

## AYLIK BUHARLAŞMA TAHMİNİNDE YAPAY ZEKA YÖNTEMLERİNİN KULLANILABİLİRLİĞİ

Ayşe ÖZEL<sup>1</sup> (ORCID: 0000-0002-0632-8563)  
Meral BÜYÜKYILDIZ<sup>1</sup> (ORCID: 0000-0003-1426-3314)\*

<sup>1,2</sup> Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, İnşaat Mühendisliği Bölümü, Konya, Türkiye

Geliş / Received: 30.10.2018  
Kabul / Accepted: 07.01.2019

### ÖZ

Hidrolojik çevrimin en önemli bileşenlerinden biri olan buharlaşma pek çok faktörün etkisindedir. Buharlaşma; bu kompleks yapısından dolayı tahmin edilmesi zor bir meteorolojik parametredir. Bu çalışmada, Konya Kapalı Havzası'nda yer alan Karaman istasyonuna ait meteorolojik parametreler kullanılarak oluşturulan farklı giriş kombinasyonları ile aylık buharlaşma miktarı tahmin edilmiştir. Bu amaçla Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (DVR), Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) metotları kullanılmıştır. Sonuç olarak DVR, aylık buharlaşma tahmininde diğer metotlardan daha başarılı olmuştur.

**Anahtar kelimeler:** Buharlaşma, yapay sinir ağları, destek vektör regresyonu, su kaynakları

## USABILITY OF ARTIFICIAL INTELLIGENCE METHODS FOR ESTIMATION OF MONTHLY EVAPORATION

### ABSTRACT

Evaporation, one of the most important components of the hydrological cycle, is influenced by many factors. Evaporation is a meteorological parameter that is difficult to predict due to this complex structure. In this study, the amount of monthly evaporation was estimated using different input combinations formed by meteorological parameters belonging to Karaman station in Konya Closed Basin. For this purpose, Artificial Neural Networks (ANN), Support Vector Regression (SVR), Adaptive Network Based Fuzzy Inference System (ANFIS) methods are used. As a result, SVR has been more successful than other methods in monthly evaporation prediction.

**Keywords:** Evaporation, artificial neural networks, support vector regression, water resources

### 1. GİRİŞ

Buharlaşma hidrolojik çevrimin en önemli bileşenlerinden birisidir. Buharlaşma miktarının yeterli doğrulukta hesaplanabilmesine yönelik çalışmalar; özellikle kurak ve yarı kurak iklim yapısına sahip bölgelerde sulama suyu tahmini, sulama projelerinin planlanması, işletilmesi ve beraberinde su kaynaklarının planlanması ve sürdürülebilir yönetimi açısından oldukça önemlidir. Ancak pek çok meteorolojik, topoğrafik ve coğrafik faktörün etkisinde olması sebebiyle karmaşık bir yapıya sahip olan buharlaşmanın belirlenmesi oldukça zordur. A sınıfı buharlaşma tavası, lizimetre gibi aletlerle doğrudan ölçülebilen buharlaşma; su dengesi, kütle transferi, enerji dengesi gibi metotlar veya geliştirilen çeşitli ampirik denklemler yardımıyla dolaylı olarak hesaplanabilir. Bununla birlikte son yıllarda, hidrolojik ve meteorolojik parametrelerin tahmin edilmesinde yaygın olarak kullanılan yapay zekâ metotları ile de buharlaşma tahmini yapılmaktadır [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16].

\*Corresponding author / Sorumlu yazar. Tel.:+90 332 223 2139 ; e-mail / e-posta: mbuyukyildiz@ktun.edu.tr

*AYLIK BUHARLAŞMA TAHMİNİNDE YAPAY ZEKA YÖNTEMLERİNİN KULLANILABİLİRLİĞİ*

Deswal ve Pal [17], Shegaon'da bulunan Anand Sagar Rezervuarı'nın yakınındaki Manasgoan istasyonuna ait sıcaklık, rüzgâr hızı, güneşlenme saati ve bağıl nem parametrelerini içeren giriş parametrelerini kullanarak Destek Vektör Makineleri (DVM) yöntemi ile buharlaşma tahmini yapmayı amaçlamışlardır. DVM'nin performansı ayrıca çoklu doğrusal regresyon (ÇDR) ile karşılaştırılmış ve sonuç olarak DVM'nin buharlaşma tahmininde daha başarılı olduğu sonucuna varılmıştır. Shiri ve ark. [5], 6 farklı istasyona ait günlük iklimsel verileri kullanarak buharlaşma tahmini yapmak amacıyla Gen Ekspresyon Programlama (GEP) modeli ile, konuma ve zamana bağlı veri tarama tekniklerini kullanmışlardır. Bu modellerden elde edilen sonuçlar ayrıca ampirik fiziksel model sonuçları ile karşılaştırılmış ve GEP modelinin daha başarılı olduğu sonucuna varılmıştır. Goyal ve ark. [18], Hindistan'ın Karso Havzası'nda günlük tava buharlaşması miktarının tahmini için, YSA, en küçük kareler- destek vektör regresyonu (EKK-DVR), bulanık mantık (BM) ve ANFIS yapay zeka modellerini kullanmış, sonuçları Hargreaves-Samani ve Stephen-Stewart ampirik denklemleri ile de karşılaştırmıştır. Mehdizadeh ve ark. [19], İran'da yaptıkları çalışmada, aylık ortalama referans evapotranspirasyon miktarının ( $ET_0$ ) tahmini için, 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 (ÇDARS) metodlarının performansını araştırmıştır.

