.3.1. ANFIS modelinin mimarisi ve işleyişi .....	37
4.4. Destek Vektör Makineleri ( DVM ).....	38
4.4.1. Destek Vektör Regresyonu (DVR).....	39
4.5. Ampirik Denklemler .....	41
4.5.1. Meyer denklemi .....	41
4.5.2. Priestley-Taylor denklemi.....	42
4.5.3. Romanenko denklemi .....	43
4.5.4. FAO-Penman Monteith denklemi.....	43
<b>5. ARAŞTIRMA BULGULARI VE TARTIŞMA</b> .....	<b>45</b>
5.1. MLP – GDX Model Uygulaması.....	47
5.2. MLP – SCG Model Uygulaması.....	49
5.3. RBNN Model Uygulaması.....	50
5.4. GRNN Model Uygulaması .....	52
5.5. ANFIS Model Uygulaması .....	53

5.6. $\epsilon$ -DVR Model Uygulaması .....	55
5.7. Ampirik Denklemler ile Yapay Zeka Metotlarının Karşılaştırılması .....	58
<b>6. SONUÇLAR VE ÖNERİLER .....</b>	<b>67</b>
<b>KAYNAKLAR .....</b>	<b>69</b>
<b>ÖZGEÇMİŞ .....</b>	<b>75</b>





## ÇİZELGELER LİSTESİ

<b>Çizelge 4.1.</b> Konya, Karaman ve Aksaray meteoroloji istasyonlarına ait bazı özellikler.....	21
<b>Çizelge 4.2.</b> Konya istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri.....	24
<b>Çizelge 4.3.</b> Karaman istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri .....	24
<b>Çizelge 4.4.</b> Aksaray istasyonuna ait ortalama, maksimum, minimum ve standart sapma değerleri.....	25
<b>Çizelge 4.5.</b> Yaygın olarak kullanılan çekirdek fonksiyonları.....	41
<b>Çizelge 5.1.</b> Kullanılan input kombinasyonları.....	45
<b>Çizelge 5.2.</b> Eğitim ve test aşamasında kullanılan gözlem periyotları ve veri sayısı.....	46
<b>Çizelge 5.3.</b> MLP-GDX modellerine ait sonuçlar.....	48
<b>Çizelge 5.4.</b> MLP-SCG modellerine ait sonuçlar.....	50
<b>Çizelge 5.5.</b> RBNN modellerine ait sonuçlar.....	51
<b>Çizelge 5.6.</b> GRNN modellerine ait sonuçlar.....	53
<b>Çizelge 5.7.</b> ANFIS modellerine ait sonuçlar.....	54
<b>Çizelge 5.8.</b> $\epsilon$ -DVR modellerine ait sonuçlar.....	57
<b>Çizelge 5.9.</b> Test periyodu için yapay zeka metotları ve ampirik denklemlere ait sonuçlar.....	59

## ŞEKİLLER LİSTESİ

Şekil 3.1. Buharlaştırma ve hidrolojik çevrim.....	10
Şekil 3.2. Su yüzeyinden buharlaştırma olayı.....	10
Şekil 3.3. Türkiye'nin 1981-2010 yılları arasındaki yıllık referans toplam buharlaştırma normal haritası.....	11
Şekil 3.4. A Sınıfı Buharlaştırma Tavasını.....	16
Şekil 3.5. Buharlaştırma tahmin yöntemleri.....	17
Şekil 4.1. Kullanılan istasyonların Türkiye'deki konumları.....	21
Şekil 4.2. Konya Kapalı Havzası siyasi haritası .....	22
Şekil 4.3. Konya Kapalı Havzası fiziki haritası.....	23
Şekil 4.4. Biyolojik sinir hücresi.....	26
Şekil 4.5. Basit yapay sinir ağı.....	28
Şekil 4.6. Çok katmanlı ileri beslemeli yapay sinir ağı mimarisi.....	29
Şekil 4.7. Çok katmanlı geri beslemeli yapay sinir ağı mimarisi.....	30
Şekil 4.8. Çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı mimarisi.....	30
Şekil 4.9. Öğretmenli eğitim.....	31
Şekil 4.10. Öğretmensiz eğitim.....	32
Şekil 4.11. Yarı öğretmenli eğitim.....	32
Şekil 4.12. GRNN yapısı.....	33
Şekil 4.13. RBNN yapısı.....	35
Şekil 4.14. Çok katmanlı ileri beslemeli YSA modeli.....	36
Şekil 4.15. ANFIS mimarisi.....	37
Şekil 4.16. Destek Vektör Makinelerinin genel yapısı.....	38
Şekil 5.1. a) Aksaray, b) Karaman, c) Konya istasyonlarına ait ANFIS-SC model yapıları.....	56
Şekil 5.2. Aksaray istasyonu için ampirik denklemler ve en başarılı ağı yapısı ve input kombinasyonuna sahip yapay zeka metotlarına ait test periyodu saçılım diyagramları.....	61
Şekil 5.3. Karaman istasyonu için ampirik denklemler ve en başarılı ağı yapısı ve input kombinasyonuna sahip yapay zeka metotlarına ait test periyodu saçılım diyagramları.....	62
Şekil 5.4. Konya istasyonu için ampirik denklemler ve en başarılı ağı yapısı ve input kombinasyonuna sahip yapay zeka metotlarına ait test periyodu saçılım diyagramları.....	63
Şekil 5.5. Aksaray istasyonu için eğitime ve test periyoduna ait zaman serisi.....	64
Şekil 5.6. Karaman istasyonu için eğitime ve test periyoduna ait zaman serisi.....	65
Şekil 5.7. Konya istasyonu için eğitime ve test periyoduna ait zaman serisi.....	66

## SİMGELER VE KISALTMALAR

### Simgeler

$\alpha$	:	1.05 ile 1.38 arasında değişen bir sabit
$\varepsilon$	:	Duyarsız hata terimi
$\delta_i$ ve $\delta_i^*$	:	Yapay değişkenler
$\gamma$	:	Psikrometrik sabit
$\Delta$	:	Doymun buhar basınç eğrisi eğimi
$\Delta H$	:	Su kütleinin sıcaklığındaki değişme için gerekli ısı
$\Delta S$	:	Kütlenin hacimdeki değişme miktarı
$b_i$	:	Bias sabiti
$C$	:	Düzenleme faktörü
$C_j, \sigma_j$	:	Bant genişliği
$D_i^2$	:	Skaler bir fonksiyon
$e_a$	:	Hava basıncı
$e_s$	:	Doymun buhar basıncı
$e_w$	:	Su basıncı
$e_1$ ve $e_2$	:	$z_1$ ve $z_2$ yükseklikte havanın buhar basıncı
$E$	:	Buharlaşma miktarı
$E_{pan}$	:	Tava buharlaşması
$ET_p$	:	Potansiyel buharlaşma
$ET_0$	:	Referans bitki su tüketimi
$F$	:	Yeraltına sızan su miktarı
$G$	:	Kütleye giren ısı akışı
$H_c$	:	Su yüzeyinden atmosfere kondüksiyonla kaybolan ısı
$H_e$	:	Buharlaşmada kullanılan enerji
$H_i$	:	Kütleye giren akımların getirdiği ısının toplamı
$H_o$	:	Kütleden çıkan akımların ısısı ile yansıyan ısının toplamı
$k_p$	:	Tava katsayısı
$K$	:	Sabit
$L$	:	Suyun buharlaşma ısısı
$n, N$	:	Örnek sayısı
$P$	:	Aylık toplam yağış
$p$	:	$x$ vektörünün boyutu
$P_o$	:	Atmosfer basıncı
$R$	:	Bowen oranı
$RH$	:	Rölatif nem
$R_n$	:	Net radyasyon
$R^2$	:	Determinasyon katsayısı
$s$	:	Düzeltilme parametresi
$T_a$	:	Hava sıcaklığı
$T_{mak}$	:	Maksimum sıcaklık
$T_{min}$	:	Minimum sıcaklık
$T_w$	:	Su sıcaklığı
$T_{ort}$	:	Ortalama sıcaklık
$u$	:	Hedef vektörü
$u_2$	:	2 m yükseklikteki rüzgar hızı
$w = [w_0, w_1, \dots, w_N]^T$	:	Ağırlık vektörü

w	:	Rüzgar hızı
$w_i$	:	Gizli nöron i ve çıkış nöronu j arasındaki ağırlık katsayısı
$w_1$ ve $w_2$	:	$z_1$ ve $z_2$ yüksekliklerindeki rüzgar hızı
x	:	Giriş vektörü
X	:	Giren akış miktarı
Y	:	Çıkan akış miktarı

### Kısaltmalar

ANFIS	:	Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi
AMM	:	Serbest Amonyak
AP	:	Atmosfer Basıncı
ARMA	:	Otoregresif Hareketli Ortalama
BM	:	Bulanık Mantık
BR	:	Bayes Düzenlemesi
BP	:	Back-Propagation
CORR	:	Korelasyon Katsayısı
ÇKYSA	:	Çok Katmanlı Yapay Sinir Ağları
ÇDR	:	Çoklu Doğrusal Regresyon
DMİ	:	Devlet Meteoroloji İşleri
DSİ	:	Devlet Su İşleri
DVM	:	Destek Vektör Makineleri
DVR	:	Destek Vektör Regresyonu
RBF	:	Radyal Tabanlı Fonksiyon
FC	:	Fecal Koliform
FFBP	:	İleri Beslemeli Geri Yayılım Modelleri
GBYSA	:	Geris Beslemeli Yapay Sinir Ağları
GDX	:	Adaptif Öğrenmeli ve Momentum Özellikli En Dik İniş
GEP	:	Gen Ekspresyon Programlama
GRNN	:	Genelleştirilmiş Regresyon Sinir Ağları
GRYSA	:	Genelleştirilmiş Regresyon Yapay Sinir Ağları
İBGYYSA	:	İleri Beslemeli Geri Yayılmalı Yapay Sinir Ağları
İBYSA	:	İleri Beslemeli Yapay Sinir Ağları
LM	:	Levenberg-Marquardt
LSSVM	:	En Küçük Kareli Destek Vektör Makinesi
LS-SVR	:	En Küçük Kareler- Destek Vektörü Regresyonu
MAE	:	Ortalama Mutlak Hata
MARS	:	Çok Değişkenli Uyarlanabilir Regresyon Spline
MLP	:	Çok Katmanlı Yapay Sinir Ağları
NSE	:	Nash-Sutcliffe Etkinlik Katsayısı
OKH	:	Ortalama Karesel Hata
OMH	:	Ortalama Mutlak Hata
pH	:	Hidrojen Potansiyeli
PM	:	Penman-Monteith
PSO	:	Parçacık Sürü Optimizasyonu
RBNN	:	Radyal Tabanlı Sinir Ağları
RMSE	:	Karekök Ortalama Karesel Hata
RTYSA	:	Radyal Tabanlı Yapay Sinir Ağları
SCG	:	Ölçeklendirilmiş Eşlenik Gradyan

TAGEM	:	Tarımsal Arařtırmalar ve Politikalar Genel M¼d¼rl¼ę¼
TBP-NN	:	Geęici geriye yayılım sinir aęı
TC	:	Toplam Koliform
TKN	:	Toplam Kjeldahl Azotu
VP	:	Buhar Basıncı
WS	:	R¼zgar Hızı
WT	:	Su Sıcaklıęı
YSA	:	Yapay Sinir Aęları



## 1. GİRİŞ

Su, tarih boyunca canlılar için doğal ve en temel yaşam kaynaklarından biri olmuştur. İnsanoğlunun temel yaşam kaynağı olma özelliğinin yanı sıra ulusal güvenlik, enerji üretimi ve ülke ekonomisinin kalkınmasında da etkin bir rol üstlenmektedir. Bu durum ise suyun önemini artırmakta, var olan su kaynaklarının korunması, geliştirilmesi ve özellikle hidrolojik çevrimin su kaynakları üzerindeki etkisinin araştırılması konularının önemini de artırmaktadır.

Hidrolojik çevrim; suyun yeryüzünde birbirine dönüştüğü tüm halleri kapsayan bir olgudur. Bu olgunun en aktif parametresini ise buharlaşma oluşturur. Buharlaşmanın doğru bir şekilde tahmin edilmesi, su kaynaklarının etkin bir şekilde planlanmasında, işletilmesinde ve sulama sularının planlanmasında önemli bir rol üstlenmektedir.

Türkiye’de yaklaşık olarak yıllık ortalama 643 mm yağış düşmekte olup bu değer yılda ortalama 501 milyar m<sup>3</sup> suya karşılık gelmektedir. Toprak ve su yüzeyleri ile bitkilerden oluşan buharlaşma nedeniyle, bu su miktarının 274 milyar m<sup>3</sup>’ü atmosfere geri dönerken, 69 milyar m<sup>3</sup>’lük kısmı yeraltı suyunu beslemekte ve geri kalan 158 milyar m<sup>3</sup>’lük kısmı da akışa geçmek suretiyle akarsular aracılığı ile denizlere ve göllere boşalmaktadır. Yeraltı suyunu besleyen 69 milyar m<sup>3</sup>’lük suyun 28 milyar m<sup>3</sup>’ü pınarlar aracılığıyla tekrar yüzeysel sulara katılmaktadır. Komşu ülkelerden gelen yılda ortalama 7 milyar m<sup>3</sup> su ile birlikte ülkemizin brüt yerüstü suyu potansiyeli 193 milyar m<sup>3</sup> olmaktadır (<http://www.dsi.gov.tr/toprak-ve-su-kaynaklari>).

Türkiye’ye düşen yağışın yaklaşık yarısı buharlaşma yolu ile atmosfere geri dönmektedir ki bu değer, ülkemizin yerüstü su potansiyelinden yaklaşık 77 milyar m<sup>3</sup> daha fazla olup oldukça önemli bir miktardır. Bu nedenle buharlaşma miktarının doğru olarak belirlenmesi tüm dünyada olduğu gibi ülkemiz açısından da oldukça önemlidir.

Ancak buharlaşma tek başına bir olgu olmayıp sıcaklık, rüzgar hızı, bağıl nem ve atmosferik basınç gibi birçok parametreye bağlı bir oluşumdur. Buharlaşmanın doğasından kaynaklanan doğrusal olmayan bu karmaşık yapısından dolayı, literatürde buharlaşmayı tahmin etmek üzere birçok ampirik denklem geliştirilmiştir. Fakat bu denklemler genellikle birbiriyle de çelişmektedir. Bu nedenle buharlaşma miktarını en iyi tespit eden ampirik denklemi belirlemek oldukça zor olmaktadır. Problemin karmaşıklığı ve belirsizliği klasik yöntemlere rahat modelleme imkanı vermez. Buharlaşma miktarı ya direkt olarak aletlerle ölçülür, ayrıca Su Dengesi, Enerji Dengesi, Kütle Transferi denklemleri ile ya da Penman, Thornthwaite, Blaney-Cridle

gibi çeşitli ampirik denklemler yardımıyla dolaylı olarak hesaplanabilir. Ancak bu denklemlerde kullanılan parametre sayılarının fazlalığı ve değerlerin meteorolojik ölçümlerindeki güçlükler referans alındığında daha az parametre ile gerçeğe daha yakın buharlaşma modellemelerine ihtiyaç duyulmuştur (Terzi, 2004).

Son yıllarda pek çok alanda olduğu gibi hidrolik, hidrolojik ve meteorolojik parametrelerin tahmin edilmesinde etkili bir biçimde kullanılan yapay zeka modelleri ile de bu konuda önemli mesafeler alınmıştır. İnsan beyninin bir çeşit taklidi niteliğindeki işlevleri sayesinde, karmaşık ve modellemesi güç sistemler arasındaki ilişkileri çözüme kavuşturuyor olması, klasik yöntemlerle elde edilen çözümü güç matematiksel verilerin zorluğunu da ortadan kaldıran bir programlama sistemine sahip olmaları yapay zeka modellerinin mühendisler tarafından kullanımlarını artırmıştır. Ayrıca bu modelleme tekniklerinin klasik yöntemlerdeki sonuçlara yakınlığı ve daha kısa sürede sonuçlanması ise hidroloji biliminde de kendine önemli bir yer bulmasını sağlamıştır. Hidroloji biliminde kullanımının yaygınlaşmasının temelinde ise su kaynaklarının doğrusal olmayan ve birçok değişkene sahip karmaşık sistemlerden oluşması durumu vardır.

Bu modelleme teknikleri sayesinde su kaynaklarının miktar ve kalite olarak potansiyelinin belirlenmesinde, kaynakların yönetilmesinde, kaynaklara ait projelerin planlanmasında, tasarımı, inşaatı ve işletmesinde önemli olan hidrolojik çalışmaları kolaylaştıran programlar su kaynakları mühendisliğine de büyük oranda katkı sağlar hale gelmiştir.

Türkiye, özellikle küresel ısınmaya bağlı olarak görülebilecek bir iklim değişikliğinden en çok etkilenebilecek ülkeler arasındadır. Üç tarafından denizlerle çevrili olması, parçalanmış bir topoğrafyaya sahip bulunması ve orografik özellikleri nedeniyle, Türkiye'nin farklı bölgeleri, farklı biçimde ve değişik derecelerde iklim değişikliğinden etkilenecektir (Öztürk, 2002). Artık tüm dünya ile birlikte ülkemizde de hissedilen küresel ısınma ve beraberinde getirdiği etkilerin ilerleyen zamanlarda daha büyük sonuçlara ulaşacağı, neticesinde oluşacak kuraklık ve buna bağlı olarak su sıkıntısı var olan kaynaklarımızın etkili bir şekilde planlanarak kullanılmasını son derece önemli kılmaktadır.

Yapılan tez çalışmasında ise ülkemizin en kurak havzalarından olan Konya Kapalı Havzası'nda bulunan ve Konya Meteoroloji Bölge Müdürlüğü tarafından işletilen Konya, Karaman ve Aksaray meteoroloji istasyonlarına ait aylık toplam yağış (P), ortalama sıcaklık ( $T_{ort}$ ), minimum sıcaklık ( $T_{min}$ ), maksimum sıcaklık ( $T_{mak}$ ), ortalama rüzgâr hızı (WS), ortalama nispi nem (RH), ortalama buhar basıncı (VP) ve

ortalama atmosferik basınç (AP) verileri kullanılarak hidrolojik çevrimin temel taşlarından biri olan toplam açık yüzey buharlaşma miktarının, Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS) gibi yapay zeka teknikleri ve beraberinde çeşitli ampirik denklemlerle modellenmesinin yapılması amaçlanmış olup yine bu tez çalışması ile çeşitli bileşenlere göre farklılık gösteren ve bundan dolayı karmaşık bir yapıya sahip olan buharlaşma miktarının modellenerek tarımsal planlama ve su kaynaklarının optimizasyonuna katkı sağlaması hedeflenmiştir.





## 2. KAYNAK ARAŞTIRMASI

Su kaynaklarının belirlenmesi, geliştirilmesi, planlanması ve inşasında hidrolik ve hidroloji biliminin disiplinlerinin önemi ortadadır. Hidrolojik ve meteorolojik parametrelerin laboratuvar şartlarına indirgenememesi sebebiyle, klasik yöntemlerdeki sonuçlara yakınlığı ve daha kısa sürede sonuçlanması, yapay zekâ metotlarının bu tür alanlarda yapılan araştırmalardaki değerini daha da artırmıştır. DVM, YSA ve ANFIS gibi yapay zekâ teknikleri bugüne kadar gerek ülkemizde gerek dünyada pek çok hidrolik, hidrolojik ve meteorolojik araştırmaya ışık tutmuştur (Gocic ve ark., 2015; Shirmohammadi ve ark., 2013; Wu ve ark., 2010; Güldal ve Tongal, 2010; Altunkaynak, 2007; Keskin ve ark., 2006; Yarar, 2004; Zhao ve Wang, 2010; Shiri ve ark., 2014; Behmanesh ve Mehdizadeh, 2017; Mehdizadeh ve ark., 2016; Tokar ve Markus, 2000; Çimen, 2008; Buyukyildiz ve ark., 2014, Sudheer ve ark., 2014; Mohandes, 2012; Doğan ve ark., 2007).

Mason ve ark.(1996), yaptıkları çalışmada drenaj sistemlerinde akışların ve yağış – akışın modellenmesinde YSA metodunu kullanmışlardır. Bu metotta öğrenme yöntemlerinden olan geriye yayılım algoritması ve radyal tabanlı fonksiyonları karşılaştırmışlardır. Karşılaştırma sonucunda radyal tabanlı fonksiyonun uygun veri sınıflandırma tekniği ile oldukça iyi sonuçlar elde ettiğini, geri yayılım algoritmasının ise oldukça yavaş olduğunu ifade etmişlerdir.

Sajkumar ve Thandaveswara (1999), yaptıkları çalışmada aylık yağış – akışların modellenmesi için geçici geriye yayılım sinir ağı (TBP-NN) olarak isimlendirilen bir YSA modellemesinden faydalanmışlardır. Çalışmalarında Lee ve Thuthapuzha Nehirlerinin verilerinden yararlanırken, Volterra-type fonksiyonel seri modellerinin sonuçları ile YSA modelinin sonuçlarını kıyaslamışlardır. Ortaya çıkan sonuç, TBP-NN modelinin uygunluğunu göstermiştir.

Bruton ve ark. (2000), çalışmalarında günlük tava buharlaşmasını belirlemek için girdi olarak günlük yağış, sıcaklık, nispi nem, güneş radyasyonu ve rüzgâr hızı gibi ölçülmüş hava değişkenlerini kullanmış ve bir yapay sinir ağı modeli geliştirmişlerdir. Çoklu lineer regresyon ve Priestley- Taylor metotlarından da faydalanarak günlük tava buharlaşması tahmininde bulunmuşlardır. YSA ile diğer metotlara ait sonuçlar karşılaştırıldığında ise, YSA modelleri ile tahmin edilen değerlerin diğer iki metottan elde edilen tahminlere göre daha iyi olduğu sonucuna ulaşmışlardır.

Thirumalaiah ve Deo (2000), Hindistan'da yaptıkları çalışmada günlük nehir ile saatlik akımın gerçek zamanlı tahminlerinde YSA modellerinin bölgedeki yağışın saptanması için yeterli olduğunu vurgulamışlardır.

Tokar ve Markus (2000), havzadaki akış miktarlarının tahmininde sıcaklık, kar yağışı ve yağış miktarının fonksiyonlarını kullanarak geleneksel modeller ile YSA modellerini karşılaştırmışlardır. Farklı zaman aralıklarında, yağış-akış modellemelerinde, çeşitli topografya ve iklimlerde yapılacak modellemelerde YSA'nın önemli bir yöntem olacağını vurgulamışlardır.

Yarar (2004), Konya Ovası Projesi için önemli bir kaynak olan Beyşehir Gölü'nün su seviyesi değişimlerini belirlemek için YSA yöntemini kullanmıştır. Giren akım-kayıp akım, yağış, buharlaşma, seviye ölçümü ve çekilen akım verilerini kullanarak YSA yardımı ile seviye değerlerinin tahmin edilmesinin amaçlandığı çalışmada, YSA modellerinden elde edilen seviye değerleri geleneksel yöntemlerden elde edilen sonuçlarla karşılaştırılmıştır.

Fırat (2007) tarafından yapılan çalışmada, Büyük Menderes havzasında, dört akarsu kolu için birbirinden farklı giriş yapısına sahip akış ve katı madde tahmin modelleri geliştirmek amacıyla ANFIS yöntemi kullanılmıştır. Tahminin güvenilirliğini artırmak adına, çapraz geçerlilik (crossvalidation) yöntemine başvurulmuştur. Düzenlenen eğitim ve test verileri için ayrı ayrı eğitim gerçekleştirilmiştir. ANFIS ve YSA metotlarının kullanıldığı çalışmada ortaya çıkan sonuçlar ise, ANFIS yönteminin akış ve katı madde modellemesinde ve tahmininde uygulanabileceğini göstermiştir.

Doğan ve ark. (2007), Sapanca Gölü için yaptıkları çalışmada rüzgâr hızına, göreceli neme, gerçek güneşlenme süresine, maksimum güneşlenme müddetine, minimum ve maksimum sıcaklığa bağlı olarak günlük buharlaşma miktarının tahmini için radyal tabanlı yapay sinir ağı (RT-YSA) ve ileri beslemeli geri yayımlı yapay sinir ağı (İBGY-YSA) modellerini kullanmışlardır. Elde edilen sonuçlar ise Penman-Monteith (PM) modelinden belirlenen sonuçlarla kıyaslanmıştır. Performans sonuçlarına göre, ölçülen günlük buharlaşma miktarına en yakın sonucu İBGY-YSA yönteminin verdiği vurgulamıştır.

Afşar (2008) tarafından yapılan çalışmada, Kayseri, Kırşehir, Nevşehir ve Yozgat illerindeki istasyonlardan alınan günlük ortalama sıcaklık, minimum sıcaklık, maksimum sıcaklık, ortalama nem ve buharlaşma verilerinden faydalanılmıştır. Bulanık mantık (BM) ve YSA modellerinin kullanıldığı çalışmada, Çok Katmanlı YSA (ÇKYSA), Radyal Tabanlı YSA (RTYSA), Genelleştirilmiş Regresyon YSA (GRYSA),

ANFIS ve Çoklu Doğrusal Regresyon (ÇDR) yöntemleri ile değişik giriş kombinasyonları uygulanarak buharlaşma tahminleri yapılmıştır. Bu sayede her bir değişkenin buharlaşmaya olan etkisi incelenmiştir.

Dindar (2010), çalışmasında Tahtaköprü Barajı'ndaki aylık buharlaşma tahmini için YSA metodunu kullanmıştır. Buharlaşma miktarının tespiti için geçmiş yıllarda meydana gelen aylık buharlaşma miktarları veri olarak değerlendirilmiş ve verilerin eğitilmesinde Bayesian düzenleme tekniği tercih edilmiştir. Levenberg – Marquardt optimizasyon yöntemine göre geliştirilmiş olan bu teknikte ağırlık ve bias katsayıları yenilenmiştir. Ulaşılan YSA sonuçları, MLR ve AR(p) modellerindeki sonuçlar ile karşılaştırılmıştır. Karşılaştırma sonuçları ise baraj haznesi aylık buharlaşma miktarının tahmininde YSA modelinin sonuçlarının, geçmişte kullanılan klasik yöntemlere göre daha iyi bir yaklaşım sunduğunu göstermiştir.

Deswal ve Pal (2008) yaptıkları çalışmada, DVM yöntemini kullanarak tava buharlaşma tahmini yapmışlardır. Bu amaç için Shegaon'da bulunan Anand Sagar Rezervuarı'nın yakınındaki Manasgoan iklim istasyonundan alınan verileri kullanmışlardır. DVM mimarisinde çıkış parametresi olarak buharlaşma ve giriş parametresi olarak ise hava sıcaklığı, rüzgâr hızı, güneşlenme saatleri ve bağıl nem kullanılmıştır. DVM yaklaşımının performansı belirlenirken, ÇDR ile meteorolojik parametrelerin farklı kombinasyonları karşılaştırılmış ve buharlaşma tahmini için giriş parametreleri değerlendirilmiştir. Bu çalışma sonuçları DVM metodunun rezervuardaki tava buharlaşma tahmini için kullanışlı olduğunu göstermektedir.

Goyal ve ark. (2014) tarafından Hindistan'ın Karso Havzası'nda yapılan çalışmada, (2000-2010 yılları arasındaki 3801 günlük kayıt) günlük tava buharlaşması miktarı için YSA, en küçük kareler- destek vektörü regresyonu (LS-SVR), BM ve ANFIS modellerinden faydalanılarak veriler test edilmiştir. Kullanılan meteorolojik parametreler ise, minimum ve maksimum hava sıcaklığı, minimum ve maksimum nem, güneşli saatler ve günlük yağış gözlemlerinden oluşmaktadır. Bayes Düzenlemesi (BR), İleri Beslemeli Geri Yayılım (FFBP) modelleri ile Levenberg-Marquardt (LM) algoritmasından da faydalanılmıştır. YSA, LSSVR, BM ve ANFIS modelleri, ampirik Hargreaves-Samani ve Stephen-Stewart ampirik denklemleri ile de karşılaştırılmıştır. Çeşitli modellerin doğruluğunu istatistiksel olarak değerlendirmek için karekök ortalama karesel hata (RMSE) ve korelasyon katsayısı (CORR) performans kriterleri kullanılmıştır. Bu karşılaştırmalara dayanarak mevcut iklim verilerindeki günlük

buharlařma s¼recinde BM mantık ve LS-SVR yaklařımlarının modellemede bařarılı bir Őekilde kullanılabilceđi bulunmuřtur.

Shiri ve ark. (2014), Amerika’da yaptıkları alıřmalarında buharlařma tahmini yapmak iin 6 farklı istasyona ait g¼nl¼k iklimsel verilerden faydalanmıřlardır. Gen Ekspresyon Programlama (GEP) modelini kullandıkları alıřmalarında, konuma ve zamana bađlı veri tarama teknikleri ile beraber buharlařma tahmininde bu modelin bařarı oranını deđerlendirmiřlerdir. Ortaya ıkan g¼nl¼k buharlařma tahminlerini ampirik fiziksel model sonuları ile karřılařtırmıřlar ve GEP modelinin daha bařarılı olduđunu belirtmiřlerdir.

elik ve Baynal (2015), sıcaklık tahmin modelini oluřturabilmek iin ilk olarak, sıcaklıđı etkileyen sekiz parametreye, ok kriterli karar verme y¼ntemlerinden AHP y¼ntemi ve kullanılan kriterlerin birbirleri ile olan iliřkilerinin derecesinin tespitinde kullanılan DEMATEL tekniklerini uygulayarak sıcaklık ¼zerindeki etkili olan sekiz ana parametrenin etkinlik sıralamasını tespit etmiřtir. Bu etkinlik sıralaması sonularına g¼re sıcaklıđa en ok etki eden d¼rt parametre dikkate alınarak Subtractive Clustering ANFIS modeli kullanılarak sıcaklık tahmini yapılmıřtır.

Kiři ve Parmar (2016), yaptıkları alıřmada nehir suyu kirliliđinin tespiti iin en k¼¼k kareli destek vekt¼r makinesi (LSSVM), ok deđiřkenli uyarlanabilir regresyon spline (MARS) ve M5 model ađacı (M5-Tree) tekniklerinden faydalanmıřlardır. Hindistan sınırları ierisinde bulunan Nizamuddin’deki Delhi Yamuna Nehri’nden faydalanılan alıřmada serbest amonyak (AMM), toplam kjeldahl azotu (TKN), su sıcaklıđı (WT), toplam koliform (TC), fecal koliform (FC) ve hidrojen potansiyeli (pH) gibi eřitli su kalitesi parametrelerinin kombinasyonları, uygulanan modellerin girdileri olarak kullanılmıřtır. Bu kombinasyonlar, aylık nehir suyu kirliliđi seviyesinin tahmininde AMM, TKN ve WT parametrelerinin girdi olarak kullanıldıđı durumlarda MARS ve LSSVM modellerinin bařarıyla kullanılabilceđi sonucunu ortaya ıkarmıřtır.

Kaya (2016) tarafından yapılan alıřmada, hidrolojik evrimin en temel bileřenlerinden biri olan buharlařma, ANFIS ve MLR y¼ntemleri kullanılarak modellenmiřtir. 2287 g¼nl¼k buharlařma, solar radyasyon, hava sıcaklıđı, bađlı nem ve r¼zg¼r hızı parametrelerini kapsayan veri k¼meleri belli oranlarda eđitim ve test k¼mesi olarak ayrılmıřtır. Amerika Birleřik Devletleri Florida eyaletinde bulunan De Soto Country istasyonuna ait verilerin kullanıldıđı arařtırmada ANFIS, MLR ve amprik denklemlerin karřılařtırılmasında determinasyon katsayısı (R), ortalama mutlak hata (OMH), ortalama karesel hata (OKH) istatistikleri kullanılmıřtır. alıřma sonucunda ise

tüm parametreleri girdi olarak kullanan kombinasyona ait ANFIS sonuçlarının, hem MLR hem de ampirik denklemlerden daha iyi performans gösterdiği belirlenmiştir.

Mehdizadeh ve ark. (2017), İran'da yaptıkları çalışmada aylık ortalama referans evapotranspirasyon miktarının ( $ET_0$ ) tahmini için, meteorolojik parametrelere dayalı 16 ampirik denklem, GEP, DVM-Polinom (DVM-Poly) ve DVM-Radyal Tabanlı Fonksiyon (DVM-RBF) olmak üzere iki tip DVM ve Çok Değişkenli Adaptif Regresyon Spline (MARS) metotlarının performansını araştırmıştır. Bu amaç için İran'daki 44 istasyonun aylık ortalama verileri kullanılmıştır. Ampirik denklemlerin ve yapay zeka yöntemlerinin uygulanmasında, kalibrasyon / eğitim adımı için verilerin % 50'si (22 istasyon) ve doğrulama / test aşaması için verilerin kalan % 50'si (22 istasyon) kullanılmıştır. İlk olarak, 16 ampirik denklem FAO-56 Penman-Monteith yöntemine göre (standart yöntem olarak) yerel olarak kalibre edilmiştir. Sonuçlar, kalibrasyon sürecinin, orijinal formlarına kıyasla denklemlerin performansını geliştirdiğini ortaya çıkarmıştır. Daha sonra GEP, DVM-Poly, DVM-RBF ve MARS modellerinin performansı aylık ortalama  $ET_0$ 'ın tahmini için değerlendirilmiştir. Model girdilerinin seçimi, ampirik denklemlerde kullanılan parametrelere dayanılarak yapılmıştır. MARS ve DVM-RBF yöntemlerinin genellikle GEP ve DVM-Poly'dan daha iyi performans gösterdiği bulunmuştur. Çalışmanın sonunda, ampirik denklemlerin ve yapay zeka yöntemlerinin doğruluğu karşılaştırılmış ve genel olarak, aylık  $ET_0$  tahmininde MARS ve DVM-RBF'nin performansının kullanılan ampirik denklemlerden daha iyi olduğu sonucu elde edilmiştir.

Büyük yıldız ve ark. (2014) tarafından Parçacık Sürü Optimizasyon Tabanlı Yapay Sinir Ağları (PSO-YSA), Destek Vektör Regresyonu (DVR), Çok Katmanlı Yapay Sinir Ağları (MLP), Radyal Tabanlı Sinir Ağları (RBNN) ve ANFIS olmak üzere beş farklı yapay zeka metodu kullanılarak Beyşehir Gölü aylık su seviyesi değişimi tahmin edilmiştir. Su seviyesi değişimi (L) tahmininde, aylık giren akım -kayıp akım (I), yağış (P), buharlaşma (E) ve çekilen akım (O) değerlerinden oluşan farklı input kombinasyonları kullanılmıştır. Elde edilen model sonuçlarına göre, Beyşehir Gölü aylık su seviyesi tahmininde  $\epsilon$ -DVR modeli en başarılı model olarak elde edilmiştir.

Zhao ve Wang (2010), Çinde Guangxi'deki 1954-2008 periyodundaki aylık yağış verilerini kullanarak yağış miktarını tahmin etmek için, DVR modelinin parametrelerinin belirlenmesinde PSO algoritmasını kullanmış ve elde ettiği sonuçları klasik DVR metodu ile karşılaştırmıştır.


Sudheer ve ark. (2014) akım tahmini yapmak üzere, Clark Fork yakınındaki St. Regis River ve Bigfork yakınındaki Swan Nehri aylık akım datalarına PSO-DVM modelini uygulamış ve elde edilen sonuçları YSA ve Otoresif Hareketli Ortalama (ARMA) modellerinin sonuçları ile karşılaştırmışlardır.

Mohandes (2012) Suudi Arabistan'da bulunan 41 istasyonun verileri kullanarak global solar radiation tahmini yaptığı çalışmasında PSO-YSA modelini kullanmış. sonuçları Back-Propagation (BP) algoritmasının performansıyla karşılaştırmıştır.




### 3. BUHARLAŞMA

Doğada farklı yer ve hallerde bulunan su, yerküresinin farklı kısımlarında sürekli bir dönüşüm halinde olup suyun doğada izlediği bu yolların bütünü hidrolojik çevrim olarak adlandırılmaktadır (Şekil 3.1). Hidrolojik çevrimin en önemli parametrelerinden birini ise buharlaşma oluşturmaktadır.



Şekil 3.1. Buharlaşma ve hidrolojik çevrim (<http://www.dsi.gov.tr/toprak-ve-su-kaynaklari>)

Hidrolojik çevriminin önemli elemanlarından birini içeren buharlaşma, Uluslararası Hidroloji Sözlüğü'ne (WMO, 2012) göre “suyun kaynama noktası altındaki sıcaklıklarda sıvı halden gaz haline geçişi” olarak tanımlanmaktadır. Su yüzeylerinden gerçekleşen buharlaşmaya ise evaporasyon denmektedir. Su yüzeyinde bulunan moleküller yeterli bir kinetik enerji kazandıkları zaman kendilerini tutmaya çalışır ve diğer moleküllerin etkisinden kurtularak buldukları ortamdan havaya fırlarlar. Su yüzeyi yakınlarında sürekli olarak havadan suya, sudan havaya geçen moleküller gözlenir. Sudan havaya geçen moleküllerin sayısının daha çok olması durumunda ise buharlaşma olduğu sonucuna varılır (Şekil 3.2).




Şekil 3.2. Su yüzeyinden buharlaşma olayı (Bayazıt, 1999)

Buhar halinde atmosferde bulunan su yoğunlaşma sonucu yeniden yeryüzüne düşer. Yeryüzüne düşen yağışın karalar üzerine düşen yaklaşık %60 - %75'i kadar büyük bir kısmı zeminden ve su yüzeylerinden buharlaşma (evaporasyon), aynı zamanda bitkilerden terleme (transpirasyon) yoluyla yeniden atmosfere dönerken, bir kısmı zeminden süzülerek yeraltına geçer. Düşen yağışın bir kısmı da bitkiler tarafından tutulur (tutma), kalan kısım ise akarsulara ve akarsular yardımı ile denizlere ulaşır (yüzeysel akış). Denizlere ulaşan su buharlaşmak suretiyle tekrar atmosfere geri döner (Terzi, 2004).

Yıllık toplam yağış miktarı yaklaşık 501 milyar m<sup>3</sup> olan ülkemizde, bu yağışın 274 milyar m<sup>3</sup>'ü buharlaşarak atmosfere geri dönmektedir. Yani düşen yağışın yaklaşık yarısı buharlaşma yoluyla kaybolduğu için herhangi bir şekilde yararlanılamamaktadır. Bu durum göz önünde bulundurulduğunda ve küresel iklim değişikliğinin özellikle su kaynakları üzerindeki olumsuz etkileri dikkate alındığında, buharlaşma kayıplarının azaltılması, tüm dünya için olduğu gibi ülkemiz için de oldukça önemlidir. Buharlaşmanın etkin olarak azaltılabilmesi için öncelikle buharlaşmayı etkileyen meteorolojik faktörlerin ve bunların buharlaşmayı ne doğrultuda etkilediklerinin anlaşılması önemlidir.

Şekil 3.3'de Türkiye'nin 1981-2010 yılları arasındaki yıllık referans toplam buharlaşma haritası görülmektedir.



**Şekil 3.3.** Türkiye'nin 1981-2010 yılları arasındaki yıllık referans toplam buharlaşma normal haritası

(<https://www.mgm.gov.tr/tarim/referans-toplam-buharlasma.aspx>)



### 3.1. Buharlaşmayı Etkileyen Faktörler

Suyun ve havanın sıcaklığı, nem, hava hareketi (rüzgar), hava basıncı, buhar basıncı farkları, güneş radyasyonu ve ortamın mevcut enerjisi gibi meteorolojik faktörlerle, su yüzey alanı, derinlik, buharlaşan yüzeyin kalitesi, ayrıca enlem, yükseklik, bakı gibi coğrafik ve topoğrafik faktörler olan meteorolojik olmayan faktörler buharlaşmanın artmasına veya azalmasına neden olmaktadır.

**Buhar basıncı farkı:** Su yüzeyindeki buhar basıncı ( $e_s$ ) ile su üzerindeki havanın buhar basıncı ( $e_a$ ) arasındaki fark Dalton Kanunu'na göre buharlaşma ile orantılıdır. Bu nedenle su sıcaklığı arttıkça molekül hızı artacağından yüzeysel gerilim azalır ve buharlaşma daha kolay bir hale gelir.

**Enerji:** Su molekülleri hızlarını artırıp buharlaşabilmek için enerjiye ihtiyaç duyarlar. 1 gram suyun buharlaşabilmesi için gerekli ısı, bulunduğu yerin sıcaklık derecesine göre 539-597 kalori arasında değişmektedir. Buharlaşmanın olabilmesi için hızlarını artırma ihtiyacı duyan su molekülleri ise bu enerjiyi, doğrudan güneşten gelen ışınlarla ya da karalarda rüzgârla çevreden taşınan ısı enerjisi ile karşılarlar.

**Nisbi nem:** Havada mevcut olan nem miktarının fazla oluşu, yüksek oranda su buharı taşıma gücünün önüne geçmektedir. Bu duruma bağlı olarak buharlaşma olayı azalır.

**Sıcaklık:** Doymuş buhar basıncı sıcaklığa bağlı olduğundan buharlaşma oranı, hava ve su sıcaklıklarından büyük oranda etkilenmektedir. Buharlaşmanın günlük ve yıllık değişimleri, sıcaklığın günlük ve yıllık değişmelerine çok benzer. Sıcak havada buharlaşma için gerekli enerji var olduğundan, soğuk havaya göre daha fazla buharlaşma meydana gelir. Yani, sıcaklıkla ilgili olarak buharlaşma, soğuk mevsimde az ve sıcak mevsimde fazla olacak şekilde süregelen bir olaydır. Gün esnasında buharlaşma sabah saatlerinde minimum, öğleden sonra 12:00- 15:00 saatleri arasında ise maksimum değerine ulaşır.

**Rüzgâr:** Buharlaşmanın sürekliliği için, su buharının difüzyon ve konveksiyon ile su yüzeyinden uzaklaşması gerekmektedir. Bu durum havanın hareketi, yani rüzgarlar ile mümkündür. Rüzgâr hızı ne kadar fazla olur ise buharlaşma o oranda artar.

**Enlem:** Enleme bağı olarak yüzeylerin farklı oranda güneş radyasyonuna maruz kalıyor olması, serbest yüzeylerdeki buharlaşma oranının birbirinden farklı olmasına neden olmaktadır.

**Baki:** Buharlaşma, kuzey ve doğuya bakan yamaçlara göre güneye ve batıya bakan yamaçlarda daha fazla olur. Çünkü bu kısımlarda sular güneş ışınlarına daha çok maruz kalırlar.

**Yükseklik:** Buharlaşma miktarı diğer faktörler değişmediği takdirde yükseklik arttıkça artar. Çünkü yükseklik arttıkça hava basıncı azalır. Diğer taraftan yine yükseldikçe havanın sıcaklığı azalacağından buharlaşma miktarı da azalır. Fakat bu azalma hava basıncından ileri gelen çoğalmayı telafi edemediğinden yükseldikçe buharlaşmanın düşük oranda arttığı kabul edilir.

**Suda erimiş tuzlar ve yüzeyindeki kimyasal maddeler:** Suda eriyen tuzlar ve kimyasal maddeler buhar basıncını azaltacağından buharlaşma miktarını düşürürler.

**Su kütlesinin büyüklüğü:** Hava sıcaklığındaki değişimlerden derin su kütleleri daha geç etkilenir. Bu sebeple derin sularda meydana gelen buharlaşma, sığ su kütlelerinde meydana gelen buharlaşmaya göre yaz mevsiminde daha az, kış mevsiminde ise daha çok olmaktadır.

### 3.2. Buharlaşma Türleri ve Buharlaşma Miktarının Belirlenmesi

Buharlaşmanın meydana geldiği yüzeylerden ise şu şekilde bahsetmek mümkündür.

**Zemin ve Kar Yüzeyinde Buharlaşma:** Zemin yüzeyinde meydana gelen buharlaşma su yüzeyinde oluşan buharlaşmaya benzer. Zemin geçirimsizliğinin az olması halinde su molekülleri buharlaşma için daha fazla dirence maruz kalırlar. Zeminin üst kısmında yeterli oranda su bulunması durumunda ise zemin yüzeyinde meydana gelen buharlaşma miktarı su yüzeyindeki buharlaşma miktarına yakın olur. Yer altı su seviyesinin yüzeyden itibaren 1-3 m'den aşağıda olması halinde buharlaşma ihmal edilebilecek seviyelere düşer.

Buharlařma kar yzeyinden de gerekleřebilir. Sblimasyon olayı adı verilen kar ve buzun dođrudan buhar haline geebilmesi olayının gerekleřebilmesi iin kar yzeyinin sıcaklıđının, havanın iđleřme noktası sıcaklıđından fazla olması gerekir. ok rzgarlı havalarda kar yzeyinden buharlařma miktarı ise gnde en fazla 5 mm'ye kadar ıkabilmekle beraber aylık en fazla 20-30 mm'ye ulařabilmektedir. Bu deđer aynı Őartlarda su yzeyinde meydana gelen buharlařmanın %20 ile %25'i kadardır (Bayazıt,1999).

**Terleme ve Tutma:** Bitkilerin kkleriyle suyu zeminden alıp, yařamaları iin gerekli iřlemlerde faydalandıktan sonra yapraklarından buhar halinde havaya vermeleri olayına terleme (transpirasyon) denir. Terleme, bitkilerin bymesi ile ilgili olduđu iin sadece byme mevsiminde ve gndz saatlerinde grlen bir olaydır. Bitkiler topraktan kkleri ile aldıkları suyun ok kk bir kısmını fotosentez iin ilerinde tutarlar ve geride kalan byk kısmını ise kullandıktan sonra atmosfere geri verirler. Bitki cinsine gre terleme kaybı gnde 0.1 ile 7 mm arasında deđiřmektedir.

Bir bitkinin bymesi sırasında terlediđi suyun ađırlıđının, kkleri hari kendi ađırlıđına oranına terleme oranı adı verilir. Bu oran bitkinin cinsine, bulunduđu zemine ve iklime gre deđiřiklik gsterir. rneđin iđne yapraklı ađalar iin 100-200 arasında deđiřen bu oran, diđer ađalarda 1000'e kadar ıkabilmektedir. Aynı durum tarım bitkilerinde ise 200-2000 arasında deđerler alabilmektedir.

Bitkiler ayrıca tutma Őeklinde de buharlařma kayıpları zerinde etkili olmaktadır. Tutma ise yer yzeyine hi varamayan ve bitkiler tarafından alıkonan yađıř olarak tanımlanmaktadır. Tutma kayıpları zellikle yađıř Őiddetinin az, sresinin kısa olduđu ve bitki rtsnn sık olması durumunda daha nemlidir. Tutma kapasitesi iđne yapraklı ađalarda daha fazla olmasıyla birlikte bitki cinsine gre 0.7-3 mm arasında deđiřerek farklılık gsterir. İđne yapraklı ađalar zerlerine dřen yađıřın yıllık % 25-30'unu, yaprak dken ađalar ise % 10-15'ini tutarlar. Ormanlık blgelerde ise tutma kaybı yıllık yađıřın 1/3 oranına ulařabilir (Bayazıt,1999).

**Evapotranspirasyon (Buharlařma-Terleme):** Bir blgede terlemeyle birlikte zeminden, su ve kar yzeylerinden buharlařma ile meydana gelen toplam su kayıplarının tamamına evapotranspirasyon (ET) kayıpları denir. Evapotranspirasyon kayıplarının potansiyel ve gerek deđerleri arasında bir ayırım yapmak gereklidir. Yeterli miktarda zemin nemi bulunması halinde meydana gelecek kayba potansiyel

evapotranspirasyon adını vermek mümkündür. Ancak toprakta her zaman evapotranspirasyon değerinin maksimum olacağı nem mevcut olmayabilir. Bu nedenle var olan nem oranında evapotranspirasyon kaybı olur ve elde edilen bu değer gerçek evapotranspirasyon olarak tanımlanabilir. Zemin kuruma noktasına geldiğinde ise gerçek evapotranspirasyon sona erer.

Gerçek evapotranspirasyon miktarı üzerinde zeminin nemi, bitki örtüsü ve bitkilerin gelişme durumu etkili olduğu için belirlenmesi oldukça güçtür. Evapotranspirasyon miktarı, bitkilerin köklerinin yer altı suyuna kadar inmemesi halinde zeminden alınan numunelerin neminde zamanla meydana gelen değişmelerini ölçmek suretiyle belirlenebilir.

Diğer bir ölçme metodu ise lizimetre denen 0.1-1 m çapında, 1-2 m kadar derinlikte toprakla dolu kaplarda istenen bitkilerin yetiştirilip yağışları, sızma kayıplarını ve kabın ağırlığında meydana gelen değişmeyi ölçerek, su dengesi metoduyla evapotranspirasyon miktarını bulmaya dayanmaktadır.