Bu çalışmanın amacı, Türkiye'de Konya Kapalı Havzası'nda bulunan Karaman meteoroloji istasyonuna ait aylık toplam açık yüzey buharlaşma miktarının yapay zeka teknikleri ile tahmin edilmesidir.

## 2. METOT

Bu çalışmada, aylık buharlaşma miktarını tahmin etmek üzere, Genelleştirilmiş Regresyon Yapay Sinir Ağları (GRYSA), Radyal Tabanlı Yapay Sinir Ağları (RTYSA) ile birlikte, Çok Katmanlı Algılayıcı (ÇKA) YSA tekniklerinden 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 algoritması, Epsilon-Destek Vektör Regresyonu ( $\epsilon$ -DVR) ve ANFIS yapay zeka metodları kullanılmıştır [20].

### 2.1. Genelleştirilmiş Regresyon Yapay Sinir Ağları (GRYSA)

GRYSA, radyal tabanlı çalışan ve genellikle tahminleyici olarak kullanılan denetimli-öğrenimli bir YSA modeli olup Specht [21] tarafından geliştirilmiş, iteratif eğitim prosedürü gerektirmeyen bir metottur. Kolay modellenebilmesi, hızlı ve tutarlı sonuçlar üretmesi gibi avantajlara sahip olan GRYSA'da, çok fazla eğitim veri setinin olması halinde işlem sayısı ve ihtiyaç duyulan bellek miktarı artmaktadır [22].

### 2.2. Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

Broomhead ve Lowe [23] tarafından geliştirilen RTYSA metodunda temel prensip, bir grup radyal taban fonksiyonunu ağırlıklandırarak toplayıp, olması istenen  $f(x)$  fonksiyonuna yaklaşmaktır. Radyal tabanlı fonksiyonlarda, klasik YSA yapısından farklı olarak, giriş katmanı ile gizli katman arasında radyal tabanlı aktivasyon fonksiyonları ve lineer olmayan bir kümeleme analizi kullanılmaktadır. Esas eğitim ise YSA yapılarında olduğu gibi gizli katman ve çıktı katmanı arasında gerçekleşmektedir [24].

### 2.3. Çok Katmanlı Algılayıcı Yapay Sinir Ağları (ÇKAYSA)

Giriş ve çıkış katmanının dışında bir veya daha fazla ara katmandan oluşan ÇKAYSA, çoğunlukla lineer olmayan problemlerde kullanılan bir YSA modelidir. ÇKAYSA, ağırlıkları optimize ederek, ağırlık ürettiği çıkış ile gerçek çıkış arasındaki hatayı minimuma indirme amacına dayanmakta olup, bu amaç için danışmanlı öğrenme yöntemini kullanmaktadır. Bu çalışmada ÇKAYSA öğrenme algoritmaları olarak SCG [25] ve GDX [26] öğrenme algoritması kullanılmıştır.

### 2.4. Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

Jang [27] tarafından ortaya atılan ve YSA ile bulanık mantığın bir arada kullanılması fikrine dayanan ANFIS ile, yapay sinir ağlarının özelliği olan öğrenme ve hesap etme yeteneği, bulanık mantık çıkarım sistemlerine sağlanmaktadır. Aynı şekilde, bulanık mantık çıkarımının sahip olduğu karar verme ve uzman bilgisi sağlama yeteneği de yapay sinir ağlarına verilmektedir. Bu fikir sayesinde iki modelin üstün özellikleri bir arada

A. ÖZEL, M. BÜYÜKYILDIZ

kullanılabilmektedir. ANFIS, yalnız Sugeno tipi modelleri çalıştırmaktadır. Bu modelleme tipi, girdilerin bir fonksiyonu şeklinde üyelik fonksiyonlarına sahip olan çıktı değişkenlerinden oluşmaktadır. ANFIS ağ yapısı 6 katmandan oluşmaktadır. Bu katmanlar sırasıyla; giriş, bulanıklaştırma, kural, normalizasyon, arındırma ve toplam katmandır.