***Su Yüzeyinden Buharlaşma:*** Serbest su yüzeyinden bir günde meydana gelen buharlaşma miktarı, meteorolojik şartlara bağlı olarak 1-10 mm arasında değişmektedir. Su yüzeylerinden (nehirler, göller, barajlar) meydana gelecek buharlaşma miktarının belirlenmesi ve buharlaşma kayıplarının azaltılması, özellikle su kaynaklarının planlanması ve işletilmesinde oldukça önemlidir. Ancak etkili pek çok faktör nedeniyle oldukça karmaşık bir mekanizması olan buharlaşmanın miktarının belirlenmesi oldukça güçtür.

Buharlaşma tavaşı adı verilen (Evaporimetre) metal kapları kullanmak, serbest su yüzeyinden buharlaşmayı belirlemenin en iyi yoludur. Birçok çeşidi bulunan buharlaşma tavaşları içinde, Türkiye dâhil birçok ülkede en çok tercih edilen buharlaşma tavaşı tipi ise A sınıfı buharlaşma tavaşlarıdır (A-Class Pan) (Şekil 3.4).

Çapı 122 cm, derinliği 25 cm olan A sınıfı buharlaşma tavaşlarının içi 20 cm derinlikte su ile doldurulur ve bir Limnimetre ile su yüzeyinde meydana gelen alçalma miktarı ölçülerek buharlaşma miktarı belirlenir. Yağışlı günlerde yapılan ölçümlerde ise yağış yüksekliği de ayrıca ölçülerek hesaba ilave edilir. Buharlaşma tavaşı, yerden 15 cm yükseğe yerleştirilirken, tavanın üst kenarı ile su yüzeyi arasındaki uzaklık 5-8 cm arasında kalacak şekilde her gün su eklenir (Bayazit, 1999).



Şekil 3.4. A Sınıfı Buharlaşma Tavasası

Fakat yapılan çalışmalarda elde edilen tava buharlaşma miktarı büyük su kütleindeki (bir hazne, bir göl, bir baraj vb.) buharlaşma miktarlarını tam olarak temsil edemez. Bunun ana sebebini tavadaki suyun kütleinin az olması ve bundan kaynaklanan hava sıcaklığındaki değişimlerden daha hızlı etkileniyor olması oluşturur.

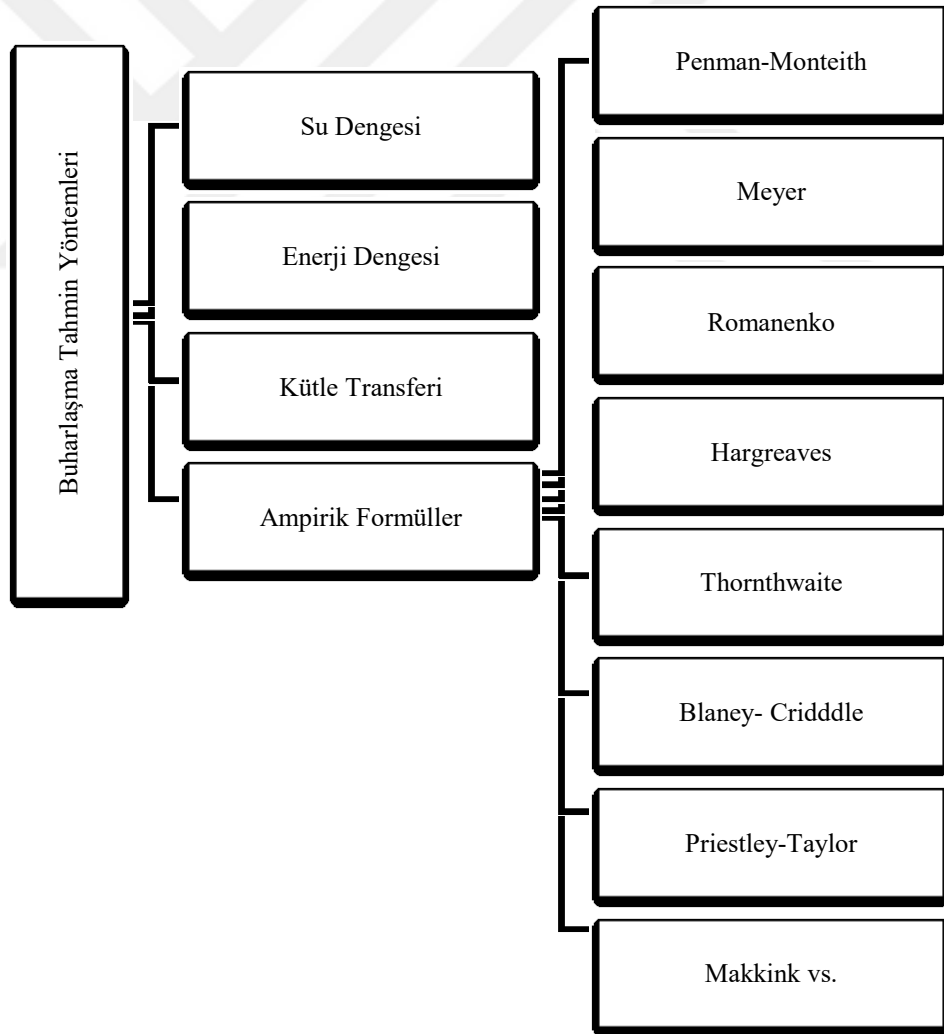
Bu durumla birlikte tavanın ısı yansımaları, tava civarında oluşan ısı alışverişi ve çevrenin az nemli oluşu da buharlaşma için diğer etkenlerdir. Aradaki farkı azaltmak için çeşitli tedbirler düşünülmüş ve BPI tavaş, Young tavaş gibi farklı tava tipleri kullanılmıştır. Bunların dışında tavaşın üst kısmına kadar toprağa gömmek ya da su üzerinde yüzdürmek gibi çözüm yöntemleri de uygulanmıştır. Bu gibi tavaşların buharlaşma miktarı büyük göllerdekine daha yakın olsa da elde edilen sonuçlar kararlı olmamaktadır. Bunun için en çok denenmiş olan A sınıfı buharlaşma tavaşının kullanılması ve devamında tavadaki okunan değerin tava katsayısı ile çarpılarak göldeki buharlaşma miktarına geçmek tavsiye edilmektedir (Bayazıt,1999).

A sınıfı buharlaşma tavaş ile belirlenen buharlaşmanın sonucunu, referans bitki su tüketimini ( $ET_0$ ) tahmin etmek için uyarlanan kap katsayısı ( $k_p$ ) ile çarpılırsa  $ET_0$  tahmin edilebilmektedir. Açık bir su yüzeyinden olan buharlaşma miktarını bulmak için uyarlanan kap katsayısı ( $k_p$ ) 0,60 ile 0,80 arasında değişmektedir. Katsayının 0,7 kabul edilmesi halinde hata payının %15'in altında olduğu düşünülmektedir (Jacobs vd., 1998). Bu aralık değerler kap yüzey özellikleri ve kaptan olan buharlaşma miktarı ile ilgilidir (Doorenbos ve Pruitt, 1975; Apan, 1982).  $ET_0$  miktarını bulmak için uyarlanan  $k_p$  ise mevcut alan ve hava koşullarına bağlı olarak değişmektedir (Allen ve ark., 1998; Doorenbos ve Pruitt, 1977). Bu anlamda, açık su yüzeyinden olan buharlaşma veya referans bitki su tüketimi  $ET_0 = E_{pan} \times k_p$  eşitliği ile hesaplanmaktadır. Burada;  $ET_0$ : açık

yüzeyden su buharlaşması ya da referans bitki su tüketimi (mm),  $E_{pan}$ : tava buharlaşması (mm),  $k_p$ : tava katsayısıdır.

Tava katsayısı aylık buharlaşma hesabında ise daha geniş değerler arasında değişirken mevsime göre farklı değerler kullanılır. Örneğin sonbaharda yüksek değerler kullanılırken ilkbaharda daha düşük değerler kullanılmaktadır. Türkiye’de buharlaşma ölçümleri D.M.İ ve D.S.İ. tarafından yapılmakta, ölçümlerde ıslak filtre kâğıdından buharlaşmayı dönen şerit üzerine kaydeden ölçeklerle birlikte standart tavalara benzer sonuçlar veren yazıcı ölçekler de (Evaporograf) kullanılmaktadır (Bayazıt,1999).

Zemin ve su yüzeyinde meydana gelen buharlaşma miktarının, lizimetre, buharlaşma tavaşı gibi doğrudan ölçülmesinin yanı sıra, meteorolojik parametrelere bağlı olarak kullanılan ve buharlaşma miktarının dolaylı olarak belirlenmesini sağlayan buharlaşma tahmin yöntemleri de bulunmaktadır (Şekil 3.5).



Şekil 3.5. Buharlaşma tahmin yöntemleri

Buharlaşmanın doğrudan ölçülmesi uzun bir zaman periyodu ile birlikte aşırı miktarda işgücü ve masraf gerektirirken, dolaylı yöntemler doğrudan ölçümlere oranla daha basit, daha hızlı ve bu nedenle daha uygulanabilir metotlardır. Ancak, iklim ve buharlaşma arasındaki fonksiyonel ilişkiye dayalı deneysel metotlar, ilişkilerin geliştirildiği şartlardan daha farklı şartlarda uygulandığında problemler ortaya çıkmaktadır.

**Su dengesi metodu:** Bir su kütesine (hazne, baraj, göl vs.) belli bir zaman dilimi için süreklilik denklemi uygulanırsa buharlaşma Eşitlik 3.1 ile elde edilir.

$$E = P + X - Y - F - \Delta S \quad (3.1)$$

Burada;

E: Buharlaşma miktarı

P: Yağış

X: Giren akış miktarı

Y: Çıkan akış miktarı

F: Yeraltına sızan su miktarı

$\Delta S$ : Kütlelenin hacimdeki değişme miktarıdır.

**Enerji dengesi metodu:** Bu yöntem, güneş ışığı ile yeryüzüne gelen ısı enerjisinin; su kütesinin sıcaklığını arttıran, buharlaşma için harcanan, iletim ve yansıma yoluyla atmosfere dönen ve su kütesinden dışarı çıkan ısı enerjilerinin toplamına eşit olduğu prensibine dayandırılmaktadır. Enerjinin korunumu ilkesi bir su kütesine (hazne, göl gibi) uygulanırsa,

$$H_e = H_i - H_o - H_c - \Delta H \quad (3.2)$$

elde edilir. Burada;

$H_i$ : Güneş ısısı ile kütleye giren akımların getirdiği ısının toplamı

$H_o$ : Kütlelenin çıkan akımların ısısı ile yansıyan ısının toplamı

$H_c$ : Su yüzeyinden atmosfere kondüksiyonla kaybolan ısı

$H_e$ : Buharlaşmada kullanılan enerji

$\Delta H$ : Su kütesinin sıcaklığındaki değişme için gerekli ısıdır.

$$H_c = R \times H_e \quad (3.3)$$

Burada R Bowen oranı adını almaktadır ve aşağıdaki şekilde hesaplanır:

$$R = 6 \cdot 10^{-4} \chi P_0 \left( \frac{T_w - T_a}{e_w - e_a} \right) \quad (3.4)$$

Bu denkleme göre:

$P_0$ : Atmosfer basıncı ( kg/ cm<sup>2</sup>)

$T_w$ : Su sıcaklığı (°C)

$T_a$ : Hava sıcaklığı (°C)

$e_w$ : Su basıncı ( kg/ cm<sup>2</sup>)

$e_a$ : Hava basıncı ( kg/ cm<sup>2</sup>)

Bowen oranının değeri 0.2 ile 0.3 arasında kalmaktadır.

Buharlaşma için gereken enerji, L suyun buharlaşma ısısı ve E buharlaşan suyun hacmi olmak üzere şu şekilde hesap edilir:

$$H_e = L \times E \quad (3.5)$$

L değeri normal atmosfer basıncında 590 kal/cm<sup>3</sup> olarak alınabilir. Bu ifadeler denklem 3.2'de yerine konulduğunda:

$$E = \frac{H_i - H_0 - \Delta H}{L(1 + R)} \quad (3.6)$$

elde edilir.

**Kütle transferi metodu:** Sınır tabakası teorisinin, türbülans karışım uzunluğunun ve türbülanslı difüzyon kavramlarının kullanılmasıyla, su moleküllerinin su yüzeyinden havaya iletilmesi olayı için yapılan teorik hesaplar sonucunda su yüzeyinden iki farklı yükseklikte ölçülen nem, sıcaklık ve rüzgar hızı cinsinden buharlaşma miktarını veren formüller ileri sürülmüştür. Eşitlik 3.7'de verilen Thorntwaite-Holzman denklemi buna bir örnektir (Bayazıt, 1999).

$$E = \frac{K(e_1 - e_2)(w_1 - w_2)}{T \cdot \ln\left(\frac{z_2}{z_1}\right)^2} \quad (3.7)$$



Bu denkleme göre:

E: Saatlik buharlaşma miktarı (mm)

K: Bir sabit

T: Havanın ortalama sıcaklığı (°C)

$w_1$  ve  $w_2$ :  $z_1$  ve  $z_2$  yüksekliklerindeki rüzgar hızı (km/saat)

$e_1$  ve  $e_2$ :  $z_1$  ve  $z_2$  yükseklikte havanın buhar basıncı (mmHg)

Bu çalışmada aylık buharlaşma tahmininde, Meyer, Romanenko, Priestley-Taylor, FAO-Penman- Monteith ampirik denklemleri kullanılmış olup bu denklemlerle ilgili açıklamalar Bölüm 4.5’de verilmiştir.

## 4. MATERYAL VE YÖNTEM

### 4.1. Çalışma Alanı ve Data

Bu çalışmada, Türkiye'nin en büyük ve en kurak kapalı havzalarından biri olan Konya Kapalı Havzası'nda bulunan ve Konya Meteoroloji Bölge Müdürlüğü tarafından işletilen Konya, Karaman ve Aksaray meteoroloji istasyonlarının verileri kullanılarak aylık açık yüzey buharlaşma (E) tahmini yapılmıştır. Bu amaç için üç istasyona ait, aylık toplam yağış (P), ortalama sıcaklık ( $T_{ort}$ ), minimum sıcaklık ( $T_{min}$ ), maksimum sıcaklık ( $T_{mak}$ ), ortalama rüzgâr hızı (WS), ortalama nispi nem (RH), ortalama buhar basıncı (VP), ortalama atmosferik basınç (AP) ve buharlaşma (E) verileri kullanılmıştır. Buharlaşma miktarının hesaplanması için çalışma kapsamında kullanılan meteoroloji istasyonlarına ait bazı özellikler Çizelge 4.1'de, istasyonların Türkiye'deki konumları ise Şekil 4.1'de verilmiştir.

Çizelge 4.1. Konya, Karaman ve Aksaray meteoroloji istasyonlarına ait bazı özellikler

İstasyon Adı	İstasyon No	Enlem	Boylam	Rakım	Gözlem Periyodu
<b>Konya</b>	17244	37.52	32.29	1031	1960-2006
<b>Karaman</b>	17246	37.11	33.13	1025	1967-2010
<b>Aksaray</b>	17192	38.23	34.05	965	1973-2010



Şekil 4.1. Kullanılan istasyonların Türkiye'deki konumları





31 ilçeden oluşmakta, bu ilçelerin 22 adedine bağlı bölgeler havza içerisinde yer almakta ve havza içerisinde 2.810.988 ha alan ile, il alanının havzaya giren kısmının %73'ünü oluşturmaktadır. İl de kışın soğuk, yazın ise sıcak ve kurak geçen karasal iklim hâkimdir (Anonim, 2010). Konya istasyonuna ait meteorolojik parametrelerinin bazı istatistiksel özellikleri Çizelge 4.2'de verilmiştir.

**Çizelge 4.2.** Konya istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri

Parametre	Ortalama	Maksimum	Minimum	Standart Sapma
P (mm)	22.60	144.1	0	23.97
WS (m/s)	2.34	6	1	0.93
RH (%)	50.85	75.5	27.6	9.29
VP (hPa)	9.94	15.4	4.8	1.96
AP (hPa)	897.46	904	893.8	2.09
T <sub>ort</sub> (°C)	17.66	26.8	6.9	4.72
T <sub>min</sub> (°C)	4.82	14.8	-8.6	5.13
T <sub>max</sub> (°C)	31.26	40.6	20.8	3.95
E (mm)	182.40	428	4	78.26

**Karaman İli;** İç Anadolu Bölgesi'nin güneyinde yer almakta ve 3 ilçesi Konya Kapalı Havzası içerisinde bulunmaktadır. Bu 3 ilçe, havza içerisinde 572.688 ha alan ile il alanının havzaya giren kısmının %60'ını oluşturmaktadır. İlde karasal iklim hâkimdir. Bu nedenle yazlar sıcak ve kurak geçmektedir. Yağış miktarının 2.8 - 6.4 mm'ye kadar düştüğü gözlenir (Anonim, 2010). Karaman istasyonuna ait meteorolojik parametrelerinin bazı istatistiksel özellikleri Çizelge 4.3'de verilmiştir

**Çizelge 4.3.** Karaman istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri

Parametre	Ortalama	Maksimum	Minimum	Standart Sapma
P (mm)	20.31	144.1	0	22.99
WS (m/s)	2.31	3.8	1.4	0.40
RH (%)	52.52	71.5	33.1	7.87
VP (hPa)	10.42	15.8	5.8	2.02
AP (hPa)	898.73	904	894.6	2.00
T <sub>ort</sub> (°C)	17.96	27	8	4.64
T <sub>min</sub> (°C)	4.35	15	-8.5	5.15
T <sub>max</sub> (°C)	31.96	40.4	20.8	4.14
E (mm)	182.49	404.6	65.7	62.84

**Aksaray İli;** Orta Anadolu'nun ortasında yer alan ilin, 4 ilçesi Konya Kapalı Havzası içerisinde bulunmakta olup 682.879 ha alan ile il alanının havzaya giren kısmının %85'ini oluşturmaktadır. İl orta iklim kuşağında yer aldığı için yazları sıcak ve kurak, kışları ise soğuktur. Bu nedenle karasal iklim tipine sahiptir. Yaz, kış mevsimlerinde, gece ve gündüz sıcaklık farkları oldukça fazladır (Anonim, 2010).

Aksaray istasyonuna ait P, WS, RH, VP, AP,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$  ve E parametrelerinin ortalama, maksimum, minimum, standart sapma değerleri ise Çizelge 4.4'deki gibidir.

**Çizelge 4.4.** Aksaray istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri


Paramtre	Ortalama	Maksimum	Minimum	Standart Sapma
P (mm)	23.10	101.4	0	24.22
WS (m/s)	2.60	3.8	1.7	0.39
RH (%)	51.67	72.5	32.3	7.38
VP (hPa)	10.52	15.4	6.2	2.14
AP (hPa)	904.27	910.1	899.8	2.11
$T_{ort}$ ( $^{\circ}$ C)	18.12	27.3	7.9	4.65
$T_{min}$ ( $^{\circ}$ C)	5.21	15	-7.5	4.96
$T_{max}$ ( $^{\circ}$ C)	31.72	40	22.2	3.84
E (mm)	196.62	379.7	69.2	69.93

## 4.2. Yapay Sinir Ağları (YSA)

Son yıllarda teknolojinin hızlı bir şekilde gelişmesi insan hayatına önemli derecede katkılarda bulunmaya başlamıştır. Özellikle bilgisayar ve bilgisayar programlama yöntemlerindeki gelişmeler insan yaşamına hız, zaman, bilgiye en kısa zamanda ve doğruya en yakın şekilde ulaşma gibi önemli konularda yardımcı olmaktadır.

Basit biyolojik sinir sistemi esas alınarak yapılan programda, taklit edilen sinir hücreleri ve bu hücrelerin çeşitli şekillerde birbirlerine bağlanması ile oluşan ağlar bulunmaktadır. Ağlar sayesinde; öğrenme, veriler arasındaki ilişkiyi ortaya çıkarma ve hafızaya alma gibi yetiler sağlanmaktadır. Bir başka deyişle, YSA bir insanın düşünme ve gözleme gibi doğal yetilerini oluşturan problemlere çözüm sağlamaktadır (Oğul, 2006).

YSA'nın temelinde biyolojik sinir ağlarının yapısının bulunması, sistemin en basit parçası olan nöron analizini önemli kılmaktadır. Nöron, yapı olarak değişik şekil ve büyüklükte olsa da temel bileşenleri hepsinde aynıdır. Nöronun yapısı Şekil 4.4 'te görüldüğü gibidir. Sinir hücrelerini ise, hücre gövdesi (soma), dendrit (giriş), akson (çıkış) ve snaps (bağlantı) oluşturmaktadır. Dendrit ile diğer hücrelerden snaps yardımıyla alınan sinyaller somaya iletilir. Hücre içinde bilgiler işlendikten sonra aksonlar, snapslar aracılığı ile bilgiyi diğer hücelere iletir. Bilginin hücelere arasındaki bu iletişimi kimyasal bir süreci oluşturur (Can, 2012).



Şekil 4.4. Biyolojik sinir hücresi

### Yapay sinir ağlarının özellikleri

YSA'ların farklı ağ modellerine göre sahip oldukları karakteristik özellikleri vardır. Ancak bu karakteristik özelliklerine rağmen birkaç temel ortak özellik taşırlar (Malkoç, 2007).

**a)Hata Toleransı:** YSA'larda ilk özellik olarak sistemin toplamsal işlevinin yapısal olarak dağılımı ve paralelliği karşımıza çıkmaktadır (Haykin, 1994). YSA'lar pek çok nöronun bir araya gelmesi ile oluşmaktadır. Nöronlar karmaşık işlevleri yerine getirirken eş zamanlı olarak çalışmaktadır. Bu işlevler gerçekleşirken nöronlardan herhangi birinin işlevini yerine getirememesi durumunda bile sistem güvenli olarak çalışmasını sürdürmektedir (Efe ve Kaynak, 2004).

**b) Genelleme:** YSA bu özelliği sayesinde eğitim esnasında daha önce karşılaşmadığı test örnekleri içinde tepkiler üretebilmektedir. Diğer bir deyişle eğitim sürecinde almadığı giriş sinyallerinin de sistem bütünü ile benzer davranış gösteriyor oluşu YSA'nın genelleme özelliğinden kaynaklanmaktadır (Turhan, 2012).

**c) Uygulanabilirlik:** YSA, ilgilendiği problemde herhangi bir değişiklik olması durumunda kendi ağırlığını oluşturan değişikliğe göre yeniden ayarlayabilmektedir. Bu sayede eğitime her koşulda devam edilebilmesi mümkün olmaktadır (Turhan, 2012).

**d) Donanım ve Hız:** YSA, paralel bir yapıya sahip oluşu nedeni ile büyük ölçekli entegre devre teknolojisi ile meydana gelmektedir. Sahip olduğu bu özellik YSA'nın hızlı bilgi işleme yeteneğinin artmasını sağlamaktadır (Turhan, 2012).

### **Yapay sinir ağlarının kullanım alanları**

YSA birçok bilim dalında kullanılan bir yöntem olup çözümü güç olan karmaşık yapıların çözümünü kolaylaştırmaktadır. YSA modelleri:

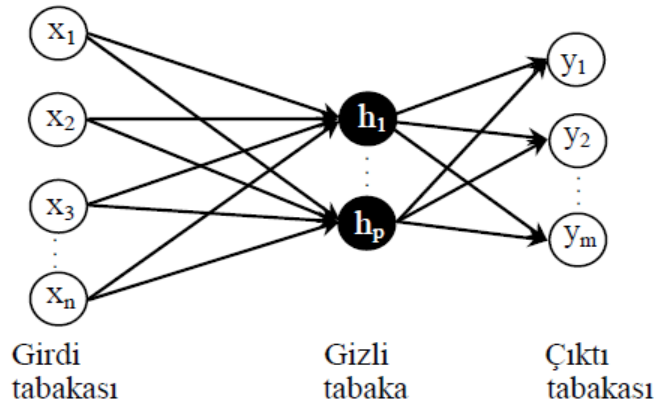
- Sınıflandırma
- Kümeleme
- Vektör sayısallaştırması
- Laboratuvar çalışmaları, ürünlerin pazardaki performansları, hava olayları gibi birçok olayın tahmininde,
- Kontrol sorunlarının giderilmesinde,
- Birçok ticari ve bilimsel alandaki çalışmaların optimizasyonunda,
- Tıp alanında; kanserli hücrelerin analizi, protez tasarımı ve hastane giderlerini optimizasyonunda,
- Silahların hedef izlemesi, gürültü önleme, algılayıcı tasarımı gibi savunma sanayi kapsamında birçok alanda,
- Otomatik bilgi sunma servisleri, görüntü ve veri sıkıştırma, gibi haberleşme alanlarında,
- Ürün analizi ve tasarımı, kalite kontrolü ve analizi, planlama ve yönetim analizi gibi birçok alanda kullanılmaktadır (Afşar, 2008).



#### 4.2.1. Yapay sinir ağlarının mimarisi

Yapay sinir ağları, yapay sinir hücrelerinin bir araya gelmesi ile oluşurlar. Sinir hücreleri genel olarak katmanlar halinde ve belli bir düzen içinde birleşerek ağı oluştururlar (Önal, 2009).

Yapay sinir ağı girdi, gizli ve çıktı katmanı olmak üzere üç farklı katmandan oluşmaktadır. Bir basit yapay sinir ağı modeli Şekil 4.5'te görülmektedir. Pek çok sinir hücresinden oluşan her birim, ağırlık kümeleri adı verilen yapıların katmanları birbirine bağlaması ile oluşmaktadır. Bu bağlanma şekli ve her birimdeki sinir hücresi sayısı birbirinden farklı olabilmekte ve aynı kısımda bulunan hücreler arasındaki iletişime izin verilmemektedir. Hücreler ise girdiyi, ara bağlantılar yardımıyla veya başlangıç girdilerinden almaktadırlar (Cıgızoğlu, 2001).



Şekil 4.5. Basit yapay sinir ağı (Öztemel, 2003)

**Girdi Katmanı:** Bazı ağlarda girdi katmanında bilgiler herhangi bir işlemegirmezken, genel olarak bu katmanda bulunan işlem elemanları dış dünyadan aldıkları bilgileri gizli katmanlara iletmekle sorumludurlar.

**Gizli Katman:** Ağ içerisinde birden fazla gizli katman olması mümkündür. Girdi katmanından gelen bilgileri işledikten sonra çıktı katmanına göndermekle sorumludurlar.


**Çıktı Katmanı:** Bu katmandaki işlem elemanları gizli katmandan gelen bilgileri işledikten sonra ağın girdi katmanında sunulan girdi seti için üretilmesi gereken çıktıyı üretmekle sorumludurlar. Üretilen çıktı ise dış dünyaya gönderilir (Öztemel, 2003).

## 4.2.2. Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağlarının pek çok çeşidi bulunmaktadır. Kullanılan mimari, öğrenme yöntemi, bağlantı yapılarındaki farklılık, gizli katman sayısındaki farklılıklar yapay sinir ağlarında sınıflandırmaya neden olmaktadır.

### 4.2.2.1. Yapılarına göre ağ çeşitleri

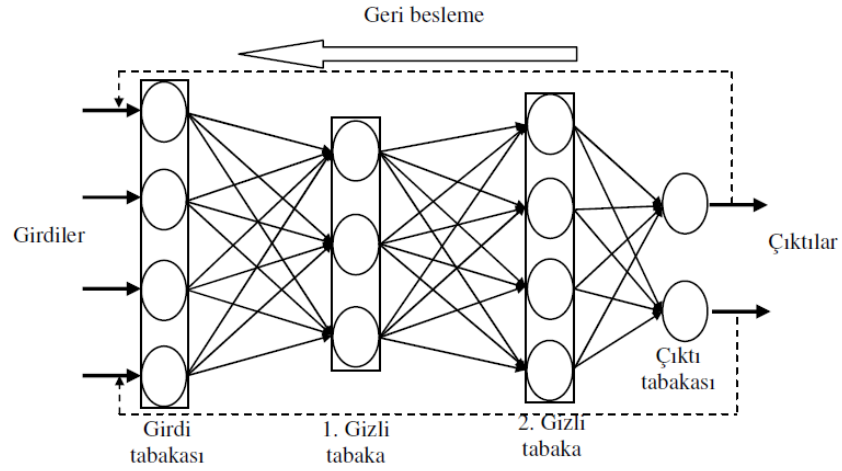
**İleri Beslemeli Ağlar (Feedforward):** İleri beslemeli yapay sinir ağları (İBYSA), YSA bünyesinde kullanımı en çok tercih edilen yöntemlerin başında gelmektedir. Yapısında bulunan hücreler katmanlar halindedir. Bir katmanda bulunan hücrelerin çıkışları başka bir katmana ağırlıklar yardımıyla giriş olarak iletilmektedir. İBYSA'da giriş katmanı, dış ortamdan alınan bilgiler üzerinde herhangi bir değişiklik yapmadan gizli katmana iletir. Bu katmana ulaşan bilgi, önce bu katmanda, sonra çıkış katmanında işlenerek ağın çıkışına gönderilmektedir (Turhan, 2012). İBYSA'nın çalışma sistemi ise Şekil 4.6'da görülmektedir.



Şekil 4.6.Çok katmanlı ileri beslemeli yapay sinir ağı mimarisi (Afşar, 2008)

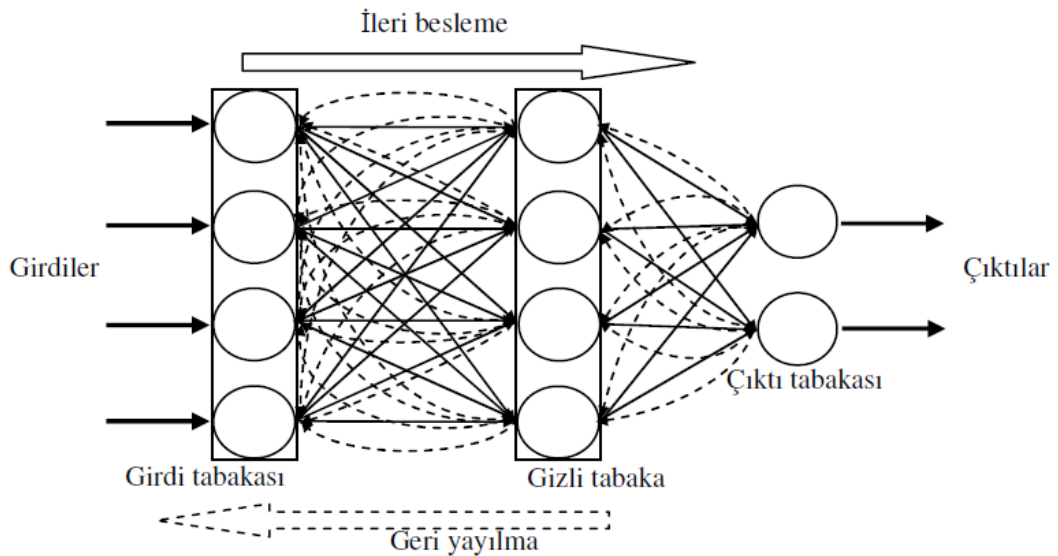
**Geri Beslemeli Ağlar (Feedback veya Backpropagation):** Geri beslemeli yapay sinir ağları (GBYSA) yapısında en az bir hücre olmak üzere, hücrenin çıkış bilgileri kendi girişine veya başka hücrelere giriş verisi olarak iletilmektedir. Geri besleme, sadece belirli bir katmanda sınırlı kalmayıp, katmanlar arasındaki hücreler arasında da gerçekleşebilmektedir. GBYSA'lar yapı olarak geri etkileşimli ve

beraberinde doğrusal olmayan dinamik bir davranış göstermektedir (Turhan, 2012). GBYSA'nın çalışma sistemi ise Şekil 4.7'de görülmektedir.



Şekil 4.7. Çok katmanlı geri beslemeli yapay sinir ağı mimarisi (Afşar, 2008)

**İleri Beslemeli Geri Yayılmalı Ağlar:** Gelişimi 1970'li yıllara dayanan ileri beslemeli geri yayılmalı yapay sinir ağlarının (İBGYYSA) gelişmesi için esas katkılar Rumelhart ve ark. (1986) tarafından sağlanmıştır. Birçok farklı uygulamada tercih edilen ağlar, özellikle doğrusal olmayan yapıdaki problemlerin çözümünde etkili olmasından dolayı ortaya konulduğu zamandan bu yana oldukça yoğun olarak kullanılan bir ağ türü olarak karşımıza çıkmaktadır. Çok katmanlı İBGYYSA'nın mimarisi ise Şekil 4.8'de görülmektedir (Afşar, 2008).

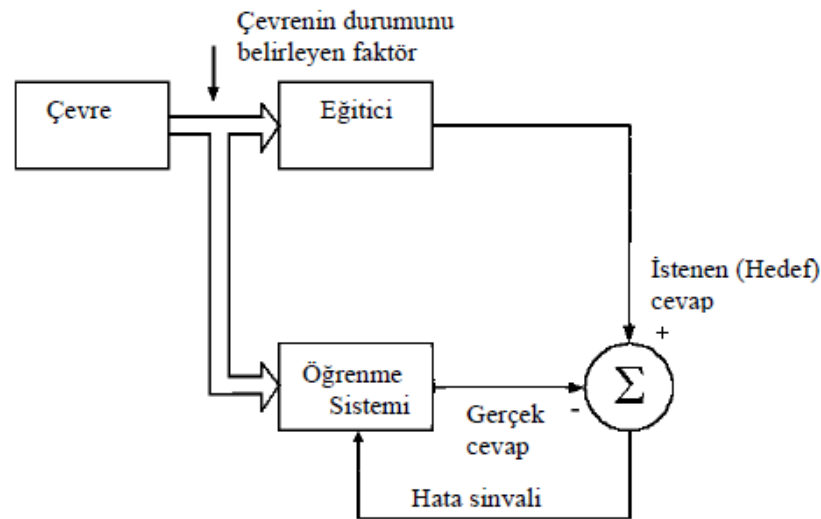


Şekil 4.8. Çok katmanlı ileri beslemeli geri yayılmalı yapay sinir ağı mimarisi (Afşar, 2008)

#### 4.2.2.2. Öğrenme yöntemine göre ağ çeşitleri

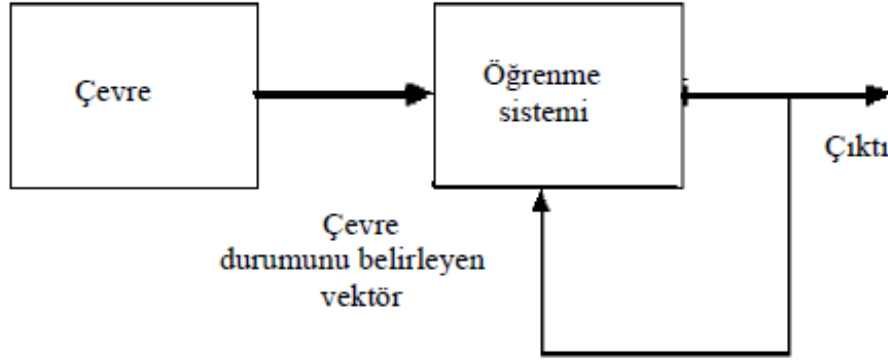
**Öğretmenli Eğitim:** Öğretmenli eğitimde, sistemin olayı öğrenmesi için yardım eğitici tarafından sağlanmaktadır. Öğrenilmesi gereken olay ile ilgili tüm girdi ve çıktılar set halinde eğitici tarafından verilmekte olup her örnek için bu durum geçerlidir. Bu aşamada sistemin yapması gereken şey eğitici tarafından verilen set doğrultusunda çıktıları haritalamaktır (Önal, 2009).

Yine eğitim esnasında hedeflenen değer ile ağ tarafından üretilen değerler karşılaştırılıp arada kalan farkın hata kabul etme sınırını aşıp aşmadığı kontrol edilmektedir. Öğretmenli eğitimin en belirgin özelliği ise eğitim için kullanılan verilerin tamamen gerçek değerlerden oluşmasıdır (Şen, 2004). Öğretmenli eğitime ait yapı Şekil 4.9'daki gibidir.




Şekil 4.9. Öğretmenli eğitim (Önal, 2009)

**Öğretmensiz Eğitim:** Öğretmensiz eğitimde, sistemin öğrenme işlemine yardımda bulunacak herhangi bir eğitici bulunmamaktadır. Sisteme girdi verileri gösterilip, parametreler arasındaki ilişkiyi herhangi bir yardım almadan kendisinin öğrenmesi istenmektedir. Sistem öğrenme işlemini tamamladıktan sonra kullanıcı tarafından çıktıların anlamını gösteren etiketlemenin yapılması gerekmektedir. Daha çok sınıflandırma problemleri için tercih edilen bu yöntem, sınırlı sayıda YSA modeline uygulanmaktadır (Önal, 2009). Öğretmensiz eğitime ait yapı Şekil 4.10'daki gibidir.



Şekil 4.10. Öğretmensiz eğitim (Önal, 2009)

**Yarı Öğretmenli Eğitim (Destekleyici Eğitim):** Yarı öğretmenli eğitimde, hedef çıktıya ulaşabilmek için bir öğretmen yoktur. Bu sistemde öğretmenin yerini verilen girdiye karşılık çıkışın durumunu değerlendiren bir ölçüt kullanılmaktadır. Sistem bilgisine hâkim olan bir öğretmen olmadığından sistem kısmen yönlendirilmektedir. Bu eğitim sisteminden genel olarak, var-yok ya da doğru-yanlış gibi sınıflandırmaların yapılmasında faydalanılmaktadır (Şen, 2004). Öğretmensiz eğitime ait yapı Şekil 4.11'deki gibidir.




Şekil 4.11. Yarı öğretmenli eğitim (Önal, 2009)

Bu çalışmada, aylık buharlaşma miktarını tahmin etmek üzere YSA metotları olarak; Genelleştirilmiş Regresyon Sinir Ağları (GRNN), Radyal Tabanlı Sinir Ağlar (RBNN) ile birlikte Çok Katmanlı Perceptron (MLP) tekniğinden de adaptif öğrenmeli ve momentum özellikli en dik iniş (Gradient descent with momentum and adaptive learning rule backpropagation algorithm-GDX) ve ölçeklendirilmiş eşlenik gradyan (Scaled conjugate gradient-SCG) öğrenme algoritmaları olmak üzere toplam 4 adet YSA metodu kullanılmıştır.

### 4.2.3. Genelleştirilmiş Regresyon Sinir Ağları (GRNN)

GRNN, Specht (1991) tarafından önerilmiş bir metot olup, radyal tabanlı çalışan ve genellikle tahminleyici olarak kullanılan denetimli-öğrenimli bir YSA modeli olup iteratif bir eğitim prosedürü gerektirmemektedir. GRNN, girdi ve çıktı vektörleri arasındaki herhangi bir fonksiyonu eğitim verisini kullanarak tahmin etmektedir. Eğitim setindeki genişleme, tahmindeki hataların sıfıra inmesini sağlamaktadır. Hızlı ve tutarlı sonuçlar üretmesi ve kolay modellenebilmesi bu algoritmanın güçlü yanlarını oluşturmaktadır. Ancak eğitim veri setindeki her örnek veri için örüntü katmanında bir adet nöron tutulması, eğitim veri setinin çok büyük olduğu çalışmalarda, örüntü katman yapısı da örnek verilerinin sayısı ile aynı oranda artmaktadır. Bunun sonucu olarak da yapılan işlem sayısı ve dolayısıyla gereksinim duyulan bellek artmaktadır. GRNN'nin yapısı Şekil 4.12'de görülmektedir.



Şekil 4.12. GRNN yapısı (Sürel, 2006)

$f(x,y)$  ortak olasılık yoğunluk fonksiyonunun bilinmesi halinde, bağımlı  $y$  değişkeninin bağımsız  $x$  değişkenine göre regresyonu Eşitlik 4.1'deki gibidir (Oğul, 2006).

$$E[y|X] = \frac{\int_{-\infty}^{\infty} y f(x,y) dy}{\int_{-\infty}^{\infty} f(x,y) dy} \quad (4.1)$$

Olasılık yoğunluk fonksiyonunun bilinmemesi halinde gözlenen  $X^i$  ve  $Y^i$  değerlerinden bu fonksiyon tahmin edilir.

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{(p+1)/2} s^{p+1}} \frac{1}{n} \sum_{i=1}^n \exp \left[ -\frac{(X-X^i)^T (X-X^i)}{2s^2} \right] \exp \left[ -\frac{(Y-Y^i)^2}{2s^2} \right] \quad (4.2)$$

Denklemden  $p$ ;  $x$  vektörünün boyutu iken,  $n$  gözlenen veri sayısı ve  $s$  düzeltme parametresidir.  $D_i^2$  skaler bir fonksiyondur ve Eşitlik 4.3 ile hesaplanır.

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (4.3)$$

Bağımlı  $y$  değişkenininin bağımsız  $x$  değişkenine göre regresyonu Eşitlik 4.4'deki gibi tanımlanabilir.


$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp \left( -\frac{D_i^2}{2s^2} \right)}{\sum_{i=1}^n \exp \left( -\frac{D_i^2}{2s^2} \right)} \quad (4.4)$$

#### 4.2.4. Radyal Tabanlı Sinir Ağları (RBNN)

Broomhead ve Lowe (1988) tarafından geliştirilen RBNN, insan sinir sistemindeki nöronlarda görülen yerel etki ve tepki davranışlarının temel alınarak oluşturulmuş bir yapay sinir ağı modelidir.

Bu fonksiyon ağlarındaki temel prensip, olması istenen  $f$  fonksiyonuna yaklaşacak biçimde bir grup radyal taban fonksiyonunu ağırlıklandırarak toplamaktır. Üç katmanlı bir yapıya sahip olan radyal tabanda; giriş katmanı giriş vektör uzayı, çıkış katmanı ise örüntü sınıfları ile ilişkilidir (Oğul, 2006).

Klasik YSA yapılarından farklı olarak radyal tabanlı fonksiyonlarda, girdi katmanı ile gizli katman arasında doğrusal olmayan bir kümeleme analizi ve radyal tabanlı aktivasyon fonksiyonları kullanılmaktadır. Gizli katman ile çıktı katmanı arasındaki yapı ise klasik YSA yapılarında olduğu gibi esas eğitimi gerçekleştirmektedir (Okkan ve Dalkılıç, 2012). Radyal tabanlı fonksiyon yapısı Şekil 4.13'de verildiği gibidir.



Şekil 4.13. RBNN yapısı

Gizli katmandaki nöronların aktivasyon fonksiyonları bir  $C_j$  ve  $\sigma_j$  bant genişliği ile belirlenmektedir. Aktivasyon fonksiyonu:

$$\sigma_j(X) = \exp\left(-\frac{(x-c_j)^2}{2\sigma_j^2}\right) \quad (4.5)$$

şeklinde tanımlanan bir Gauss eğrisidir. Çıkış katmanındaki  $j$ . nöronun çıkışı için genel eşitlik ise,

$$S_j(X) = \sum_{i=1}^K w_{ij} \sigma_i(X) + b_j \quad (4.6)$$

şeklinindedir. Eşitlikteki  $w_{ij}$ ; gizli nöron  $i$  ve çıkış nöronu  $j$  arasındaki ağırlık katsayısı,  $b_j$  ise bias sabitidir (Paredes ve Vidal, 2000).

#### 4.2.5. Çok Katmanlı Yapay Sinir Ağları (MLP)

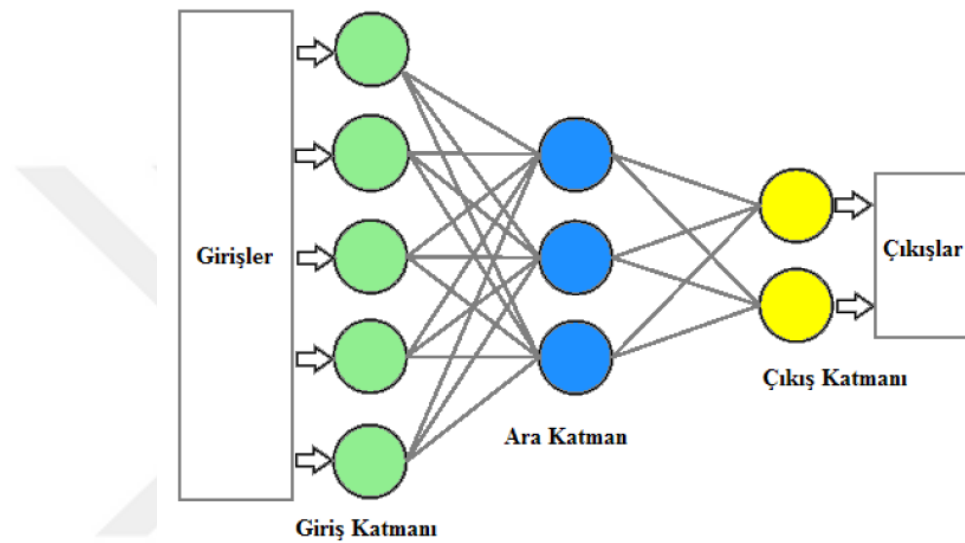
MLP, çoğunlukla lineer olmayan problemlerin çözümünde tercih edilen YSA modeli olup minimum üç katmandan oluşan ağlardır.

MLP, klasik YSA'dan farklı olarak giriş ve çıkış katmanının dışında bir veya daha fazla ara katmandan oluşmaktadır. Çözüme ulaşması istenen probleme göre; giriş ve çıkış katmanlarındaki hücre sayıları, ara katman sayısı ve ara katmanda bulunan hücre sayıları uygun olarak tasarımcı tarafından belirlenmektedir. Katman ve bu



katmanlara uygun hücre sayısının doğru şekilde seçilememesi durumunda YSA'dan istenilen performans elde edilememektedir (Arık, 2014).

MLP, danışmanlı öğrenme yöntemini kullanmakta ve bu yöntemi kullanırken de öğrenme işlemi, ağırlıkların optimize edilmesi ile ağıın ürettiği çıkış verisi ve gerçek çıkış verisi arasındaki hatayı en aza indirme amacına dayanmaktadır. Bu kural, en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş şeklidir. Çok katmanlı ve ileri beslemeli bir YSA modeli Şekil 4.14'te verildiği gibidir.



Şekil 4.14. Çok katmanlı ileri beslemeli YSA modeli

### 4.3. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS)

ANFIS, YSA ile bulanık mantığın bir arada kullanılması fikrine dayanmaktadır. Bu iki sistemin birleştirilmesi sayesinde bulanık mantık çıkarım sistemlerine yapay sinir ağlarının özelliği olan öğrenme ve hesap etme yeteneği sağlanmaktadır. Aynı şekilde yapay sinir ağlarına da, bulanık mantık çıkarımının sahip olduğu karar verme ve uzman bilgisi sağlama yeteneği verilmiş olmaktadır. İlk kez, Jang (1993) tarafından ortaya atılan bu fikir sayesinde bulanık çıkarım sistemi ve yapay sinir ağı modelinin üstün özellikleri bir arada kullanılabilir (Saraç, 2012).


ANFIS, yalnız Sugeno tipi modelleri çalıştırmaktadır. Bu modelleme tipi, girdilerin bir fonksiyonu şeklinde üyelik fonksiyonlarına sahip olan, çıktı değişkenlerinden oluşmaktadır. Aynı zamanda çıktı üyelik fonksiyonları, lineer veya sabit olma zorunluluğu taşımaktadır. Üyelik fonksiyonları parametrelere bağlı olan

ANFIS'te, parametreler deęiřtikçe buna baęlı olarak üyelik fonksiyonları da deęiřmektedir (Öztürk ve ark., 2010).

Bir bařka deyiřle ANFIS, yapısı itibariyle sinirsel öğrenme özelliğine sahip Sugeno tipi bulanık sistemlerin bir aę halinde birleřmesinden oluřmaktadır. Bu aę yapısı ise, katmanlar halinde her biri ayrı bir görev üstlenen düęümlerin birleřmesi ile meydana gelmektedir (Tsoukalas ve Uhrig, 1996).

#### 4.3.1. ANFIS modelinin mimarisi ve iřleyiři

ANFIS aę yapısı; giriř, bulanıklařtırma, kural, normalizasyon, arındırma, toplam katmanı olmak üzere 6 katmandan oluřmaktadır. ANFIS mimarisindeki her katmana ait düęüm iřlevleri ve katmanlar Őekil 4.15'de görölmektedir.



Őekil 4.15. ANFIS mimarisi (Yaseen, 2016)

ANFIS modelleme teknięini ifade etmek amacıyla, bulanık çıkarım sistemi iki girdili ( $x, y$ ) ve tek çıktılı ( $z$ ) olmak üzere örneklendirilmiřtir. Bununla birlikte kuralın temelini, ařaęıda ifade edildięi gibi Sugeno tipi “ Eęer – ise ” mekanizmasının oluřturduęu kabul edilmektedir (Jang, 1993).

**Kural 1:** Eęer  $x$   $A_1$  ve  $y$   $B_1$  ise  $f_1 = p_1x + q_1y + r_1$

**Kural 2:** Eęer  $x$   $A_2$  ve  $y$   $B_2$  ise  $f_2 = p_2x + q_2y + r_2$

...

**Kural n:** Eęer  $x$   $A_n$  ve  $y$   $B_n$  ise  $f_n = p_nx + q_ny + r_n$

#### 4.4. Destek Vektör Makineleri ( DVM )


DVM'nin temeli, Vapnik (1995) tarafından istatistiksel öğrenme teorisi esas alınarak ortaya konulmuştur.