### 2.5. Destek Vektör Makineleri ( DVM )

DVM, Vapnik [28] tarafından önce sınıflandırma (DVM) problemleri için sonrasında ise regresyon (DVR) tipi problemler için ortaya atılmış olup, istatistiksel öğrenme teorisi ile yapısal risk minimizasyonu ilkesini temel almaktadır [28, 29]. DVM yapı olarak; istatistik, makine öğrenmesi ve sinir ağlarını çeşitli şekilde birleştirmektedir. Destek Vektör Regresyonunun (DVR) tahmin performansında etkili olan parametreler; duyarlılık hata terimi ( $\epsilon$ ), düzenleme faktörü (C), kernel fonksiyonunun türü ve kernel parametresidir. Bu parametrelerden  $\epsilon$ ; hatanın ihmal edildiği aralığı gösterirken bu değerin azalması DVR'deki destek vektör sayısının artmasına neden olmaktadır. C ise, ağırlık vektörü ve karakterize edilmiş sistem karışıklığıyla beraberindeki duyarlılık değişkenler ve ölçülen tahmin hataları arasındaki düzeni sağlamak amacıyla [30]. Kullanılan çekirdek fonksiyonu ve model parametrelerinin seçimi DVR modellerinin performansında önemli rol oynamakta olup, bunların seçimi ile ilgili belirleyici bir kriter yoktur. En uygun değerler deneme yanılma ile belirlenmektedir. DVR modellerinde tercih edilen çekirdek fonksiyonları Tablo 1'de görülmektedir.

**Tablo 1.** Yaygın olarak kullanılan çekirdek fonksiyonları

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

### 2.6. Performans Kriterleri

Yapay zekâ metotlarının kullanılması sonucu elde edilen modellerin performansları; ortalama mutlak hata (OMH), karekök ortalama karesel hata (KOKH), determinasyon katsayısı ( $R^2$ ) ve Nash-Sutcliffe etkinlik katsayısı ( $E_{Nash}$ ) ile değerlendirilmiştir.

$$OMH = \frac{1}{N} \sum_{i=1}^N |Y_{i_{gözlem}} - Y_{i_{ta\min}}| \tag{1}$$

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{i_{gözlem}} - Y_{i_{ta\min}})^2} \tag{2}$$

$$R^2 = \frac{\left[ \sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})(Y_{i_{tahmin}} - \bar{Y}_{tahmin}) \right]^2}{\sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})^2 \sum_{i=1}^N (Y_{i_{tahmin}} - \bar{Y}_{tahmin})^2} \tag{3}$$

$$E_{Nash} = 1 - \frac{\sum_{i=1}^N (Y_{i_{gözlem}} - Y_{i_{ta\min}})^2}{\sum_{i=1}^N (Y_{i_{gözlem}} - \bar{Y}_{gözlem})^2} \tag{4}$$

$\epsilon$ -DVR metodu için LIBSVM Software programı kullanılmış, tüm yapay zekâ metotlarına ait uygulamalar ise MATLAB 2014a ile yapılmıştır.

### 3. ÇALIŞMA ALANI VE DATA

Bu çalışmada, Türkiye'nin en büyük ve kurak kapalı havzalarından biri olan Konya Kapalı Havzası'nda bulunan ve Devlet Meteoroloji İşleri (DMI) tarafından işletilen Karaman meteoroloji istasyonuna ait meteorolojik veriler kullanılarak aylık açık yüzey buharlaşma (E) tahmini yapılmıştır.

İç Anadolu Bölgesi'nin güneyinde yer alan ve 3 ilçesi Konya Kapalı Havzası içerisinde bulunan Karaman ilinde karasal iklim hakim olup, yağış miktarının 2.8-6.4 mm'ye kadar düştüğü gözlenir [31]. Bu çalışmada kullanılan Karaman meteoroloji istasyonu (İstasyon No: 17246) 37.11 enlem ve 33.13 boylamı arasında 1025 m yükseklikte bulunmaktadır.

Çalışmada 1967-2010 gözlem periyodu arasındaki veriler kullanılmıştır. Aylık buharlaşma miktarını tahmin etmek üzere kullanılan meteorolojik veriler; aylık toplam yağış (P), ortalama, minimum ve maksimum sıcaklık ( $T_{ort}$ ,  $T_{min}$ ,  $T_{max}$ ), rüzgâr hızı (WS), nispi nem (RH), buhar basıncı (VP) ve atmosferik basınç (AP) verileridir. Kullanılan parametrelere ait bazı özellikler Tablo 2'de görülmektedir.

**Tablo 2.** Karaman istasyonuna ait meteorolojik parametrelerin istatistiksel karakteristikleri

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

### 4. UYGULAMA VE SONUÇLAR

Karaman meteoroloji istasyonu aylık buharlaşma tahmini için ÇKAYSA (SCG – GDX), RTYSA, GRYSA, ANFIS, ε-DVR modellerinden oluşan yapay zekâ metotları kullanılmıştır. Yapay zekâ metotları uygulanmadan önce, giriş ve çıkış katmanında kullanılan parametrelerdeki birim farklılığını ortadan kaldırmak amacıyla Eşitlik (5) kullanılarak veriler 0 ile 1 arasında boyutsuz hale getirilmiştir.

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \tag{5}$$

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

Aylık buharlaşma (E) miktarını (çıkış) tahmin etmek amacıyla, giriş katmanında, meteorolojik parametrelerden oluşan sekiz farklı giriş kombinasyonu kullanılmıştır (Tablo 3).

**Tablo 3.** Kullanılan giriş kombinasyonları

Model Adı	Giriş Parametreleri	Çıkış
<b>M1</b>	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , WS, RH, VP, AP	
<b>M2</b>	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH, VP, AP	
<b>M3</b>	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH, VP	
<b>M4</b>	P, $T_{ort}$ , $T_{min}$ , $T_{max}$ , RH	
<b>M5</b>	$T_{ort}$ , $T_{min}$ , $T_{max}$ , RH	E
<b>M6</b>	$T_{ort}$ , $T_{min}$ , $T_{max}$	
<b>M7</b>	$T_{ort}$ , $T_{max}$	
<b>M8</b>	$T_{ort}$	

A. ÖZEL, M. BÜYÜKYILDIZ

Çalışmada kullanılan gözlem periyodu için, yıllara göre ölçüm yapılan aylar farklılık gösterdiği için, Karaman istasyonun da ölçümü tam olan ortak aylar göz önünde bulundurulmuş olup, ay bazında bu ortak periyot 1 Nisan-31 Ekim tarihleri arasındaki gözlemleri içermektedir. Buna göre Karaman istasyonu için 1967-2010 periyodunda verisi mevcut olan 308 ay bulunmaktadır. 308 aylık verinin yaklaşık %70’i (1967-1997 periyodundaki 217 aylık veri) eğitime, %30’u (1998-2010 periyodundaki 91 aylık veri) ise test aşamasında kullanılmıştır.

#### 4.1. ÇKA – GDX Uygulaması ve Sonuçları

Sekiz farklı giriş kombinasyonu kullanılarak ÇKA- GDX modelleri kurulurken, iki gizli katmandan oluşan dört tabakalı YSA mimarisi kullanılmıştır. Kurulan modellerde, gizli katmanlarda tanjant sigmoid, çıkış katmanında ise logaritmik sigmoid aktivasyon fonksiyonu kullanılmıştır. ÇKA-GDX modellerinde momentum katsayısı 0.8, iterasyon sayısı ise 1000 olarak alınmıştır. Gizli katmanlarda nöron sayısı 1-20 aralığında, öğrenme oranı ( $lr$ ) 0.1-1 arasında incelenmiştir. Bu kabuller neticesinde yapılan denemelerden elde edilen en başarılı ÇKA-GDX modellerine ait sonuçlar Tablo 4’de verilmiştir.

**Tablo 4.** ÇKA-GDX modellerine ait sonuçlar

Model Adı	Model Yapısı	lr	Eğitime		Test	
			R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
M1	(8, 1, 16, 1)	0.1	0.779	0.779	0.734	0.554
<b>M2</b>	<b>(7, 13, 2, 1)</b>	<b>0.7</b>	<b>0.766</b>	<b>0.766</b>	<b>0.752</b>	<b>0.587</b>
<b>M3</b>	<b>(6, 10, 1, 1)</b>	<b>0.4</b>	<b>0.760</b>	<b>0.760</b>	<b>0.750</b>	<b>0.544</b>
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, 1 5, 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

Tablo 4’ e göre, model yapısındaki ilk değer giriş sayısını, ikinci ve üçüncü değerler gizli katmanlarda bulunan nöron sayısını, son değer ise çıkış sayısını göstermektedir. En başarılı ağ yapısı; test periyoduna ait en büyük E<sub>Nash</sub> değerine göre belirlenmiştir.

Karaman istasyonunda en başarılı GDX yapısı, E<sub>Nash</sub>=0.587 (R<sup>2</sup>=0.752) değeri ile P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, RH, VP, AP parametrelerinin kullanıldığı M2 kombinasyonunda elde edilmiştir. Bu modele göre, birinci gizli katmanda nöron sayısı 13, ikinci gizli katmanda ise 2 olarak elde edilmiş olup öğrenme oranı ise 0.7 olarak belirlenmiştir. GDX modelleri için buharlaşma tahmininde en düşük başarı E<sub>Nash</sub> =0.544 (R<sup>2</sup>=0.750) değerleri ile P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, RH, VP parametrelerinin kullanıldığı M3 modelinde elde edilmiştir.

#### 4.2. ÇKA – SCG Uygulaması ve Sonuçları

ÇKA- SCG modelleri kurulurken, iki gizli katmandan oluşan dört tabakalı YSA yapısı kullanılmıştır. Gizli katmanlardaki nöron sayıları 1-20 arasında, iterasyon sayısı ise 100–1000 arasında deneme yanılma ile belirlenmiştir. Oluşturulan modellerde, gizli katmanlarda aktivasyon fonksiyonu olarak tanjant sigmoid, çıkış katmanında ise logaritmik sigmoid fonksiyonu dikkate alınmıştır. Bu kabuller doğrultusunda ÇKA-SCG öğrenme algoritmasına ait elde edilen en başarılı sonuçlar Tablo 5’de verilmiştir.