Vapnik'in ortaya attığı bu yöntem, istatistiksel öğrenme teorisi ile beraber yapısal risk minimizasyonu ilkesini temel alan, sınıflandırma ve regresyon problemlerine çözüm üretme amacı taşımaktadır ve genelleştirilmiş doğrusal sınıflandırıcı ailesine aittir (Vapnik 1995, 1998).

Deneysel sınıflandırma hatalarını en aza indirme ve geometrik sınırları da mümkün olduğunca büyütme özelliğine sahip olması nedeniyle de en büyük sınır sınıflandırıcısı olarak bilinirler (Akgündoğdu ve ark., 2010).

DVM yapı olarak; istatistik, makine öğrenmesi ve sinir ağlarını çeşitli şekilde kombine etmektedir. Genelleme hatalarını, sınırlandırılmış eğitim hataları toplamıyla gösterirler ve yapısal risk minimizasyonunu gerçekleştirirken, minimize edilmiş Vapnik-Chervonenkis (VC) boyutlu bir sınıflandırıcı oluştururlar (Shawkat ve Abraham, 2002).

DVM yöntemi, doğrusal bir diskiriminant fonksiyonuna dayanmaktadır. Aynı zamanda geniş marj sınıflandırıcısı ve Vapnik- Chervonenkis teorisi tarafından ispat edilebilmektedir. Bu özellikleri ise verinin hatasız bir şekilde ayrılabilmesini sağlamaktadır. Sağladığı bu avantaj sayesinde gerçek problemlerin çözümünde iyi bir performans göstermekte ve uygulamayı kolaylaştırmaktadır (Erastö, 2001). DVM'nin genel yapısı Şekil 4.16'daki gibidir.



Şekil 4.16. Destek Vektör Makinelerinin genel yapısı

#### 4.4.1. Destek Vektör Regresyonu (DVR)

Karar destek sistemleri Vapnik (1995) tarafından, ilk olarak sınıflandırma (DVM) problemleri için sonrasında ise regresyon (DVR) tipi problemler için önerilmiştir.

DVR, eğitim verilerinden gelecek değerleri tahmin eden bir fonksiyon bulmak amacı ile kullanılmaktadır (Park, 2006). DVR'nin temelini, sahip olunan eğitim verilerinin karakterini gerçeğe yakın ve istatistiksel öğrenme teorisine uyan doğrusal ayırıcı bir fonksiyon bulması oluşturmaktadır.

DVM sıklıkla sınıflandırma da kullanılan bir yöntem olmasına rağmen regresyon tipi problemlerin çözümünde de tercih edilmektedir. DVM'de öğrenme, hata fonksiyonunun  $\varepsilon$ -duyarsız kayıp fonksiyonu  $L_{\varepsilon}(u, f(x))$ 'e bağlı olarak minimize edilmesi ile Eşitlik 4.7'deki gibi hesaplanmaktadır (Ekici, 2007).

$$L_{\varepsilon}(u, f(x)) = |u - f(x)| - \varepsilon, |u - f(x)| \geq \varepsilon \text{ for} \quad (4.7)$$

$$0, \quad |u - f(x)| < \varepsilon \text{ for}$$

denklemlerdeki;  $\varepsilon$  varsayılan doğruluk,  $u$  hedef,  $x$  giriş vektörü ve  $f(x)$  DVM'nin gerçek çıkışıdır. DVM'nin gerçek çıkışı:

$$f(x) = \sum_{j=0}^N w_j x_j + b_j = w^T x + b \quad (4.8)$$

şeklinindedir. Denklemdeki;  $w = [w_0, w_1, \dots, w_N]^T$  ağırlık vektörü,  $N$  örnek sayısı,  $x$  giriş veri grubu ve  $b$  bias değeridir.

Öğrenme işlemi ise hata fonksiyonu olan  $E$ 'nin minimize edilmesiyle hesaplanmaktadır (Ekici, 2007).

$$E = \frac{1}{N} \sum_{i=1}^N L_{\varepsilon}(u_i, f(x_i)) \quad (4.9)$$

Öğrenme problemi,  $\delta_i$  ve  $\delta_i^*$  yapay değişkenlerinin aşağıda verildiği üzere bir değer işlevi ile minimize edilmesiyle,

$$\theta(w, \delta, \delta^*) = C \sum_{i=1}^N (\delta_i + \delta_i^*) + \frac{1}{2} w^T w \quad (4.10)$$

olarak tanımlanabilir. Bu eşitlik için ise sınır şartları aşağıdaki gibidir (Ünsal 2007);

$$\begin{aligned} u_i - w^T x_i &\leq \varepsilon + \delta_i \\ w^T x_i - u_i &\leq \varepsilon + \delta_i^* \\ \delta_i, \delta_i^* &\geq 0 \end{aligned} \quad (4.11)$$

Yukarıdaki denklemde bulunan  $\varepsilon$  ve  $C$  kullanıcı tarafından belirlenen iki bağımsız değişkendir. Optimizasyon problemi, Lagrangian işlevi ile çözümlenir. Lagrangian çarpanları  $\alpha_i, \alpha_i^*$  ( $i = 1, 2, \dots, N$ ) ise işlevsel sınırlamalar için kullanılmaktadır. İkili problemde kullanılan Lagrangian fonksiyonu maksimize edilerek,

$$\max \sum_{i=1}^N u_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) \pm \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x, z) \quad (4.12)$$

ifadesine ulaşılmaktadır. Burada sınır şartları aşağıdaki gibidir;

$$\begin{aligned} \sum_{i=1}^N (\alpha_i - \alpha_i^*) &\geq 0 \\ 0 &\leq \alpha_i \leq C, \\ 0 &\leq \alpha_i^* \leq C \end{aligned} \quad (4.13)$$

$K(x, z) = \phi^T(x)\phi(z)$  ise Mercer teoremine göre tanımlanmış iç çarpım fonksiyonudur. İkili problemin çözümüne göre,  $w$  ağırlık vektörü için en uygun yöntem aşağıdaki gibidir (Ekici, 2007);

$$w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i) \quad (4.14)$$

Değeri 0 olmayan Lagrange çarpanlarının sayısı, destek vektör sayısına eşittir. Lagrange çarpanları ve çekirdek fonksiyonu dahilinde, DVM'nin çıkış fonksiyonu olan  $f(x)$ , Eşitlik 4.15'deki gibidir.

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, z) + b_i \quad (4.15)$$

DVM regresyonunun tahmin performansında;  $\varepsilon$  (duyarsız hata terimi), C (düzenleme faktörü), kernel fonksiyonunun türü ve kernel parametresi etkili olmaktadır. Bu parametrelerden  $\varepsilon$ ; hatanın ihmal edildiği aralığı belirtirken, bu sabitin değerinin azalması durumunda DVR'deki destek vektör sayısında artış gözlenmektedir. C ise, ağırlık vektörü ve karakterize edilmiş sistem karışıklığıyla beraberindeki duyarsız değişkenler ve ölçülen tahmin hataları arasındaki düzeni sağlamak amacıyla DVR'nin başarısını, belirtilen değişkenlerin uygun şekilde kullanılması etkilemektedir (Ekici, 2007).

DVR'de kullanılan çekirdek fonksiyonu ve model parametrelerinin seçimi performans açısından oldukça önemli olmasına rağmen, bu iki faktörün seçimi ile ilgili belirleyici kriterler bulunmamaktadır. DVR uygulamalarında çoğunlukla tercih edilen çekirdek fonksiyonları Çizelge 4.5'te verildiği gibidir.

**Çizelge 4.5.** Yaygın olarak kullanılan çekirdek fonksiyonları

Çekirdek Tipi	Çekirdek Fonksiyonu
Lineer	$K(x_i, x) = x_i^T x_j$
Polinom	$K(x_i, x) = (\gamma x_i^T x_j + r)^d$
Radyal Tabanlı Fonksiyon	$K(x_i, x) = \exp(-\gamma \ x_i - x_j\ ^2)$
Sigmoid	$K(x_i, x) = \tanh(\gamma x_i^T x_j + r)$

## 4.5. Ampirik Denklemler

### 4.5.1. Meyer denklemi

Meyer (1915) tarafından geliştirilen metot, buharlaşma miktarının hesaplanması için rüzgar hızının da dahil olduğu denklemdir ve Eşitlik 4.16 ile hesaplanır.

$$E = A(e_s - e_a) \left(1 + \frac{w}{16}\right) \quad (4.16)$$

Bu denkleme göre:

E: Aylık buharlaşma miktarı (mm)

$e_s$ : T ( $^{\circ}\text{C}$ ) sıcaklıktaki havanın doymuş buhar basıncı (mmHg)

$e_a$ : Su yüzeyindeki buhar basıncı (mmHg)

w: Su yüzeyinden 8 m yüksekte km/saat cinsinden ölçülen rüzgar hızıdır.

A: Büyük su kütlelerinde 11, küçük su kütlelerinde 15 olarak alınan bir katsayıdır.

RH rölatif nem olmak üzere Eşitlik 4.16 da kullanılan  $e_a$  ve  $e_s$  ise aşağıdaki eşitlikler ile hesaplanmaktadır.

$$RH = \frac{e_a}{e_s} \quad (4.17)$$

$$e_s = 6.11 \exp[17.3 T / (237.3 + T)] \quad (4.18)$$

Bu eşitlikte

T: Hava sıcaklığı ( $^{\circ}\text{C}$ )

$e_s$ : Doymuş buhar basıncı (mmbar)

#### 4.5.2. Priestley-Taylor denklemi

Priestley ve Taylor (1972), havanın ıslak yüzey ile teması halinde su buharının havayı doymuş hale getireceğini ileri sürmüş ve atmosferin denge koşullarının sonucu olarak aynı doygunluktaki yüzeylerden buharlaşma oranını belirlemek için Penman-Monteith denklemini basitleştirerek önermişlerdir. Penman-Monteith denkleminde bulunan aerodinamik bileşen silinmiş ve enerji bileşeni  $\alpha$  katsayısı ile çarpılarak aşağıda verilen eşitlik elde edilmiştir.

$$ET_p = \alpha \left( \frac{\Delta}{\Delta + \gamma} \right) (R_n - G) \frac{1}{\lambda} \quad (4.19)$$

Bu denkleme göre:

$ET_p$ : Potansiyel buharlaşma (mm/gün)

$\alpha$  : 1.05 ile 1.38 arasında değişen bir sabit (Priestley ve Taylor, bu katsayıyı geniş ıslak yüzeyler için ortalama 1.26 olarak bulmuşlardır (Xu ve Singh, 2000)).

$\Delta$  : Doygun buhar basınç eğrisi eğimi (kPa/°C)

$\gamma$  : Psikometrik sabit (kPa/°C)

$R_n$ : Net radyasyon (W/m<sup>2</sup>)

G: Kütleye giren ısı akışı (W/m<sup>2</sup>)

#### 4.5.3. Romanenko denklemi

Romanenko (1961) tarafından geliştirilen ve aylık buharlaşma miktarının tahmini için kullanılan ampirik denklemlerden biri olup Eşitlik 4.20 ile hesaplanmaktadır.

$$E = 0.0018 (25 + T_a)^2 (100 - RH) \quad (4.20)$$

Burada;

E: Aylık buharlaşma miktarı (mm/ay)

$T_a$ : Ortalama hava sıcaklığı (°C)

RH: Rölatif nem (%)

#### 4.5.4. FAO-Penman Monteith denklemi

Son 50-60 yılda, farklı iklimsel değişkenlerden evapotranspirasyonu tahmin etmek için çok sayıda ampirik yöntem geliştirilmiştir. Bunlardan bazıları, şu ana kadar bilinen bir enerji dengesi ve aerodinamik formülün bir kombinasyonuna dayanarak açık su, çıplak toprak ve çimlerden (şu anda evapotranspirasyon olarak adlandırılır) buharlaşmayı belirlemek için bilinen Penman denkleminde (Penman 1948) türetilmiştir.

Penman (1948), meteorolojik verileri (güneşlenme, sıcaklık, nem ve rüzgar hızı) kullanarak açık su yüzeyinden buharlaşma tahmini için bir teori ileri sürmüştür. Bu teoriye göre, buharlaşmanın devam edebilmesi için iki şart vardır. Bunlar, buharlaşma latent ısısı için gerekli enerjinin sağlanması ve buharı uzaklaştıran bir mekanizmanın olmasıdır.

Monteith (1965) tarafından Penman denklemi, aerodinamik ve yüzey direnci faktörlerinin eklenmesiyle bitkiler için daha da geliştirilmiş ve Penman-Monteith denklemi olarak literatürde kullanılmaya başlanmıştır.



Son olarak Birleşmiş Milletler Gıda ve Tarım Örgütü (Food and Agriculture Organization-FAO) tarafından (Allen ve ark. 1998) orijinal Penman-Monteith denklemi ile aerodinamik ve yüzey direnç eşitliklerinin birleştirilmesiyle FAO-56 Penman-Monteith denklemi elde edilmiş ve Eşitlik 4.21'deki halini almıştır.

$$ET_0 = \frac{0,408 \cdot \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 * u_2)} \quad (4.21)$$

Burada;

$ET_0$ : Referans evapotranspirasyon (mm/gün)

$R_n$ : Bitki yüzeyindeki net radyasyon ( MJ/ m<sup>2</sup>.gün)

$G$ : Toprak ısı akımı yoğunluğu (MJ/ m<sup>2</sup>.gün)

$T$ : Günlük ortalama sıcaklık (°C)

$u_2$ : 2 m yükseklikteki rüzgar hızı (m/s)

$e_s$ : Doygun buhar basıncı ( kPa)

$e_a$ : Mevcut buhar basıncı ( kPa)

$e_s - e_a$ : Doygun buhar basıncı noksanlığı ( kPa)

$\Delta$ : Doymuş buhar basıncı-sıcaklık eğrisinin eğimi (kPa/ °C)

$\gamma$  : Psikrometrik sabit (kPa/ °C)

## 5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Konya Kapalı Havzası'nda bulunan Aksaray, Konya ve Karaman meteoroloji istasyonlarına ait aylık buharlaşma miktarının tahmini için MLP (SCG – GDX), RBNN, GRNN, ANFIS,  $\varepsilon$ -DVR modellerinden oluşan yapay zeka metotları ile, FAO-Penman–Monteith, Priestley-Taylor, Meyer ve Romanenko ampirik denklemleri kullanılmıştır. Yapay zeka metotlarının uygulaması yapılmadan önce, input ve output katmanında kullanılan parametrelerdeki birim farklılığını ortadan kaldırmak amacıyla aşağıdaki eşitlik kullanılarak veriler 0 ile 1 arasında boyutsuz hale getirilmiştir.

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (5.1)$$

Burada  $X_{norm}$ ,  $X_i$ ,  $X_{min}$  ve  $X_{max}$  tüm parametreler için sırasıyla normalize edilmiş, gözlenmiş, minimum ve maksimum değeri ifade etmektedir.

Aylık buharlaşma (E) miktarını (output) tahmin etmek amacıyla, aylık toplam yağış (P), ortalama sıcaklık ( $T_{ort}$ ), minimum sıcaklık ( $T_{min}$ ), maksimum sıcaklık ( $T_{mak}$ ), ortalama rüzgâr hızı (WS), ortalama nispi nem (RH), ortalama buhar basıncı (VP) ve ortalama atmosferik basınç (AP) parametrelerinden oluşan sekiz farklı input kombinasyonu kullanılmıştır. Kullanılan input kombinasyonları Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Kullanılan input kombinasyonları

Model Adı	Inputlar	Output
M1	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , WS, RH, VP, AP	
M2	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH, VP, AP	
M3	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH, VP	
M4	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH	
M5	$T_{ort}$ , $T_{min}$ , $T_{max}$ , RH	E
M6	$T_{ort}$ , $T_{min}$ , $T_{max}$	
M7	$T_{ort}$ , $T_{max}$	
M8	$T_{ort}$	

Her meteoroloji istasyonu için kullanılan veriler 1 Nisan-31 Ekim tarihleri arasındaki gözlemleri içermektedir. Yıllara göre ölçüm yapılan aylar değiştiğinden dolayı her istasyon için ölçümü tam olan ortak aylar göz önünde bulundurulmuştur. Her

istasyon için eğitime ve test aşamasında kullanılan gözlem periyotları ve veri sayısı Çizelge 5.2’de verilmiştir.

**Çizelge 5.2.** Eğitime ve test aşamasında kullanılan gözlem periyotları ve veri sayısı

İstasyon Adı	Gözlem Periyodu	Eğitime Verisi Periyodu	Test Verisi Periyodu
Konya	1960-2006 (329 ay)	1960-1992 (231 ay)	1993-2006 (98 ay)
Karaman	1967-2010 (308 ay)	1967-1997 (217 ay)	1998-2010 (91 ay)
Aksaray	1973-2010 (266 ay)	1973-1999 (189 ay)	2000-2010 (77 ay)

MLP-GDX, MLP-SCG, GRNN, RBNN,  $\varepsilon$ -DVR, ANFIS yapay zeka metotları ve FAO-Penman Monteith, Priestley Taylor, Meyer ve Romanenko ampirik denklemlerinin kullanılmasıyla elde edilen modellerin başarılarının değerlendirilmesinde aşağıdaki eşitliklerde verilen, ortalama mutlak hata (MAE), karekök ortalama karesel hata (RMSE), determinasyon katsayısı ( $R^2$ ) ve Nash-Sutcliffe etkinlik katsayısı (NSE)) performans kriterleri kullanılmıştır.

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{i_{gözlem}} - Y_{i_{tahmin}}| \quad (5.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{i_{gözlem}} - Y_{i_{tahmin}})^2} \quad (5.3)$$

$$R^2 = \frac{\left[ \sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})(Y_{i_{tahmin}} - \bar{Y}_{tahmin}) \right]^2}{\sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})^2 \sum_{i=1}^N (Y_{i_{tahmin}} - \bar{Y}_{tahmin})^2} \quad (5.4)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Y_{i_{gözlem}} - Y_{i_{tahmin}})^2}{\sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})^2} \quad (5.5)$$

$\varepsilon$ -DVR metodu için LIBSVM Software olarak bilinen program kullanılmış, tüm yapay zeka metotlarına ait uygulamalar MATLAB 2014a ile yapılmıştır.

## 5.1. MLP – GDX Model Uygulaması

Sekiz farklı input kombinasyonu kullanılarak Konya, Karaman ve Aksaray meteoroloji istasyonları için, buharlaşma miktarını tahmin etmek üzere, MLP- GDX öğrenme algoritması kullanılarak modeller kurulurken, iki gizli katmandan oluşan dört tabakalı YSA mimarisi kullanılmıştır. Kurulan modellerde gizli katmandaki nöron sayısı ve öğrenme oranı deneme yanılma ile belirlenmiştir. Aktivasyon fonksiyonu olarak gizli katmanlarda tanjant sigmoid, çıkış katmanında ise logaritmik sigmoid fonksiyonu kullanılmıştır. Gizli katmanlardaki nöron sayısı 1-20 aralığında, yakınsama hızını etkileyen parametreler olan öğrenme oranı ( $\eta$ ) 0.1-1 arasında 0.1'lik artışla incelenmiştir. Oluşturulan MLP-GDX modellerinde iterasyon sayısı 1000, momentum katsayısı ise 0.8 olarak alınmıştır. Bu kabuller doğrultusunda yapılan denemeler sonucunda sekiz farklı input kombinasyonu için elde edilen en başarılı MLP-GDX modellerine ait sonuçlar Çizelge 5.3'de verilmiştir. En başarılı ağ yapılarına; test verilerine ait en büyük NSE değerine göre karar verilmiştir.

Yapılan denemeler sonucunda test verilerine göre en başarılı MLP-GDX yapısı, Aksaray istasyonu için  $NSE=0.863$  değeri ve Konya istasyonu için  $NSE=0.871$  değeri olmak üzere M1 input kombinasyonunda elde edilmiştir. Model yapısındaki ilk değer input sayısını, ikinci ve üçüncü değerler gizli katmandaki nöron sayısını, son değer ise output sayısını ifade etmektedir. Buna göre M1 modelinde; Aksaray istasyonu için, birinci gizli katmanda 5, ikinci gizli katmanda ise 7 tane nöron sayısı söz konusu olup öğrenme oranı 0.2 olarak belirlenirken, Konya istasyonu için birinci gizli katmanda 3, ikinci gizli katmanda ise 15 tane nöron sayısı ve öğrenme oranı 0.3 olan model yapısı söz konusudur. M1 modeli test periyodundaki  $R^2=0.879$  değeri ile de Aksaray istasyonu için buharlaşma tahminindeki en başarılı model olurken, Konya istasyonu için test periyodunda bu değer  $R^2=0.875$ 'tir.  $R^2$  ve NSE sonuçları her iki istasyonda da birbirini desteklemektedir.

Aksaray istasyonu buharlaşma tahmininde en düşük başarıyı, test periyoduna ait  $R^2=0.772$  ve  $NSE=0.748$  değerleri ile,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , RH parametrelerinin kullanıldığı M5 modeli gösterirken; Konya istasyonu ise, buharlaşma tahminindeki en düşük başarıyı  $R^2=0.836$  ve  $NSE=0.796$  değerleri ile  $T_{ort}$  parametresinin kullanıldığı M8 modelinde göstermektedir.

Yine bu denemeler sonucundaki test verilerine göre en başarılı GDX yapısı, Karaman istasyonu için test verisine ait  $NSE=0.587$  değeri ile M2 modelinde

görülmüştür. Karaman istasyonu için, birinci gizli katmanda 13, ikinci gizli katmanda ise 2 tane nöron sayısı söz konusu olup öğrenme oranı 0.7 olarak belirlenmiştir. M2 modeli  $R^2=0.752$  değeri ile en başarılı model olurken  $R^2$  ve NSE sonuçları da birbirini desteklemektedir.

Karaman istasyonu buharlaşma tahmininde en düşük başarıyı ise, test periyodundaki  $R^2=0.750$  ve  $NSE=0.544$  değerleri ile P,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , RH, VP parametrelerinin kullanıldığı M3 modeli göstermektedir.

Çizelge 5.3. MLP-GDX modellerine ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	Öğrenme oranı (lr)	Eğitme		Test	
				$R^2$	NSE	$R^2$	NSE
AKSARAY	M1	(8, 5,7, 1)	0.2	0.873	0.873	0.879	0.863
	M2	(7, 4, 5, 1)	0.9	0.863	0.863	0.838	0.827
	M3	(6, 2,12, 1)	0.3	0.859	0.859	0.845	0.836
	M4	(5, 12, 5,1)	0.6	0.889	0.889	0.843	0.817
	M5	(4, 4, 1, 1)	0.2	0.832	0.832	0.772	0.748
	M6	(3, 10, 3, 1)	0.3	0.862	0.862	0.825	0.807
	M7	(2, 3, 12, 1)	0.4	0.850	0.850	0.821	0.802
	M8	(1, 1, 16, 1)	0.7	0.849	0.849	0.832	0.814
KARAMAN	M1	(8, 1,16, 1)	0.1	0.779	0.779	0.734	0.554
	M2	(7, 13,2, 1)	0.7	0.766	0.766	0.752	0.587
	M3	(6, 10,1, 1)	0.4	0.760	0.760	0.750	0.544
	M4	(5, 9,2, 1)	0.1	0.748	0.748	0.745	0.574
	M5	(4, 17,3, 1)	0.2	0.750	0.750	0.743	0.574
	M6	(3, 1,15, 1)	0.2	0.726	0.726	0.743	0.557
	M7	(2, 7,1, 1)	0.1	0.718	0.718	0.744	0.560
	M8	(1, 2,13, 1)	0.3	0.731	0.731	0.751	0.549
KONYA	M1	(8, 3,15, 1)	0.3	0.775	0.775	0.875	0.871
	M2	(7, 1,15, 1)	0.8	0.649	0.649	0.856	0.842
	M3	(6, 3,7, 1)	0.2	0.646	0.646	0.853	0.838
	M4	(5, 3,17, 1)	0.9	0.643	0.643	0.858	0.847
	M5	(4, 1,4, 1)	1.0	0.648	0.648	0.852	0.837
	M6	(3, 2,12, 1)	1.0	0.622	0.622	0.838	0.816
	M7	(2, 2,7, 1)	0.2	0.621	0.621	0.852	0.815
	M8	(1, 12,8, 1)	0.4	0.645	0.644	0.836	0.796

## 5.2. MLP – SCG Model Uygulaması

MLP - SCG modelleri kurulurken, iki gizli katmandan oluşan dört tabakalı YSA yapısına başvurulmuştur. Oluşturulan modellerde gizli katmandaki nöron sayıları 1-20 aralığında, iterasyon sayısı ise 100 – 1000 arasında deneme yanılma ile belirlenmiş ve aktivasyon fonksiyonu olarak da gizli katmanlarda tanjant sigmoid, çıkış katmanında ise logaritmik sigmoid fonksiyonu kullanılmıştır. Kullanılan bu değerler doğrultusunda yapılan denemelere göre sekiz farklı input kombinasyonu için elde edilen en başarılı MLP-SCG öğrenme algoritmasına ait sonuçlar Çizelge 5.4'te görülmektedir. Model yapılarındaki ilk değer input sayısını, ikinci ve üçüncü değerler gizli katmandaki nöron sayısını, son değer ise output sayısını ifade etmektedir. En başarılı ağ yapısının belirlenmesinde, test verilerine ait en büyük NSE değeri temel alınmıştır.