Elde edilen model yapılarında, ilk değer giriş sayısını, ikinci ve üçüncü değerler gizli katmandaki nöron sayısını, sonuncu değer ise çıkış sayısını göstermektedir. Test periyoduna ait en büyük E<sub>Nash</sub> değeri dikkate alındığında en başarılı SCG yapısını, E<sub>Nash</sub>=0.586 (R<sup>2</sup>=0.744) değeri ile T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, RH giriş parametrelerinin kullanıldığı M5 modeli göstermiştir. Bu modele göre; gizli katmanlardaki nöron sayısı sırası ile 6 ve 13, iterasyon sayısı ise 200 olarak belirlenmiştir. En düşük başarı ise E<sub>Nash</sub>=0.521 (R<sup>2</sup>=0.725) değerleri ile P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, WS, RH, VP, AP parametrelerinin kullanıldığı M1 modelinde bulunmuştur.

*AYLIK BUHARLAŞMA TAHMİNİNDE YAPAY ZEKA YÖNTEMLERİNİN KULLANILABİLİRLİĞİ*

**Tablo 5.** ÇKA-SCG modellerine ait sonuçlar

Model Adı	Model Yapısı	İterasyon Sayısı	Eğitime		Test	
			R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
<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

**4.3. RTYSA Uygulaması ve Sonuçları**

Tek gizli katmandan oluşan üç tabakalı YSA ağ yapısına sahip RTYSA modelleri oluşturulurken, dağılım parametresi 0.01’lik artışlarla 0.01–5 aralığında, gizli katmandaki nöron sayısı ise 1-20 aralığında incelenmiştir. Bu kabuller doğrultusunda, sekiz farklı giriş kombinasyonu için elde edilen en başarılı RTYSA modellerine ait sonuçlar Tablo 6’da verilmiştir. Model yapısındaki değerler ise sırası ile, giriş sayısını, dağılım parametresini, gizli katmandaki nöron sayısını ve çıkış sayısını belirtmektedir.

**Tablo 6.** RTYSA modellerine ait sonuçlar

Model Adı	Model Yapısı	Eğitime		Test	
		R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
<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

Karaman istasyonu için en başarılı RTYSA yapısı, dağılım parametresi 3.07 ve gizli katmandaki nöron sayısı 9 olan ve E<sub>Nash</sub>=0.588 (R<sup>2</sup>=0.748) değerine sahip T<sub>ort</sub>, T<sub>min</sub>T<sub>max</sub>, RH giriş parametrelerinin kullanıldığı M5 modelinde elde edilmiştir. RTYSA modellerinde en düşük başarıyı gösteren giriş kombinasyonu ise E<sub>Nash</sub>=0.542 (R<sup>2</sup>=0.760) değerine sahip ve P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, WS, RH, VP, AP parametrelerinin kullanıldığı M1 modeli olmuştur.

**4.4. GRYSA Uygulaması ve Sonuçları**

GRYSA metodu ile aylık buharlaşma miktarını tahmin etmek üzere dağılım parametresi [0.01 5] aralığında 0.01 artışla test edilmiştir. Sekiz farklı giriş kombinasyonu ile yapılan denemelere göre en başarılı GRYSA modellerine ait sonuçlar Tablo 7’de verilmiştir. Elde edilen model yapılarında değerler sırası ile; giriş sayısını, dağılım parametresini ve çıkış sayısını göstermektedir.

Tablo 7’ye göre en başarılı GRYSA yapısı, E<sub>Nash</sub>=0.519 (R<sup>2</sup>=0.732) değeri ile M4 giriş kombinasyonunda P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, RH giriş parametreleri ile elde edilmiştir. En düşük başarıyı ise; E<sub>Nash</sub>=0.463 (R<sup>2</sup>=0.722) değerleri ile P, T<sub>ort</sub>, T<sub>min</sub>, T<sub>max</sub>, WS, RH, VP, AP parametrelerinin kullanıldığı M1 modeli göstermektedir.

**Tablo 7.** GRYSA modellerine ait sonuçlar

Model Adı	Model Yapısı	Eğitme		Test	
		R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
<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	(8, 0.27, 1)	0.762	0.748	0.727	0.515
M3	(8, 0.18, 1)	0.762	0.758	0.730	0.509
<b>M4</b>	<b>(8, 0.19, 1)</b>	<b>0.741</b>	<b>0.736</b>	<b>0.732</b>	<b>0.519</b>
M5	(8, 0.16, 1)	0.739	0.736	0.725	0.512
M6	(8, 0.14, 1)	0.727	0.725	0.704	0.491
M7	(8, 0.11, 1)	0.726	0.724	0.727	0.517
M8	(8, 0.07, 1)	0.728	0.727	0.735	0.512

#### 4.5. ANFIS Uygulaması ve Sonuçları

Karaman istasyonunun aylık buharlaşma tahmininde ANFIS modelleri, hem geriye yayımlı (backpropagation-BP) hem de hibrit öğrenme algoritmaları, kuralların oluşturulmasında da eksiltici kümeleme (subtractive-clustering-SC) tekniği kullanılarak geliştirilmiştir. İterasyon sayısı ise 100 olarak alınmıştır. ANFIS-SC tekniğinde tüm giriş kombinasyonları için, accept ratio değeri 0.5, reject ratio değeri 0.15 alınmıştır. Squash factor (sf) değerleri 1, 1.25 ve 1.50 alınarak, bu değerlere karşılık range influence (ri) değerleri ise 0.1–1 aralığında 0.1’lik artışlar dikkate alınarak ANFIS modelleri oluşturulmuştur. Elde edilen ANFIS modellerinden, test periyoduna göre en yüksek E<sub>Nash</sub> değerini sahip model yapıları Tablo 8’de verilmiştir.