Çizelge 5.4'e göre; oluşturulan kombinasyonlar sonucunda test periyoduna göre en başarılı SCG yapısı, Aksaray istasyonu için  $NSE=0.859$  değeri ile (8, 3, 15, 1) ağ yapısını, Konya istasyonu için ise  $NSE =0.872$  değeri (8, 3, 15, 1) ağ yapısını içeren M1 modellerinde elde edilmiştir. Aksaray ve Konya istasyonları için M1 input kombinasyonundaki  $R^2$  değerleri de test periyodu için sırasıyla 0.873 ve 0.877 olarak elde edilmiş olup bu değerler diğer kombinasyonlardan daha yüksek başarıya sahiptir. Bu duruma göre  $R^2$  ve NSE sonuçlarının, her iki istasyonda da en başarılı input kombinasyonu açısından birbirini desteklediğini söylemek mümkündür.

Aksaray istasyonu buharlaşma tahmininde en düşük başarıyı  $R^2=0.829$  ve  $NSE=0.805$  değerleri ile  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$  parametrelerinin kullanıldığı M6 modeli göstermektedir. Konya istasyonunda ise, buharlaşma tahminindeki en düşük başarının  $R^2=0.844$  ve  $NSE =0.796$  değerleri ile  $T_{ort}$  parametresinin kullanıldığı M8 modelinde elde edildiği görülmüştür.

Karaman istasyonu için ise elde edilen test verilerine göre en başarılı SCG yapısına,  $NSE =0.586$  ve  $R^2=0.744$  değerleri ile M5 modelinde ulaşılmıştır. Karaman istasyonunun model yapısına bakıldığında, 1. gizli katmanda 6 tane, 2. gizli katmanda ise 13 tane nöron sayısı olduğu görülmüş olup, iterasyon sayısı 200 olarak belirlenmiştir.

Karaman istasyonuna ait buharlaşma tahmininde en düşük başarının,  $NSE=0.521$  ve  $R^2=0.725$  değerleri ile P,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , WS, RH, VP, AP parametrelerinin kullanıldığı M1 modelinde olduğu görülmüştür.

Çizelge 5.4. MLP-SCG modellerine ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	İterasyon Sayısı	Eğitme		Test	
				R <sup>2</sup>	NSE	R <sup>2</sup>	NSE
AKSARAY	<b>M1</b>	<b>(8, 3, 15, 1)</b>	<b>400</b>	<b>0.907</b>	<b>0.907</b>	<b>0.873</b>	<b>0.859</b>
	M2	(7, 2, 16, 1)	800	0.895	0.895	0.862	0.849
	M3	(6, 2, 7, 1)	100	0.862	0.862	0.849	0.833
	M4	(5, 4, 12, 1)	200	0.866	0.866	0.848	0.833
	M5	(4, 5, 1, 1)	100	0.860	0.860	0.829	0.821
	<b>M6</b>	<b>(3, 1, 18, 1)</b>	<b>900</b>	<b>0.859</b>	<b>0.859</b>	<b>0.829</b>	<b>0.805</b>
	M7	(2, 3, 12, 1)	500	0.856	0.856	0.832	0.810
	M8	(1, 1, 18, 1)	100	0.851	0.851	0.828	0.811
KARAMAN	<b>M1</b>	<b>(8, 1, 16, 1)</b>	<b>100</b>	<b>0.805</b>	<b>0.805</b>	<b>0.725</b>	<b>0.521</b>
	M2	(7, 9, 3, 1)	100	0.760	0.760	0.752	0.573
	M3	(6, 10, 1, 1)	100	0.739	0.739	0.762	0.572
	M4	(5, 9, 18, 1)	100	0.773	0.773	0.735	0.576
	<b>M5</b>	<b>(4, 6, 13, 1)</b>	<b>200</b>	<b>0.769</b>	<b>0.769</b>	<b>0.744</b>	<b>0.586</b>
	M6	(3, 1, 18, 1)	100	0.725	0.725	0.761	0.571
	M7	(2, 3, 2, 1)	100	0.729	0.728	0.744	0.553
	M8	(1, 2, 19, 1)	300	0.734	0.734	0.751	0.547
KONYA	<b>M1</b>	<b>(8, 3, 15, 1)</b>	<b>100</b>	<b>0.779</b>	<b>0.779</b>	<b>0.877</b>	<b>0.872</b>
	M2	(7, 4, 12, 1)	100	0.656	0.656	0.844	0.839
	M3	(6, 2, 9, 1)	100	0.644	0.644	0.844	0.840
	M4	(5, 3, 15, 1)	100	0.650	0.650	0.854	0.845
	M5	(4, 2, 9, 1)	800	0.650	0.650	0.855	0.852
	M6	(3, 2, 12, 1)	100	0.625	0.625	0.843	0.820
	M7	(2, 4, 7, 1)	300	0.626	0.626	0.844	0.808
	<b>M8</b>	<b>(1, 1, 13, 1)</b>	<b>100</b>	<b>0.628</b>	<b>0.628</b>	<b>0.844</b>	<b>0.796</b>

### 5.3. RBNN Model Uygulaması

RBNN modelleri oluşturulurken, tek gizli katmandan oluşan üç tabakalı YSA mimarisinden faydalanılmıştır. Modellerde dağılım parametresi 0.01'lik artışlarla 0.01–5 arasında seçilirken, gizli katmandaki nöron sayısı 1-20 aralığında incelenmiştir.

Sekiz farklı input kombinasyonu için yapılan denemelere göre en başarılı RBNN modellerine ait sonuçlar Çizelge 5.5'de verilmiştir. En başarılı ağ yapılarının

belirlenmesinde, test verilerine ait en büyük NSE değeri dikkate alınmıştır. Model yapısındaki değerler ise sırası ile, input sayısını, dağılım parametresini, gizli katmandaki nöron sayısını ve output sayısını ifade etmektedir.

Çizelge 5.5. RBNN modellerine ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	Eğitime		Test	
			R <sup>2</sup>	NSE	R <sup>2</sup>	NSE
AKSARAY	<b>M1</b>	<b>(8, 1.08, 15, 1)</b>	<b>0.889</b>	<b>0.889</b>	<b>0.890</b>	<b>0.880</b>
	M2	(7, 0.57, 15, 1)	0.882	0.882	0.854	0.838
	M3	(6, 0.65, 8, 1)	0.858	0.858	0.835	0.828
	M4	(5, 0.73, 14, 1)	0.879	0.879	0.844	0.824
	M5	(4, 0.59, 8, 1)	0.858	0.858	0.846	0.831
	M6	(3, 0.37, 9, 1)	0.857	0.857	0.821	0.802
	<b>M7</b>	<b>(2, 0.37, 9, 1)</b>	<b>0.851</b>	<b>0.851</b>	<b>0.816</b>	<b>0.796</b>
	M8	(1, 0.23, 5, 1)	0.847	0.847	0.822	0.798
KARAMAN	<b>M1</b>	<b>(8, 2.35, 2, 1)</b>	<b>0.786</b>	<b>0.786</b>	<b>0.760</b>	<b>0.542</b>
	M2	(7, 1.35, 2, 1)	0.742	0.742	0.754	0.587
	M3	(6, 4.79, 8, 1)	0.741	0.741	0.762	0.582
	M4	(5, 3.05, 15, 1)	0.745	0.745	0.756	0.577
	<b>M5</b>	<b>(4, 3.07, 9, 1)</b>	<b>0.738</b>	<b>0.738</b>	<b>0.748</b>	<b>0.588</b>
	M6	(3, 3.34, 7, 1)	0.733	0.733	0.744	0.565
	M7	(2, 0.84, 2, 1)	0.708	0.708	0.746	0.573
	M8	(1, 5, 2, 1)	0.716	0.716	0.743	0.565
KONYA	<b>M1</b>	<b>(8, 1.64, 10, 1)</b>	<b>0.811</b>	<b>0.811</b>	<b>0.871</b>	<b>0.870</b>
	M2	(7, 1.91, 4, 1)	0.644	0.644	0.857	0.847
	M3	(6, 3.82, 9, 1)	0.653	0.653	0.847	0.845
	M4	(5, 3.07, 3, 1)	0.649	0.649	0.851	0.845
	M5	(4, 2.67, 6, 1)	0.650	0.650	0.842	0.841
	M6	(3, 2.07, 4, 1)	0.625	0.625	0.828	0.805
	M7	(2, 5, 3, 1)	0.622	0.622	0.840	0.809
	<b>M8</b>	<b>(1, 5, 2, 1)</b>	<b>0.621</b>	<b>0.621</b>	<b>0.828</b>	<b>0.788</b>

RBNN modellerinde de en başarılı input kombinasyonu Aksaray ve Konya istasyonu için M1 modeli olmuştur. RBNN-M1 modellerinde Aksaray istasyonunda NSE=0.880, gizli katmandaki nöron sayısı 15 ve dağılım parametresi 1.08, Konya istasyonunda ise NSE=0.870, gizli katmandaki nöron sayısı 10 ve dağılım parametresi 1.64 olarak elde edilmiştir. M1 kombinasyonu, Aksaray istasyonu için R<sup>2</sup>=0.890 değeri ve Konya istasyonu için R<sup>2</sup>=0.871 değeri de diğer input kombinasyonlarına göre en



başarılı değerlere sahip olup,  $R^2$  ve NSE sonuçlarının her iki istasyonda da birbirini desteklediği görülmektedir.

Aksaray istasyonu için, buharlaşma tahmininde en düşük başarıyı gösteren input kombinasyonu ( $R^2=0.816$ ,  $NSE=0.796$ ) M7 modeli olurken; Konya istasyonunda ( $R^2=0.828$ ,  $NSE=0.788$ ) M8 modeli olarak belirlenmiştir.

Karaman istasyonu için ise en başarılı RBF yapısı, test verisine ait  $NSE=0.588$ ,  $R^2=0.748$ , gizli katmandaki nöron sayısı 9 ve dağılım parametresi 3.07 değerleri ile M5 modelinde görülmüştür. En düşük başarıyı ise,  $NSE=0.542$  ve  $R^2=0.760$  değerleri ile P,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , WS, RH, VP, AP parametrelerinin kullanıldığı M1 modeli göstermektedir.

#### 5.4. GRNN Model Uygulaması

GRNN metodu ile ilgili istasyonlarda aylık buharlaşma miktarını tahmin etmek üzere sekiz farklı input kombinasyonu için dağılım parametresi [0.01 5] aralığında 0.01 artışla test edilmiştir. Sekiz farklı input kombinasyonu ile yapılan denemelere göre en başarılı GRNN modellerine ait sonuçlar Çizelge 5.6'da verilmiştir. Test verilerine ait en büyük NSE değeri, en başarılı ağ yapılarının belirlenmesinde kriter olarak kullanılmıştır. Oluşturulan modellerdeki değerler ise sırası ile; input sayısını, dağılım parametresini ve output sayısını ifade etmektedir.

Denemeler sonucunda en başarılı GRNN yapısı, Aksaray istasyonu için test verisine ait  $NSE=0.831$  değeri ile dağılım parametresinin 0.25 olduğu M1 modelinde elde edilmiştir. Karaman istasyonunda test verisine ait  $NSE=0.519$  değeri ile en başarılı ağ yapısı M4 modelinde elde edilmiş olup; dağılım parametresi 0.19 olarak belirlenmiştir. Konya istasyonunda ise  $NSE=0.811$  değerine sahip dağılım parametresinin 0.13 olduğu M5 modelinde en yüksek başarı elde edilmiştir.

İstasyonlarda buharlaşma tahmininde en düşük başarıyı; Aksaray istasyonu için  $R^2=0.794$  ve  $NSE=0.781$  değerleri ile  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$  parametrelerinin kullanıldığı M6 modeli; Karaman istasyonu için  $R^2=0.722$  ve  $NSE=0.463$  değerleri ile P,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , WS, RH, VP, AP parametrelerinin kullanıldığı M1, Konya istasyonu için ise  $R^2=0.832$  ve  $NSE=0.767$  değerleri ile  $T_{ort}$  parametresinin kullanıldığı M8 modeli göstermektedir.

Çizelge 5.6. GRNN modellerine ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	Eğitme		Test	
			R <sup>2</sup>	NSE	R <sup>2</sup>	NSE
AKSARAY	<b>M1</b>	<b>(8, 0.25, 1)</b>	<b>0.884</b>	<b>0.871</b>	<b>0.836</b>	<b>0.831</b>
	M2	(7, 0.23, 1)	0.871	0.860	0.802	0.794
	M3	(6, 0.18, 1)	0.867	0.860	0.799	0.789
	M4	(5, 0.16, 1)	0.870	0.862	0.807	0.801
	M5	(4, 0.17, 1)	0.848	0.841	0.806	0.802
	<b>M6</b>	<b>(3, 0.14, 1)</b>	<b>0.837</b>	<b>0.833</b>	<b>0.794</b>	<b>0.781</b>
	M7	(2, 0.1, 1)	0.840	0.837	0.811	0.798
	M8	(1, 0.1, 1)	0.845	0.839	0.810	0.801
KARAMAN	<b>M1</b>	<b>(8, 0.33, 1)</b>	<b>0.787</b>	<b>0.753</b>	<b>0.722</b>	<b>0.463</b>
	M2	(7, 0.27, 1)	0.762	0.748	0.727	0.515
	M3	(6, 0.18, 1)	0.762	0.758	0.730	0.509
	<b>M4</b>	<b>(5, 0.19, 1)</b>	<b>0.741</b>	<b>0.736</b>	<b>0.732</b>	<b>0.519</b>
	M5	(4, 0.16, 1)	0.739	0.736	0.725	0.512
	M6	(3, 0.14, 1)	0.727	0.725	0.704	0.491
	M7	(2, 0.11, 1)	0.726	0.724	0.727	0.517
	M8	(1, 0.07, 1)	0.728	0.727	0.735	0.512
KONYA	M1	(8, 0.16, 1)	0.908	0.899	0.838	0.777
	M2	(7, 0.18, 1)	0.709	0.702	0.824	0.776
	M3	(6, 0.16, 1)	0.693	0.686	0.832	0.801
	M4	(5, 0.14, 1)	0.689	0.683	0.841	0.810
	<b>M5</b>	<b>(4, 0.13, 1)</b>	<b>0.683</b>	<b>0.677</b>	<b>0.838</b>	<b>0.811</b>
	M6	(3, 0.10, 1)	0.653	0.650	0.828	0.781
	M7	(2, 0.07, 1)	0.651	0.650	0.844	0.787
	<b>M8</b>	<b>(1, 0.06, 1)</b>	<b>0.628</b>	<b>0.628</b>	<b>0.832</b>	<b>0.767</b>

### 5.5. ANFIS Model Uygulaması

Konya Kapalı Havzası'ndaki üç istasyonun aylık buharlaşma miktarını tahmin etmek üzere ANFIS modelleri geliştirilirken, hem geri-yayımlı (backpropagation) hem de hibrit (hybrid) öğrenme algoritmaları, kuralların oluşturulmasında da eksiltici-kümeleme (subtractive-clustering, SC) tekniği kullanılmıştır. Kurulan ANFIS modellerinde iterasyon sayısı 100 olarak alınmıştır. Subtractive-clustering tekniğinde tüm input kombinasyonları için, accept ratio değeri 0.5, reject ratio değeri 0.15 alınırken, squash factor değerleri 1, 1.25 ve 1.50 alınarak, bu değerlere karşılık range

influence değerleri ise 0.1–1 aralığında 0.1'lik artışlar dikkate alınarak ANFIS modelleri oluşturulmuştur. Elde edilen ANFIS modellerinden, test periyoduna göre en yüksek NSE değerini veren model yapıları Çizelge 5.7'de verilmiştir.

Çizelge 5.7. ANFIS modellerine ait sonuçlar


İstasyon Adı	Model adı	Öğrenme Algoritması	sf	ri	Eğitime		Test	
					R <sup>2</sup>	NSE	R <sup>2</sup>	NSE
AKSARAY	M1	<b>Hibrit</b>	<b>1.25</b>	<b>1</b>	<b>0.893</b>	<b>0.893</b>	<b>0.846</b>	<b>0.818</b>
		Backpropagation	1.25	1	0.892	0.887	0.857	0.802
	M2	<b>Hibrit</b>	<b>1.5</b>	<b>0.9</b>	<b>0.884</b>	<b>0.884</b>	<b>0.820</b>	<b>0.766</b>
		Backpropagation	1.25	0.9	0.879	0.870	0.819	0.780
	M3	Hibrit	1	1	0.875	0.875	0.821	0.775
		Backpropagation	1	1	0.875	0.875	0.821	0.774
	M4	Hibrit	1.5	0.7	0.863	0.863	0.828	0.793
		Backpropagation	1.25	1	0.865	0.865	0.828	0.791
	M5	Hibrit	1.25	0.7	0.861	0.861	0.832	0.805
		Backpropagation	1.25	0.7	0.860	0.860	0.831	0.802
	M6	Hibrit	1	0.6	0.861	0.861	0.819	0.795
		Backpropagation	1	0.5	0.862	0.862	0.820	0.793
	M7	Hibrit	1.5	0.4	0.850	0.850	0.815	0.787
		Backpropagation	1.5	0.4	0.850	0.850	0.813	0.783
	M8	Hibrit	1.25	0.4	0.851	0.851	0.821	0.790
		Backpropagation	1.25	0.4	0.852	0.852	0.827	0.799
KARAMAN	M1	<b>Hibrit</b>	<b>1.5</b>	<b>0.8</b>	<b>0.828</b>	<b>0.828</b>	<b>0.724</b>	<b>0.384</b>
		Backpropagation	1.25	0.9	0.827	0.823	0.719	0.446
	M2	Hibrit	1.5	0.7	0.759	0.759	0.757	0.563
		<b>Backpropagation</b>	<b>1.25</b>	<b>1</b>	<b>0.771</b>	<b>0.766</b>	<b>0.679</b>	<b>0.675</b>
	M3	Hibrit	1.5	0.6	0.740	0.740	0.746	0.552
		Backpropagation	1.5	0.6	0.738	0.738	0.745	0.548
	M4	Hibrit	1.5	0.6	0.734	0.734	0.749	0.559
		Backpropagation	1.5	0.6	0.733	0.733	0.748	0.556
	M5	Hibrit	1.5	0.6	0.730	0.730	0.745	0.564
		Backpropagation	1.5	0.6	0.730	0.730	0.745	0.560
	M6	Hibrit	1.5	0.6	0.726	0.726	0.737	0.535
		Backpropagation	1.25	0.6	0.740	0.740	0.749	0.551
	M7	Hibrit	1.5	0.5	0.725	0.725	0.738	0.530
		Backpropagation	1	0.6	0.727	0.727	0.741	0.536
	M8	Hibrit	1	0.9	0.721	0.721	0.742	0.547
		Backpropagation	1.25	0.8	0.721	0.721	0.742	0.549
KONYA	M1	<b>Hibrit</b>	<b>1.5</b>	<b>1</b>	<b>0.834</b>	<b>0.834</b>	<b>0.849</b>	<b>0.847</b>
		Backpropagation	1.5	0.8	0.792	0.790	0.858	0.840
	M2	Hibrit	1.5	0.6	0.678	0.678	0.808	0.807
		Backpropagation	1.5	0.8	0.668	0.666	0.809	0.807
	M3	Hibrit	1.25	0.7	0.668	0.668	0.835	0.833
		Backpropagation	1	0.8	0.667	0.667	0.834	0.833
	M4	Hibrit	1.25	1	0.654	0.654	0.836	0.835
		Backpropagation	1.25	1	0.654	0.654	0.837	0.835
	M5	Hibrit	1.5	0.8	0.652	0.652	0.839	0.838
		Backpropagation	1.25	0.9	0.652	0.652	0.838	0.837
	M6	Hibrit	1.25	0.6	0.624	0.624	0.836	0.802
		Backpropagation	1.25	0.6	0.624	0.624	0.836	0.802
	M7	Hibrit	1.5	0.6	0.624	0.624	0.841	0.798
		Backpropagation	1.5	0.6	0.624	0.624	0.843	0.802
	M8	<b>Hibrit</b>	<b>1.5</b>	<b>0.5</b>	<b>0.620</b>	<b>0.620</b>	<b>0.834</b>	<b>0.787</b>
		Backpropagation	1.5	0.5	0.620	0.620	0.837	0.791

Çizelge 5.7'ye göre, hibrit ve backpropagation öğrenme algoritmaları, Aksaray ve Konya istasyonu için M1, Karaman istasyonu için ise M2 input kombinasyonunda başarılı olmuştur. En başarılı öğrenme algoritması açısından tahmin başarısı değerlendirilecek olursa, Konya ve Aksaray istasyonu için hibrit, Karaman istasyonu için ise backpropagation tekniği daha başarılı sonuçlar vermiştir. Bu sonuçlara göre, Aksaray istasyonunda  $sf=1.25$ ,  $ri=1.0$  değerlerine karşılık  $NSE=0.818$  değerleri ile M1-hibrit, Karaman istasyonunda  $sf=1.25$ ,  $ri=1.0$  değerlerine karşılık  $NSE=0.675$  değeri ile M2-backpropagation, Konya istasyonu için ise  $sf=1.50$ ,  $ri=1.0$  ile  $NSE=0.847$  değerleri ile M1-hibrit modelleri, buharlaşma tahmininde en başarılı sonuçlar olmuştur. Buharlaşma tahmininde tahmin başarısı en düşük olan ANFIS modelleri ise Aksaray istasyonu için M2, Karaman istasyonu için M1 ve Konya istasyonu için de M8 input kombinasyonlarında olmak üzere her üç istasyonda da hibrit öğrenme algoritmasında elde edilmiştir.


Aksaray ve Konya istasyonu için 2 kurallı, Karaman istasyonu için ise 3 kurallı ANFIS-SC ağ yapısı Şekil 5.1'de görülmektedir.

### 5.6. $\varepsilon$ -DVR Model Uygulaması


$\varepsilon$ -DVR ile aylık buharlaşma tahmininde de aynı input kombinasyonları kullanılarak en başarılı  $\varepsilon$ -DVR modeli belirlenmeye çalışılmıştır. Bu çalışmada çekirdek fonksiyonu olarak literatürde de yaygın olarak kullanılan Radyal Tabanlı çekirdek fonksiyonu kullanılmıştır.  $\varepsilon$ -DVR modellerinin uygulanması sırasında, düzenleme faktörü (C) için [1 100] aralığında 1'er artış, hata terimi ( $\varepsilon$ ) için [0.01 0.5] aralığında 0.01 lik artış, Radyal Tabanlı Çekirdek Fonksiyonuna ait  $\gamma$  parametresi için ise [0.1 8] aralığında 0.1'lik artışlarla farklı input kombinasyonları için denemeler yapılmıştır. Yapılan bu denemelerden elde edilen en başarılı  $\varepsilon$ -DVR modellerine ait sonuçlar Çizelge 5.8'de verilmiştir. Model yapılarındaki değerler sırasıyla; input sayısı, C,  $\varepsilon$ ,  $\gamma$  parametresi değerlerini ve output sayısını ifade etmektedir.



(a)



(b)



(c)

Şekil 5.1. a) Aksaray, b) Karaman, c) Konya istasyonlarına ait ANFIS-SC model yapıları

Çizelge 5.8.  $\varepsilon$ -DVR modellerine ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	Eğitme		Test	
			R <sup>2</sup>	NSE	R <sup>2</sup>	NSE
AKSARAY	<b>M1</b>	<b>(8, 7, 0.11, 0.1, 1)</b>	<b>0.872</b>	<b>0.862</b>	<b>0.886</b>	<b>0.885</b>
	M2	(7, 2, 0.04, 0.8, 1)	0.893	0.892	0.845	0.833
	M3	(6, 2, 0.03, 0.8, 1)	0.877	0.877	0.847	0.834
	M4	(5, 1, 0.03, 1.2, 1)	0.876	0.876	0.848	0.838
	M5	(4, 1, 0.03, 1.7, 1)	0.870	0.870	0.842	0.831
	<b>M6</b>	<b>(3, 1, 0.04, 3.8, 1)</b>	<b>0.863</b>	<b>0.862</b>	<b>0.825</b>	<b>0.806</b>
	M7	(2, 1, 0.21, 1.1, 1)	0.837	0.810	0.817	0.816
	M8	(1, 1, 0.22, 4.1, 1)	0.831	0.799	0.823	0.823
KARAMAN	M1	(8, 1, 0.2, 0.3, 1)	0.787	0.601	0.740	0.736
	<b>M2</b>	<b>(7, 1, 0.21, 0.3, 1)</b>	<b>0.749</b>	<b>0.583</b>	<b>0.750</b>	<b>0.750</b>
	M3	(6, 1, 0.25, 0.3, 1)	0.722	0.575	0.733	0.723
	M4	(5, 1, 0.27, 0.3, 1)	0.716	0.505	0.746	0.742
	M5	(4, 1, 0.27, 0.3, 1)	0.713	0.523	0.742	0.740
	<b>M6</b>	<b>(3, 2, 0.19, 1, 1)</b>	<b>0.713</b>	<b>0.610</b>	<b>0.732</b>	<b>0.716</b>
	M7	(2, 6, 0.21, 0.2, 1)	0.714	0.590	0.745	0.739
	M8	(1, 2, 0.26, 1.3, 1)	0.721	0.519	0.744	0.744
KONYA	<b>M1</b>	<b>(8, 5, 0.12, 0.1, 1)</b>	<b>0.782</b>	<b>0.769</b>	<b>0.876</b>	<b>0.866</b>
	M2	(7, 1, 0.16, 0.1, 1)	0.642	0.606	0.858	0.836
	M3	(6, 2, 0.14, 0.1, 1)	0.648	0.632	0.853	0.837
	M4	(5, 2, 0.14, 0.1, 1)	0.647	0.632	0.854	0.840
	<b>M5</b>	<b>(4, 1, 0.16, 0.1, 1)</b>	<b>0.642</b>	<b>0.612</b>	<b>0.854</b>	<b>0.833</b>
	M6	(3, 47, 0.17, 1.5, 1)	0.636	0.591	0.838	0.838
	M7	(2, 3, 0.18, 0.4, 1)	0.619	0.570	0.843	0.841
	M8	(1, 9, 0.19, 0.3, 1)	0.615	0.553	0.842	0.842

Çizelge 5.8'deki sonuçlara göre; test verilerine ait NSE değerleri dikkate alındığında, Aksaray istasyonunda M1( 8, 7, 0.11, 0.1,1) model yapısı ile NSE= 0.885, R<sup>2</sup>=0.886; Karaman istasyonunda M2( 7, 1, 0.21, 0.3,1) model yapısı ile NSE=0.750, R<sup>2</sup>=0.750; Konya istasyonunda ise M1( 8, 5, 0.12, 0.1,1) model yapısı ile NSE=0.866, R<sup>2</sup>=0.876 değerlerine sahip modeller diğer input kombinasyonlarının kullanılması ile oluşturulan modellerden daha yüksek başarıya ulaşmışlardır.

En düşük başarıyı gösteren input kombinasyonu ise Aksaray (R<sup>2</sup>=0.825, NSE=0.806) ve Karaman istasyonları (R<sup>2</sup>=0.732, NSE=0.716) için M6, Konya istasyonu (R<sup>2</sup>=0.854, NSE=0.833) için ise M5 olmuştur.

### 5.7. Ampirik Denklemler ile Yapay Zeka Metotlarının Karşılaştırılması

Çalışmanın bu bölümünde, incelenen istasyonlar için buharlaşma miktarını tahmin etmek üzere kullanılan yapay zeka metotlarının her birinde elde edilen en başarılı ağ yapıları ile Meyer, Romanenko, Priestley Taylor ve FAO-Penman Monteith denklemlerinin sonuçları karşılaştırılarak bu denklemlere ve en başarılı ağ yapısına sahip yapay zeka metotlarına ait MAE, RMSE ve NSE değerleri Çizelge 5.9'da verilmiştir.

Çizelge 5.9'a göre, yapay zeka metotları, kullanılan input kombinasyonları açısından değerlendirilirse; Aksaray istasyonunun tüm yapay zeka metotlarında M1 kombinasyonu ile en yüksek tahmin başarısına ulaştığı görülmüştür. Karaman istasyonunda MLP-GDX,  $\epsilon$ -DVR ve ANFIS metotlarında M2, MLP-SCG ve RBNN metotlarında M5, GRNN metodunda ise M4 input kombinasyonunun en yüksek tahmin başarısını gösterdiği görülmektedir. Konya istasyonunda GRNN metodunda M5, diğer yapay zekâ metotlarında ise M1 modeli en yüksek başarıyı gösteren input kombinasyonu olmuştur.

Buharlaşma tahmininde kullanılan metotlar arasında en başarılı olan modele ise, test periyoduna ait en yüksek NSE ve en düşük MAE ile RMSE değerlerine göre karar verilmiştir. Yapılan değerlendirmelere göre, Aksaray istasyonunda kullanılan tüm yapay zekâ metotlarının birbirine yakın değerler gösterdiği, ancak MAE=17.990 mm/ay, RMSE=22.723 mm/ay ve NSE=0.885, değerleri ile M1( 8, 7, 0.11, 0.1,1) ağ yapısına ait  $\epsilon$ -DVR metodunun aylık buharlaşma miktarını tahmin etmede en başarılı yapay zeka metodu olduğu görülmüştür. Aksaray istasyonda, en düşük başarıyı gösteren yapay zekâ metodu ise MAE=22.037 mm/ay, RMSE=28.596 mm/ay ve NSE= 0.818 değerleri ile ANFIS olmuştur.

Karaman istasyonunda da  $\epsilon$ -DVR metodu, MAE=21.553 mm/ay, RMSE=29.424 mm/ay ve NSE= 0.750 değerlerine sahip (7, 1, 0.21, 0.3,1) ağ yapısı ile en yüksek tahmin başarısını veren modeldir. Bu istasyonda, en düşük başarıyı gösteren yapay zeka metodu ise MAE=31.822 mm/ay, RMSE=40.851 mm/ay ve NSE= 0.518 değerleri ile GRNN metodu olmuştur.

Çizelge 5.9. Test periyodu için yapay zeka metotları ve ampirik denklemlere ait sonuçlar

İstasyon Adı	Model Adı	Model Yapısı	MAE (mm/ay)	RMSE (mm/ay)	NSE
AKSARAY	MLP-GDX	M1(8, 5,7, 1)	20.138	24.821	0.863
	MLP-SCG	M1(8, 3, 15, 1)	20.600	25.170	0.859
	RBNN	M1(8, 1.08, 15, 1)	18.865	23.250	0.880
	GRNN	M1(8, 0.25, 1)	22.386	27.590	0.831
	ANFIS	M1 (sf=1.25, ri=1, hibrit)	<b>22.037</b>	<b>28.596</b>	<b>0.818</b>
	ε-DVR	<b>M1( 8, 7, 0.11, 0.1,1)</b>	<b>17.990</b>	<b>22.723</b>	<b>0.885</b>
	Meyer		29.592	40.406	0.636
	Romanenko		33.651	40.366	0.636
	Priestley–Taylor		31.568	40.374	0.638
	<b>FAO-Penman–Monteith</b>		<b>18.357</b>	<b>24.553</b>	<b>0.866</b>
KARAMAN	MLP-GDX	M2(7, 13,2, 1)	29.679	37.821	0.587
	MLP-SCG	M5(4, 6, 13, 1)	29.330	37.875	0.586
	RBNN	M5(4, 3.07, 9, 1)	22.969	27.542	0.588
	GRNN	<b>M4(5, 0.19, 1)</b>	<b>31.822</b>	<b>40.851</b>	<b>0.519</b>
	ANFIS	M2(sf=1.25, ri=1, backpropagation)	32.056	42.621	0.675
	ε-DVR	<b>M2 ( 7, 1, 0.21, 0.3,1)</b>	<b>21.553</b>	<b>29.424</b>	<b>0.750</b>
	Meyer		37.766	46.006	0.392
	Romanenko		37.791	45.235	0.411
	Priestley-Taylor		31.755	42.092	0.488
	<b>FAO-Penman–Monteith</b>		<b>29.236</b>	<b>38.657</b>	<b>0.568</b>
KONYA	MLP-GDX	M1(8, 3,15, 1)	22.505	29.158	0.871
	MLP-SCG	<b>M1(8, 3, 15, 1)</b>	<b>22.238</b>	<b>29.124</b>	<b>0.872</b>
	RBNN	M1(8, 1.64, 10, 1)	22.552	29.288	0.870
	GRNN	<b>M5(4, 0.13, 1)</b>	<b>26.188</b>	<b>35.355</b>	<b>0.811</b>
	ANFIS	M1 (sf=1.5, ri=1, hibrit)	24.602	31.737	0.847
	ε-DVR	M1( 8, 5, 0.12, 0.1, 1)	21.460	29.809	0.866
	Meyer		29.294	37.062	0.792
	Romanenko		27.977	37.069	0.792
	Priestley-Taylor		40.524	52.589	0.581
	<b>FAO-Penman–Monteith</b>		<b>26.676</b>	<b>36.911</b>	<b>0.794</b>



Çizelge 5.9'a göre Konya istasyonunda da GRNN metodu, kullanılan yapay zeka metotları arasında MAE=26.188 mm/ay, RMSE=35.355 mm/ay ve NSE=0.811 değerleri ile en düşük başarıyı gösterirken, en yüksek tahmin başarısına sahip model MAE=22.238 mm/ay, RMSE=29.124 mm/ay ve NSE=0.872, değerleri ile MLP-SCG metodu olmuştur. MLP-GDX, RBNN ve  $\epsilon$ -DVR modellerinin başarısı da MLP-SCG metoduna oldukça yakındır. Konya istasyonunda, en düşük başarıyı gösteren yapay zeka metodu ise MAE=26.188 mm/ay, RMSE=35.355 mm/ay ve NSE= 0.811 değerleri ile GRNN metodu olmuştur.

Çizelge 5.9'da verilen, ampirik denklemlere ait sonuçlar incelendiğinde her üç istasyonda da aylık buharlaşma miktarını en başarılı şekilde tahmin eden ampirik denklemin Aksaray istasyonunda MAE=18.357 mm/ay, RMSE=24.553 mm/ay ve NSE=0.866, Karaman istasyonunda MAE=29.236 mm/ay, RMSE=38.657 mm/ay ve NSE=0.568, Konya istasyonunda ise MAE=26.676 mm/ay, RMSE=36.911 mm/ay ve NSE=0.794 değerleri ile FAO-Penman Monteith metodu olduğu görülmektedir.


FAO-Penman-Monteith denklemi Aksaray istasyonu için RBNN ve  $\epsilon$ -DVR hariç diğer yapay zeka metotlarından daha iyi bir başarıya ulaşmıştır. Karaman istasyonu için de FAO-Penman Monteith denkleminin GRNN metodundan daha iyi bir tahmin başarısı gösterdiği görülmektedir.

Aksaray istasyonu için, Meyer (NSE=0.636), Romanenko (NSE=0.636) ve Priestley-Taylor (NSE=0.638) ampirik denklemleri birbirine yakın sonuçlar göstermekle birlikte bu denklemlerin başarısı hem FAO-Penman-Monteith denkleminde hem de kullanılan tüm yapay zeka metotlarından daha düşük kalmıştır.


Karaman istasyonunda Meyer metodu MAE=37.766 mm/ay, RMSE=46.006 mm/ay ve NSE=0.392 değerleriyle, Konya istasyonun da ise Priestley-Taylor denklemi MAE=40.524 mm/ay, RMSE=52.589 mm/ay ve NSE=0.581 değerleriyle buharlaşma tahmininde en düşük başarıya sahip ampirik denklemler olmuştur.

Konya istasyonunda Priestley-Taylor hariç diğer denklemler birbirine oldukça yakın bir performans sergilemiştir.


Kullanılan yapay zeka metotlarına ait en başarılı ağ yapıları ve ampirik denklemlere ait test periyodu için çizilen saçılım diyagramları ise Aksaray, Karaman ve Konya istasyonları için sırasıyla Şekil 5.2, Şekil 5.3 ve Şekil 5.4'de verilmiştir.



Şekil 5.2. Aksaray istasyonu için ampirik denklemler ve en başarılı ağ yapısı ve input kombinasyonuna sahip yapay zeka metodlarına ait test periyodu saçılım diyagramları

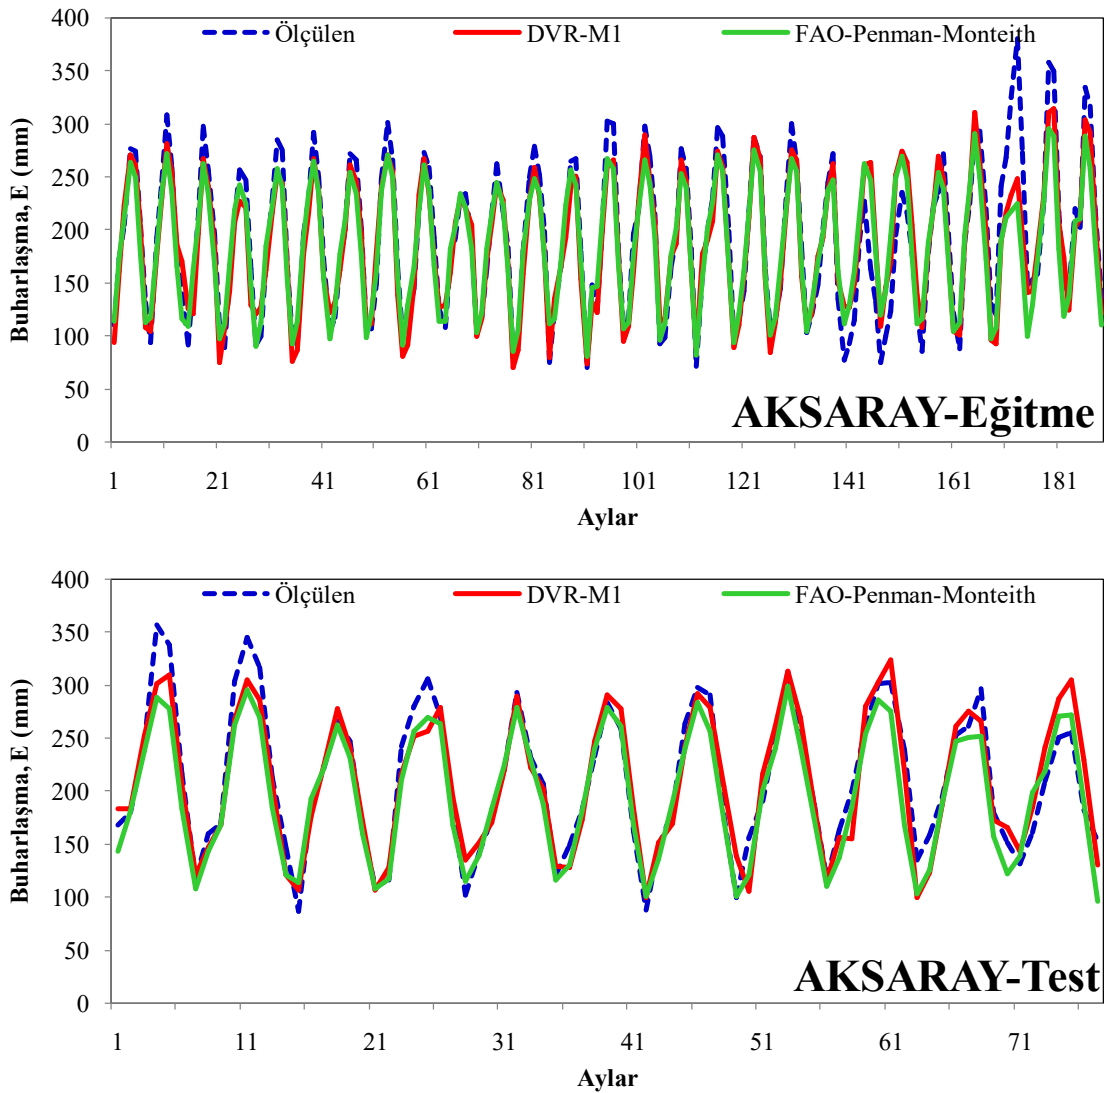


Şekil 5.3. Karaman istasyonu için ampirik denklemler ve en başarılı ağ yapısı ve input kombinasyonuna sahip yapay zeka metodlarına ait test periyodu saçılım diyagramları



Şekil 5.4. Konya istasyonu için ampirik denklemler ve en başarılı ağ yapısı ve input kombinasyonuna sahip yapay zeka metotlarına ait test periyodu saçılım diyagramları

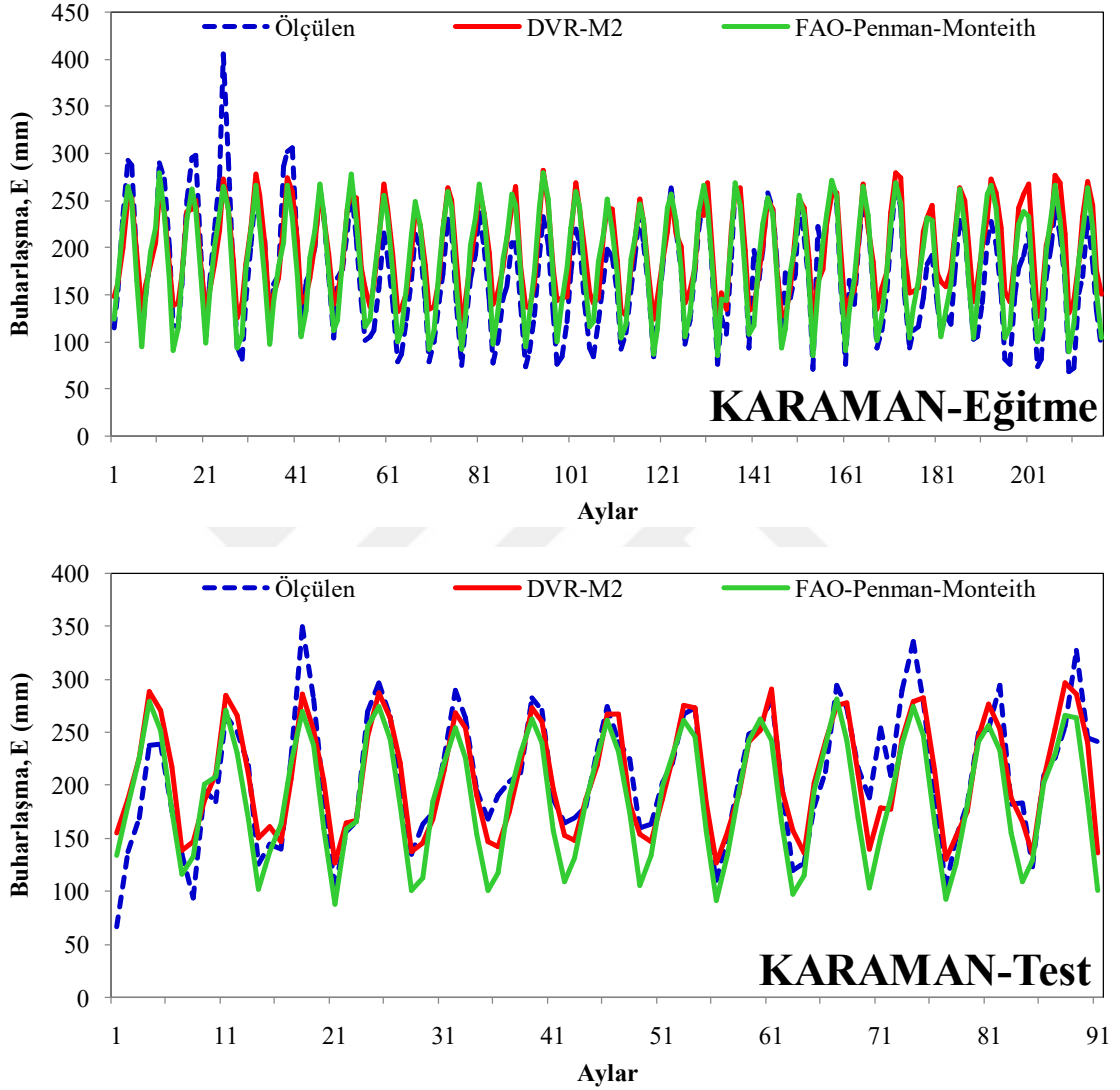
Elde edilen tüm sonuçlar değerlendirildiğinde aylık buharlaşma tahmininde; Aksaray istasyonu için  $C=7$ ,  $\varepsilon=0.11$  ve  $\gamma=0.1$  ağ yapısına sahip  $\varepsilon$ -DVR metodu  $P$ ,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ ,  $WS$ ,  $RH$ ,  $VP$ ,  $AP$  parametrelerinin kullanıldığı M1 kombinasyonunda  $MAE=17.990$  mm/ay,  $RMSE=22.723$  mm/ay ve  $NSE=0.885$  performans değerleri ile en başarılı yapay zeka metodu,  $MAE=18.357$  mm/ay,  $RMSE=24.553$  mm/ay ve  $NSE=0.866$  değerleri ile de FAO-Penman-Monteith, en başarılı ampirik denklem olmuştur. Bu iki metottan elde edilen buharlaşma değerleri ile gerçek buharlaşma değerlerine ait zaman serisi eğitme ve test periyodu için Şekil 5.5’de görülmektedir.



Şekil 5.5. Aksaray istasyonu için eğitim ve test periyoduna ait zaman serisi

Karaman istasyonu için  $C=1$ ,  $\varepsilon=0.21$  ve  $\gamma=0.3$  ağ yapısına sahip  $\varepsilon$ -DVR metodu  $P$ ,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ ,  $RH$ ,  $VP$ ,  $AP$  parametrelerinin kullanıldığı M2 kombinasyonunda  $MAE=21.553$  mm/ay,  $RMSE=29.424$  mm/ay ve  $NSE=0.750$  performans değerleri ile en

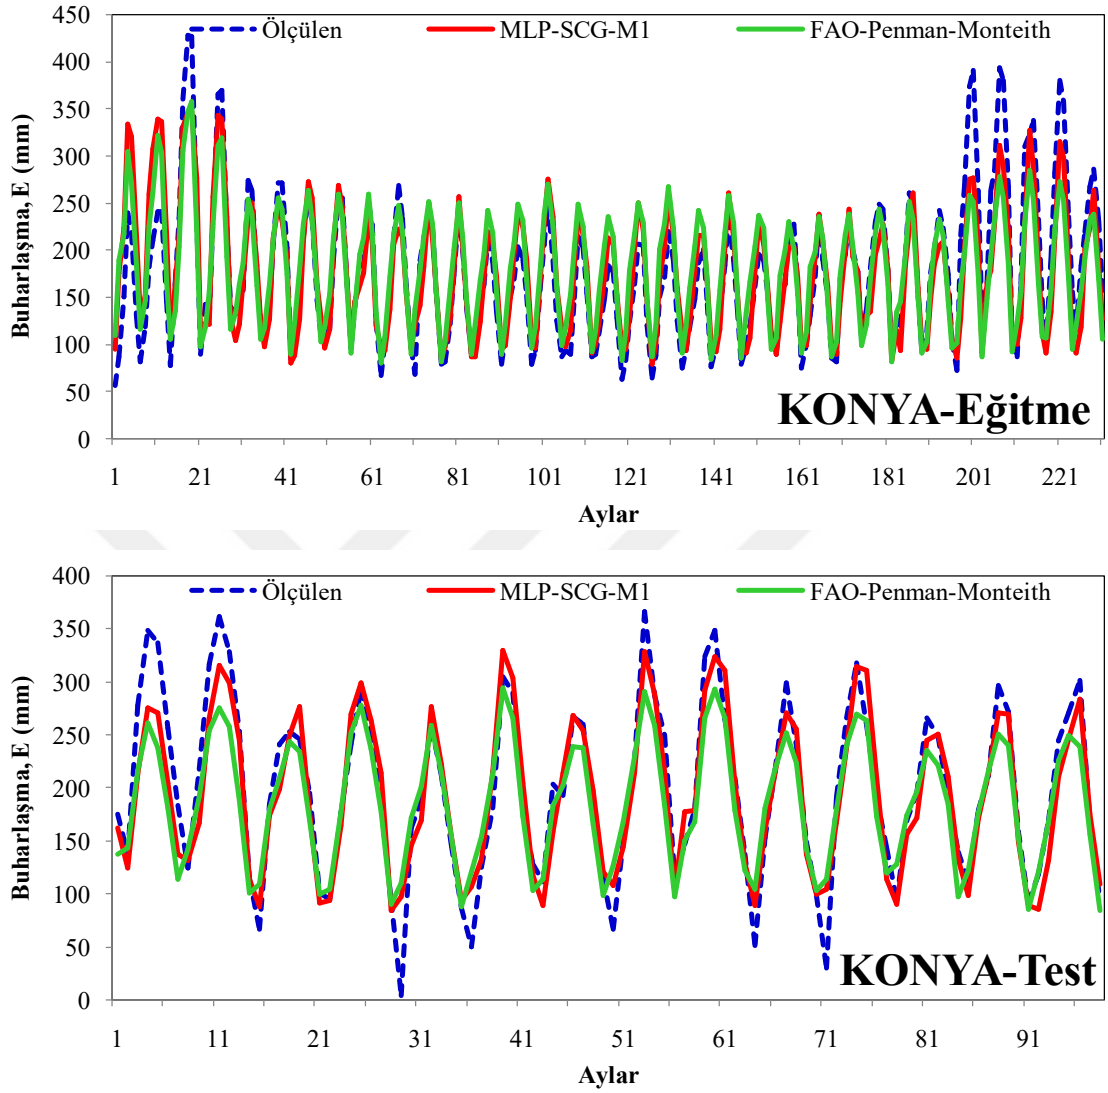
başarılı yapay zeka metodu, MAE=29.236 mm/ay, RMSE=38.657 mm/ay ve NSE=0.568 değerleri ile de FAO-Penman-Monteith, en başarılı ampirik denklem olmuştur. Bu iki metottan elde edilen buharlaşma değerleri ile gerçek buharlaşma değerlerine ait zaman serisi eğitime ve test periyodu için Şekil 5.6'da görülmektedir.