**Tablo 8.** ANFIS modellerine ait sonuçlar

Model adı	Öğrenme Algoritması	sf	ri	Eğitme		Test	
				R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
<b>M1</b>	<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>
	BP	1.25	0.9	0.827	0.823	0.719	0.446
<b>M2</b>	Hibrit	1.5	0.7	0.759	0.759	0.757	0.563
	<b>BP</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
	BP	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
	BP	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
	BP	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
	BP	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
	BP	1	0.6	0.727	0.727	0.741	0.536
M8	Hibrit	1	0.9	0.721	0.721	0.742	0.547
	BP	1.25	0.8	0.721	0.721	0.742	0.549

Tablo 8’e göre, hibrit ve BP öğrenme algoritmaları ayrı ayrı değerlendirildiğinde her ikisinin de M2 giriş kombinasyonunda daha yüksek başarıya ulaştığı görülmektedir. M2 giriş kombinasyonunda BP öğrenme algoritmasının başarısının sf=1.25, ri=1.0 değerlerine karşılık E<sub>Nash</sub>=0.675 (R<sup>2</sup>=0.679) değerleri ile hibrit öğrenme algoritmasından daha iyi olduğu tespit edilmiştir. Buharlaşma tahmininde en düşük tahmin başarısına sahip ANFIS modeli ise, M1 giriş kombinasyonunda olmak üzere hibrit öğrenme algoritmasında elde edilmiştir.

#### 4.6. ε-DVR Uygulaması ve Sonuçları

Aynı giriş kombinasyonları ile ε-DVR kullanılarak oluşturulan modellerde, Radyal Tabanlı çekirdek fonksiyonu kullanılmıştır. ε-DVR modelleri oluşturulurken, düzenleme faktörü (C) için [1 100] aralığında 1'er artış, hata terimi (ε) için [0.01 0.5] aralığında 0.01'lik artış, Radyal Tabanlı Çekirdek Fonksiyonuna ait γ parametresi için ise [0.1 8] aralığında 0.1'lik artışlarla denemeler yapılmıştır. Yapılan denemelerden elde edilen en başarılı ε-DVR modellerine ait sonuçlar Tablo 9'da verilmiştir. Model yapılarındaki değerler sırasıyla; giriş sayısı, C, ε, γ ve çıkış sayısını ifade etmektedir.

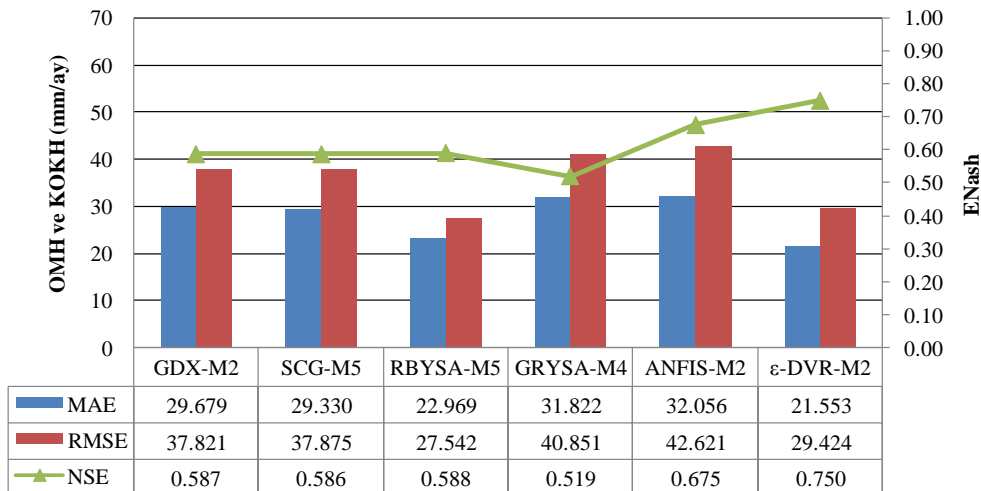
**Tablo 9.** ε-DVR modellerine ait sonuçlar

Model Adı	Model Yapısı	Eğitme		Test	
		R <sup>2</sup>	E <sub>Nash</sub>	R <sup>2</sup>	E <sub>Nash</sub>
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

Tablo 9'daki sonuçlara göre; test verilerine ait E<sub>Nash</sub> değerleri dikkate alındığında, M2(8, 1, 0.21, 0.3,1) ağ yapısı ile E<sub>Nash</sub>=0.750 (R<sup>2</sup>=0.750) değerlerine sahip ε-DVR modelinin daha yüksek başarıya ulaştığı görülmektedir. En düşük başarıyı gösteren ε-DVR modeli ise E<sub>Nash</sub>=0.716 (R<sup>2</sup>=0.732) değerine sahip M6 giriş kombinasyonunda elde edilmiştir.