Şekil 5.6. Karaman istasyonu için eğitime ve test periyoduna ait zaman serisi

Konya istasyonunda ise birinci gizli katmanda 3, ikinci gizli katmanda ise 15 nöronun kullanıldığı 100 iterasyonda ve yine P,  $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ , WS, RH, VP, AP parametrelerinin kullanıldığı M1 input kombinasyonunda MLP-SCG metodu MAE=22.238 mm/ay, RMSE=29.124 mm/ay ve NSE=0.872 performans değerleri ile en başarılı yapay zeka metodu, MAE=26.676 mm/ay, RMSE=36.911 mm/ay ve NSE=0.794 değerleri ile de FAO-Penman-Monteith, en başarılı ampirik denklem

olmuştur. Bu iki metottan elde edilen buharlaşma değerleri ile gerçek buharlaşma değerlerine ait zaman serisi eğitime ve test periyodu için Şekil 5.7’de görülmektedir.



Şekil 5.7. Konya istasyonu için eğitime ve test periyoduna ait zaman serisi

## 6. SONUÇLAR VE ÖNERİLER

Çalışma kapsamında Türkiye'nin en kurak havzalarından olan Konya Kapalı Havzası'nda yer alan ve Devlet Meteoroloji İşleri tarafından işletilen Aksaray, Konya ve Karaman istasyonlarına ait aylık açık yüzey buharlaşma miktarının tahmini amaçlanmıştır.

Bu amaçla, üç istasyona ait aylık  $P$ ,  $T_{ort}$ ,  $T_{min}$ ,  $T_{mak}$ ,  $WS$ ,  $RH$ ,  $VP$  ve  $AP$  verileri kullanılarak oluşturulan sekiz farklı input kombinasyonu ile  $\varepsilon$ -DVR, YSA ve ANFIS modelleri kurulmuştur. Ayrıca Meyer, Romanenko, Priestley-Taylor ve FAO-Penman-Monteith ampirik denklemleri ile buharlaşma tahmini yapılmıştır. Yapılan bu modellemelere ait en başarılı ağ yapıları belirlenirken, test periyoduna ait en yüksek NSE ve en düşük MAE ile RMSE değerlerine göre karar verilmiştir.

Elde edilen sonuçlara göre; Aksaray istasyonu için M1 input kombinasyonunun bütün yapay zeka metotlarında en yüksek başarıyı gösterdiği görülmektedir. Aksaray istasyonuna ait yapay zeka metotları kendi içerisinde değerlendirildiğinde NSE değerlerinin birbirine yakın sonuçlar vermesine rağmen en yüksek tahmin başarısının M1(8, 7, 0.11, 0.1, 1) ağ yapısına sahip  $\varepsilon$ -DVR metodunda, en düşük tahmin başarısının ise M1(sf=1.25, ri=1, hibrit) yapısına sahip ANFIS metodunda olduğu sonucuna ulaşılmıştır. Aksaray istasyonuna ait ampirik denklemlerden elde edilen sonuçlara göre, en yüksek tahmin başarısını FAO-Penman-Monteith modeli gösterirken; en düşük tahmin başarısının Romanenko metodunda olduğu görülmüştür.

Karaman istasyonuna ait en başarılı input kombinasyonları, kullanılan yapay zeka metotlarında farklılık göstermektedir. RBNN metodunda M5, GRNN metodunda M4, diğer yapay zeka metotlarında ise M2 en başarılı input kombinasyonu olarak elde edilmiştir. Karaman istasyonu için yapay zeka metotları kendi içerisinde incelendiğinde; M2(7, 1, 0.21, 0.3, 1) ağ yapısı ile  $\varepsilon$ -DVR en başarılı metot olurken, M4(5, 0.19, 1) ağ yapısı ile GRNN en düşük tahmin başarısını gösteren metot olmuştur. Karaman istasyonuna ait, ampirik denklemlerden elde edilen sonuçlara göre en yüksek tahmin başarısını FAO-Penman-Monteith modeli gösterirken; en düşük tahmin başarısının Meyer metodunda olduğu görülmüştür.

Konya istasyonu ise kullanılan tüm yapay zeka metotlarında, test verilerine ait NSE değerleri birbirine yakın sonuçlar göstermiştir. Bu metotlar arasındaki en yüksek tahmin başarısı; M1(8, 3, 15, 1) ağ yapısına sahip MLP-SCG metodu olurken, en düşük başarı M5(4,0.13,1) ağ yapısına sahip GRNN metodunda ortaya çıkmaktadır. Konya



istasyonu için input kombinasyonlarındaki başarı dağılımına bakıldığında ise, GRNN metodunda M5 input kombinasyonu, diğer yapay zeka metotlarında ise M1 modelinin daha başarılı olduğu görülmektedir. Konya istasyonuna ait, ampirik denklemlerden elde edilen sonuçlara göre ise en yüksek tahmin başarısını FAO-Penman-Monteith modeli gösterirken; en düşük tahmin başarısının Priestley-Taylor metodunda olduğu görülmüştür.

Test periyoduna ait NSE değerlerine göre tahmin başarısının belirlendiği her üç istasyondan elde edilen sonuçlara göre, aylık buharlaşma tahmininde, yapay zeka metotlarının ampirik denklemlere göre daha başarılı olduğu sonucuna varılmıştır. FAO-Penman-Monteith metodu ile elde edilen sonuçların da, en başarılı yapay zeka metotlarından elde edilen sonuçlara oldukça yakın sonuçlar ürettiği, hatta Aksaray istasyonunda  $\epsilon$ -DVR hariç diğer yapay zeka metotlarından daha başarılı olduğu tespit edilmiştir. Yapay zeka metotlarından elde edilen sonuçlar ve özellikle FAO-Penman-Monteith eşitliğinin performansı, bu tür modellerin buharlaşma tahmininde kullanılabileceğini göstermektedir.

Gerek iklim değişikliğine bağlı olarak gerek nüfusun artması, teknolojinin ilerlemesi, bilinçsiz su tüketimi gibi nedenlerle su kaynaklarının hızla azalması, yerel ve ulusal yönetim stratejilerinin belirlenmesinde, su kaynaklarının yönetimi konusuna daha çok önem verilmesine neden olmuştur. Su kaynaklarından önemli miktarda kayba neden olan buharlaşma miktarının belirlenmesi çalışmaları bu açıdan oldukça önemlidir.

Ülkemizde de DSİ ve Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü (TAGEM) arasında 2013 yılında imzalanan protokol gereği, bitki su ihtiyaçlarının FAO-Penman-Monteith metoduna göre hesaplanması için gerekli alt yapının oluşturulmasının amaçlandığı dikkate alındığında, buharlaşma miktarının belirlenmesine yönelik yapılan bu tür çalışmaların önemi ortaya çıkmaktadır.

Sonuç olarak; özellikle bu tez çalışmasında ele alınan Konya Kapalı Havzası gibi, kurak ve yarı kurak iklim özelliğine sahip, aynı zamanda da önemli oranda tarım yapılan bölgelerde, buharlaşma miktarının yeterli doğrulukta hesaplanabilmesine yönelik bu tür çalışmalar; sulama suyunun tahmini ve neticesinde sulama projelerinin planlama, proje, işletim safhalarına ve beraberinde su kaynaklarının planlanması ve sürdürülebilir yönetimi çalışmalarına önemli oranda katkı sağlayacaktır.

## KAYNAKLAR

- Afşar, S. (2008),“Yapay sinir ağırları ve bulanık mantık yöntemleri kullanılarak tava buharlaşma tahmini yapılması”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri.
- Akgündoğdu A., Jennane J., Aufort G., Benhamou C. L. and Uçan O. N., 2010, 3D Image Analysis and Artificial Intelligence for Bone Disease Classification, *Journal of Med. Syst*, 34, 815-828.
- Allen, R.G., Pereira, L.S., Raes, D. and Smith, M., 1998, Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements. Irrigation and Drainage Paper 56, *Food and Agriculture Organization of the United Nations (FAO)*, Rome, Italy.
- Altunkaynak, A., 2007, Forecasting surface water level fluctuations of Lake Van by artificial neural networks, *Water Resour Manag.*, 21, 399–408.
- Anonim, 2010, Havza Koruma Eylem Planlarının Hazırlanması Projesi – Konya Kapalı Havzası, *TÜBİTAK MAM Çevre Enstitüsü*, Gebze, Kocaeli, [www.cygm.gov.tr/cygm/anasayfa/sutoprakyonetimi/havzakoruma.aspx?sflang=tr](http://www.cygm.gov.tr/cygm/anasayfa/sutoprakyonetimi/havzakoruma.aspx?sflang=tr)
- Anonim, 2017, Konya Kapalı Havzası Sektörel Su Tahsis Planının Hazırlanmasına Yönelik Teknik Destek Hizmet Alımı İşi, Taslak Su Talepleri Analizi Raporu, Ekim 2017, *T.C. Orman ve Su İşleri Bakanlığı, Su Yönetimi Genel Müdürlüğü*, [www.suyonetimi.gov.tr/Libraries/su/Konya\\_SSTP\\_STAR.sflb.ashx](http://www.suyonetimi.gov.tr/Libraries/su/Konya_SSTP_STAR.sflb.ashx)
- Apan, M., 1982, Çözümlü hidroloji problemleri, *Atatürk Üniversitesi*, Erzurum, 23s
- Arık, S. (2014), “Yapay Sinir Ağları Kullanılarak Hava Veri Bilgisayarı Parametrelerinin Hesaplanması”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri.
- Bayazıt, M., 1999, Hidroloji, İ.T.Ü. *İnşaat Fakültesi Matbaası*, Sayı:1605, 242s. İstanbul.
- Behmanesh, J. and Mehdizadeh, S., 2017, Estimation of soil temperature using gene expression programming and artificial neural networks in a semiarid region, *Environ Earth Sci.* 76(2), 76.
- Broomhead, D. and Lowe D., 1988, Multivariable functional interpolation and adaptive Networks, *Complex Systems* 2(6), 568–576.
- Bruton, J.M., McClendon, R.W. and Hoogenboom, G., 2000, Estimating daily pan evaporation with artificial neural networks, *Transactions of the American Society of Agricultural Engineers*, 43(2), 491-496.
- Büyükyıldız, M., Tezel, G. and Yılmaz, V., 2014, Estimation of the change in lake water level by artificial intelligence methods, *Water Resour Manag*, 28, 4747–4763.

- Can, M. (2012), “Yapay Sinir Ağları ile Akım Tahmini: Mahmudiye Göleti Örneği”, Yüksek Lisans Tezi, *İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Cıgızoğlu, H.K., 2001, YSA ve Zaman Seriler Analizinde Kullanımı, *III. Ulusal Hidroloji Kongresi*, İzmir, 579-586.
- Çelik, C. ve Baynal, K., 2015, ANFIS Yöntemi ile Hava Sıcaklık Tahmininin Modellenmesi, *Uluslararası 9. İstatistik Kongresi*, Antalya, Türkiye.
- Çimen, M., 2008, Estimation of daily suspended sediments using support vector machines, *Hydrological Science Journal*, 53(3), 656–666.
- Deswal, S. and Pal, M., 2008, Modeling of Pan Evaporation Using Support Vector Machines Algorithm, *Journal of Hydrologic Engineering*, 14(1), 104-116.
- Dindar, K.K. (2010), “Yapay sinir ağları yaklaşımı ile Tahtaköprü Barajındaki aylık buharlaşma miktarının tahmini”, Yüksek Lisans Tezi, *Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü*, Antakya.
- Doğan, E., Işık, S. ve Sandalcı, M., 2007, Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi, *İMO Teknik Dergi*, 4119 -4131.
- Doorenbos, J. and Pruitt, W.O., 1975, Guidelines for prediction of crop water requirements, *Food Agr. Org. U.N. Irr. Drainage Paper 24*.
- Doorenbos, J., and Pruitt, W.O., 1977, Guidelines for prediction of crop water requirements, *Food Agr. Org. U.N. Irr. Drainage Paper 24* (revised).
- Efe, M. Ö. ve Kaynak, O., 2004, Yapay Sinir Ağları ve Uygulamaları, *Boğaziçi Üniversitesi Yayınları*.
- Ekici, S. (2007), “Elektrik Güç Sistemlerinde Akıllı Sistemler Yardımıyla Arıza Tipi ve Yerinin Belirlenmesi”, Doktora Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Şanlı Urfa.
- Erastö, P. (2001).“Support Vector Machines-Backgrounds and Practice”, Academic Dissertation for The Degree of Licentiate of Philosophy, *Rolf Nevanlinna Institute*, Helsinki.
- Fırat, M. (2007), “Sinirsel bulanık mantık yaklaşımı ile havza modellemesi”, Doktora Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli.
- Gocic, M., Motamedi, S., Shamshirband, S., Petkovic, D., Ch, S., Hashim, R. and Arif, M., 2015, Soft computing approaches for forecasting reference evapotranspiration, *Comput Electron Agric*, 113, 164–173.
- Goyal, M.K., Bharti, B., Quilty, J., Adamowski, J. and Pandey, A., 2014, Modeling of daily pan evaporation in sub-tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS, *Expert Syst. Appl*, 41 (11), 5267–5276.

- Güldal, V. and Tongal, H., 2010, Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Eğirdir lake level forecasting, *Water Resour Manag.*, 24(1), 105–128.
- Haykin, S., 1994, *Neural Networks*, Macmillan Collage Printing Company, New Jersey, 41.
- Jacobs, A.F.G., Heusinkveld, B. G. and Lucassen, D. C., 1998, Temperature variation in a class A evaporation pan, *Journal of Hydrology*, 206(1-2), 75-83.
- Jang, J.S.R., 1993, ANFIS: Adaptive-Network-Based Fuzzy Inference System, *Systems, Man and Cybernetics, IEEE Transactions on*, 23(3), 665-685.
- Kaya, Y.Z. (2016), “Bulanık Mantık Yöntemi ile mevsimsel verilere dayalı buharlaşma tahmini”, Yüksek Lisans Tezi, *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü*, Osmaniye.
- Keskin, M.E., Taylan, D. and Terzi, Ö, 2006, Adaptive neural-based fuzzy inference system (ANFIS) approach for modelling hydrological time series, *Hydrol Sci. J.*, 51(4), 588–598.
- Kişi, Ö. and Parmar, K.S., 2016, Application of least square support vector machine and multivariate adaptive regression spline models in long term prediction of river water pollution, *Journal of Hydrology*, 534, 104–112.
- Malkoç, Y., 2007, Türkiye Elektrik Enerjisi İhtiyacının Karşılanmasında Rüzgâr Enerjisinin Yeri, *EİE İdaresi Genel Müdürlüğü*, 3: 45–50.
- Mason, J.C., Price, R.K. and Tem'ne, A., 1996, A neural network model of rainfall runoff using radial basis functions, *Journal of Hydraulic Research*, 34(4), 537–548.
- Mehdizadeh, S., Behmanesh, J. and Khalili, K., 2016, Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation, *J. Atmos Sol Terr Phys*, 146, 215–227.
- Mehdizadeh, S., Behmanesh, J. and Khalili, K., 2017, Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapotranspiration, *Computers and Electronics in Agriculture*, 139, 103–114.
- Meyer, A., 1915, Evaporation of surface water bodies, A compendium of Water Resources Technology, *McGraw-Hill Book Company*.
- Mohandes, M.A., 2012, Modeling global solar radiation using particle swarm optimization (PSO), *Sol Energy*, 86, 3137–3145.
- Monteith, J.L., 1965, Evaporation and Environment. In: *The state and movement of water in living organism, 19th Symp. Soc. Exptl. Biol.* P. 205-234.

- Oğul, E. (2006), “Yağış–Akış İlişkisinin Yapay Sinir Ağı Yöntemleriyle Modellenmesi: Kurukavak Havzası Uygulaması”, Yüksek Lisans Tezi, *Anadolu Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir.
- Okkan, U. ve Dalkılıç, H.Y., 2012, Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi, *İMO Teknik Dergi*, 5957-5966.
- Önal, S. (2009), “Yapay Sinir Ağları Metodu İle Kızılırmak Nehri’nin Akım Tahmini”, Yüksek Lisans Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.
- Öztemel, E., 2003.,Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul, 28-110s.
- Öztürk, K., 2002, Küresel İklim Değişikliği ve Türkiye’ye Olası Etkileri, *G.Ü. Gazi Eğitim Fakültesi Dergisi*, 22(1), 47-65.
- Öztürk, M., Hançer, M., Ulutaş, M.S., Can, M., Tartık, M., Günel, A., Şahin, U., Şahin, A.D. ve Akyüz D.E., 2010, Bulanık Mantık Hesaplamalarına Dayalı Bulanık Mantık Hesaplamalarına Dayalı Binalarda Isı Kayıp-Kazanç Yaklaşımı, *Bilimde Modern Yöntemler Sempozyumu-BMYS*, Diyarbakır.
- Paredes, V. and Vidal, E., 2000, A class-dependent weighted dissimilarity measure for nearest neighbor classification problems, *Pattern Recogn Lett*, 21:1027–1036.
- Park, J., 2006, “Uncertainty and Sensitivity Analysis in Support Vector Machines: Robust Optimization and Uncertain Programming Approaches”, Doctoral Dissertation, *The University of Oklahoma Norman, OK, USA*.
- Penman, H.L., 1948, Natural evaporation from open water, bare soil and grass. Proc. Royal Soc. London, *Mathematical and Physical Sciences*, 193 (1032), 120-145.
- Priestley, C.H.B. and Taylor, R.J., 1972, On the assessment of the surface heat flux and evaporation using large-scale parameters, *Monthly Weather Review*, 100, 81-92.
- Romanenko, V.A., 1961, Computation of the autumn soil moisture using a universal relationship for a large area, *Proceedings Ukrainian Hydrometeorological Research Institute: 3*. Kiev.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986, Learning representations by backpropagation error, *Letters to Nature*, 32, 533-536.
- Sajkumar, N. and Thandaveswara, B.S., 1999, A non-linear rainfall runoff model using an artificial neural network, *Journal of Hydrologic Engineering*, 216, 32-55.
- Saraç, E. (2012), “Bir Çağrı Merkezindeki Projelerin Anfis Metodu ile Değerlendirilmesi ve Seçimi”, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

- Shawkat A. and Ajith A., 2002, Soft Computing Systems: Design, Management and Application, *an Empirical Comparison of Kernel Selection for Support Vector Machines, Proceedings of the 2nd International Conference on Hybrid Intelligent Systems*, Amsterdam – The Netherlands, 233.
- Shiri, J., Marti, P. and Singh, V.P., 2014, Evaluation of gene expression programming approaches for estimating daily evaporation through spatial and temporal data scanning, *Hydrol. Process*, 28 (3), 1215–1225.
- Shirmohammadi, B., Vafakhah, M., Moosavi, V. and Moghaddamnia, A., 2013, Application of several data-driven techniques for predicting ground water level, *Water Resour Manag*, 27(2), 419–432.
- Specht, D. F., 1991, A General Regression Neural Network, *IEEE Transactionson Neural Networks*, 2, 568-576.
- Sudheer, C., Maheswaran, R., Panigrahi, B.K. and Mathur S., 2014, A hybrid SVM-PSO model for forecasting monthly streamflow, *Neural. Comput. and Applic*, 24, 1381–1389.
- Sürel, A. (2006), “Genelleştirilmiş Regresyon Yapay Sinir Ağının Su Kaynakları Mühendisliğinde Kullanımı”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Şen, Z., 2004, Yapay sinir ağları ilkeleri, *Su Vakfı Yayınları*, 183.
- Şen, E. ve Başaran, N., 2007, Küresel Isınma Sürecinde Konya Ovasının Baz İklim Verilerinde Meydana Gelen Değişmeler ve Eğilimler, *Uluslararası Küresel İklim Değişikliği ve Çevresel Etkileri Konferansı*, Konya.
- Terzi, Ö. (2004), “Eğirdir Gölü’ne Ait Buharlaşıma Modellerinin Geliştirilmesi ve Uygulanması”, Doktora Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.
- Thirumalaiah, K. and Deo, M., 2000, Hydrological Forecasting Using Neural Networks, *Journal of Hydrologic Engineering*, 5(2), 180-189.
- Tokar, A.S. and Markus, M., 2000, Precipitation-Runoff Modelling Using Artificial Neural Networks and Conceptual Models, *Journal of Hydrologic Engineering*, 5(2), 156-161.
- Tsoukalas, L. and Uhrig, R., 1996, Neuro fuzzy approach for anticipatory control of complex systems, *IEEE International Conference in Fuzzy Systems*, 1, 587-593.
- Turhan, E. (2012). “Seyhan Havzasının Yağış – Akış İlişkisinin Yapay Sinir Ağı Yöntemi İle Modellenmesi”, Yüksek Lisans Tezi, *Çukurova Üniversitesi Fen Bilimleri Enstitüsü*, Adana.

- Ünsal, M. (2007), “Suların Havalandırılmasında Yüksek basınçlı ve Serbest Yüzeyle Konduitlerin Kullanılması”, Doktora Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Şanlı Urfa.
- Vapnik, V. N., 1995, The Nature of Statistical Learning Theory, *Springer and Verlag*, NewYork.
- Vapnik, V.N., 1998, Statistical Learning Theory, *John Wiley and Sons*, New York.
- World Meteorological Organization, 2012, International Glossary of Hydrology (ISBN 978-92-63-03385-8), WMO-No. 385.
- Wu, C.L., Chau, K.W. and Fan, C., 2010, Prediction of rainfall time series using modular artificial neural Networks coupled with data-preprocessing techniques, *J.Hydrol.*, 389, 146–167.
- Xu, C.Y. and Singh V.P., 2000, Evaluation and generalization of radiation-based methods for calculating evaporation, *Hydrological Processes*, 14(2), 339-349.
- Yarar, A. (2004), “Beyşehir Gölü su seviyesi değişimlerinin yapay sinir ağları ile belirlenmesi”, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Yaseen, F.A. (2016), “ANFIS Yönteminin Esnek Yol Üstyapılarının Yapısal Analizinde Kullanılabilirliği”, Yüksek Lisans Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.
- Zhao, S. and Wang, L., 2010, Support vector regression based on particle swarm optimization for rainfall forecasting, *Third International Joint Conference on Computational Science and Optimization*.

<https://www.mgm.gov.tr/tarim/referans-toplam-buharlasma.aspx>

<http://www.dsi.gov.tr/toprak-ve-su-kaynaklari>

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Ayşe ÖZEL  
**Uyruğu** : T.C  
**Doğum Yeri ve Tarihi** : Konya / 01.01.1991  
**Telefon** : 0 538 507 0089  
**Faks** : -  
**e-mail** : aysapinarkara@gmail.com

### EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Karatay Süleyman Demirel Milli Piyango Anadolu Lisesi, Konya	2009
Üniversite	: Selçuk Üniversitesi Mühendislik Fakültesi	2013

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
-----	-------	--------

**UZMANLIK ALANI:** Hidroloji

**YABANCI DİLLER:** İngilizce

### BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

### YAYINLAR

Ozel, A. and Buyukyildiz, M., 2018, Estimation of Monthly Pan Evaporation Using ANFIS Technique, International Symposium for Environmental Science and Engineering Research (ISESER), Konya.