#### 4.7. Yapay Zeka Metotlarının Karşılaştırılması

Kurulan modeller sonucunda, test periyodu için yapay zeka metotlarının her birinde elde edilen en başarılı ağ yapılarına ait OMH, KOKH ve E<sub>Nash</sub> değerleri Şekil 1'de verilmiştir. Şekil 1'e göre, yapay zekâ metotları kullanılan giriş kombinasyonları açısından değerlendirilirse; Karaman istasyonunda ÇKA-GDX, ε-DVR ve ANFIS metotlarında M2, ÇKA-SCG ve RTYSA metotlarında M5, GRYSA metodunda ise M4 giriş kombinasyonunda en yüksek tahmin başarısına ulaşıldığı görülmektedir.



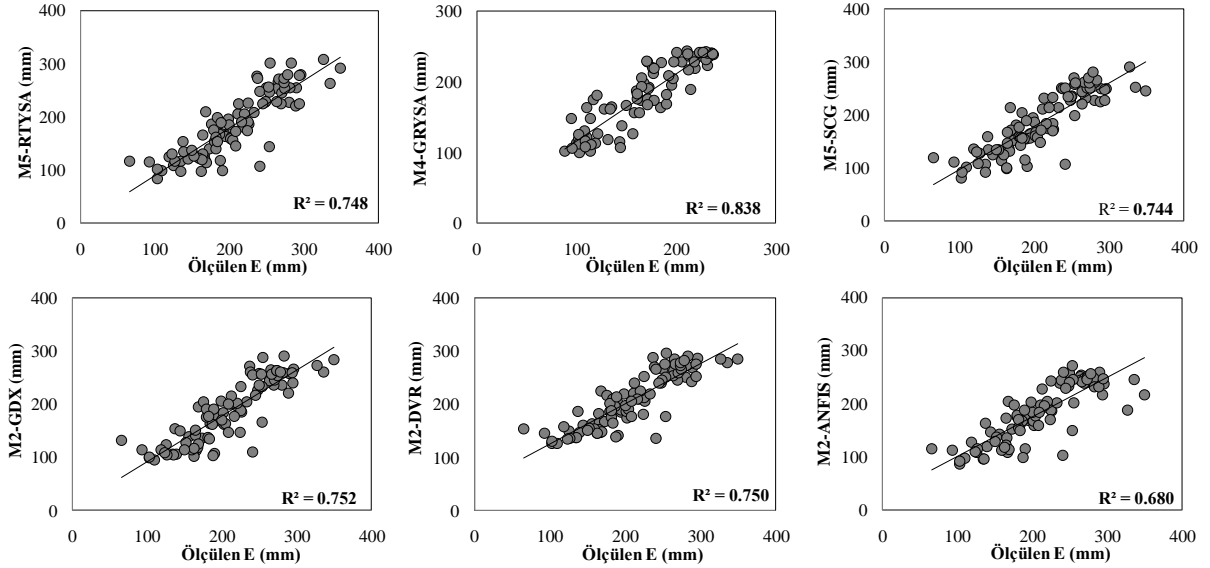
**Şekil 1.** En başarılı input kombinasyonları için test periyoduna ait performans kriterleri



A. ÖZEL, M. BÜYÜKYILDIZ

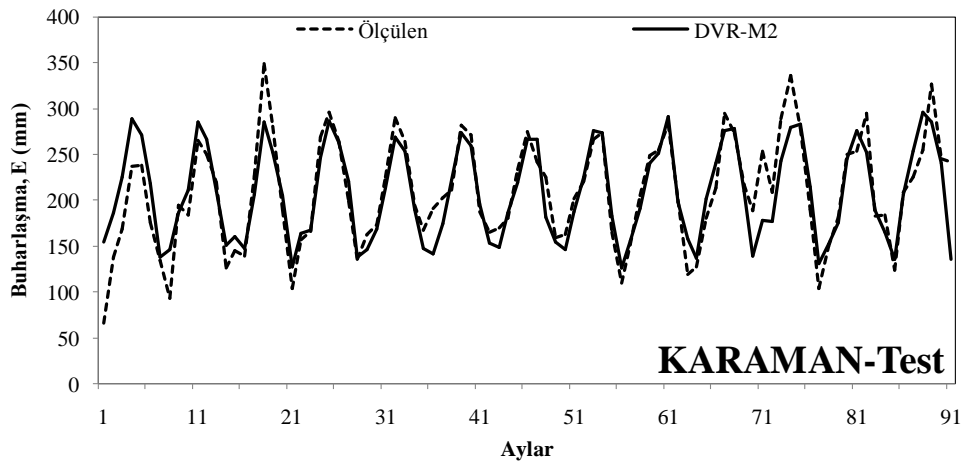
Aylık buharlaşma tahmini amacıyla kurulan her model, en yüksek  $E_{Nash}$  ve en düşük OMH ile KOKH'ya göre değerlendirildiğinde Şekil 1'de görüldüğü gibi  $C=1$ ,  $\epsilon=0.21$  ve  $\gamma=0.3$  ağ yapısına sahip  $\epsilon$ -DVR metodu;  $P, T_{ort}, T_{min}, T_{max}, RH, VP, AP$  parametrelerinin kullanıldığı M2 kombinasyonunda  $OMH=21.553$  mm/ay,  $KOKH=29.424$  mm/ay ve  $E_{Nash}=0.750$  performans değerleri ile en başarılı yapay zeka metodu olurken, en düşük başarıyı gösteren yapay zeka metodu ise  $OMH=31.822$  mm/ay,  $KOKH=40.851$  mm/ay ve  $E_{Nash}=0.519$ , değerleri ile GRYSA-M4 metodu olmuştur.

Kullanılan yapay zeka metotları için en başarılı ağ yapılarına ait test periyodu için çizilen saçılım diyagramları ise Şekil 2'de verilmiştir.



Şekil 2. Karaman istasyonu için en başarılı ağ yapısı ve input kombinasyonuna sahip yapay zeka metotlarına ait test periyodu saçılım diyagramları

Karaman istasyonu için, aylık buharlaşma tahmininde, kullanılan yapay zeka metotları arasında en başarılı model olan DVR-M2 metodundan elde edilen buharlaşma değerleri ile gerçek buharlaşma değerlerine ait zaman serisi, test periyodu için Şekil 3'de görülmektedir.



Şekil 3. Karaman istasyonu için DVR-M2 modeli için test periyoduna ait zaman serisi

## 5. SONUÇLAR ve ÖNERİLER

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

Bu amaçla, aylık  $P$ ,  $T_{ort}$ ,  $T_{min}$ ,  $T_{mak}$ ,  $WS$ ,  $RH$ ,  $VP$  ve  $AP$  verileri kullanılarak oluşturulan sekiz farklı giriş kombinasyonu ile  $\epsilon$ -DVR, YSA ve ANFIS modelleri kurulmuştur. Kurulan modellere ait en başarılı ağ yapılarına, en yüksek  $E_{Nash}$  ile en düşük  $OMH$  ve  $KOKH$  değerlerine göre karar verilmiştir.

Elde edilen sonuçlara göre; Karaman istasyonuna ait en başarılı giriş kombinasyonları, kullanılan yapay zekâ metotlarında farklılık göstermektedir. RTYSA metodunda M5, GRYSA metodunda M4, diğer yapay zekâ metotlarında ise M2 en başarılı giriş kombinasyonu olarak elde edilmiştir. Karaman istasyonu buharlaşma tahmininde, M2(8, 1, 0.21, 0.3, 1) ağ yapısı ile  $\epsilon$ -DVR en başarılı metot olurken, M4(8, 0.19, 1) ağ yapısı ile GRYSA en düşük tahmin başarısını gösteren metot olmuştur.

Sonuç olarak; 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. Su kaynaklarından önemli miktarda kayba neden olan buharlaşma miktarının belirlenmesi çalışmaları bu açıdan oldukça önemlidir.

## KAYNAKLAR

- [1] HUO, Z., FENG, S., KANG, S., DAI, X., "Artificial Neural Network Models for Reference Evapotranspiration in an Arid Area of Northwest China", *J. Arid Environ*, 82, 81–90, 2012.
- [2] SUDHEER, K.P., GOSAIN, A.K., RAMASASTRI, K.S., "Estimating Actual Evapotranspiration from Limited Climatic Data using Neural Computing Technique", *J. Irrig. Drain. Eng.* 129 (3), 214–218, 2003.
- [3] SHIRMOHAMMADI, B., VAFAKHAH, M., MOOSAVI, V., MOGHADDAMNIA, A., "Application of Several Data-Driven Techniques for Predicting Ground Water Level", *Water Resour Manag*, 27(2), 419–432, 2013.
- [4] KESKIN, M.E., TAYLAN, D., TERZI, O., "Adaptive Neural-Based Fuzzy Inference System (ANFIS) Approach for Modelling Hydrological Time Series", *Hydrol Sci. J.*, 51(4), 588–598, 2006.
- [5] SHIRI, J., MARTI, P., SINGH, V.P., "Evaluation of Gene Expression Programming Approaches for Estimating Daily Evaporation through Spatial and Temporal Data Scanning", *Hydrol. Process*, 28 (3), 1215–1225, 2014.
- [6] TERZI, O., KESKIN, M.E., "Modelling of Daily Pan Evaporation", *J Appl Sci*, 5(2), 368-372, 2005.
- [7] KIM, S., SHIRI, J., KISI, O., SINGH, V.P., "Estimating Daily Pan Evaporation using Different Data Driven Methods and Lag-Time Patterns", *Water Resour. Manage.*, 27 (7), 2267–2286, 2013.
- [8] BRUTON, J.M., MCCLENDON, R.W., HOOGENBOOM, G., "Estimating Daily Pan Evaporation with Artificial Neural Networks", *Transactions of the American Society of Agricultural Engineers*, 43(2), 491-496, 2000.
- [9] KUMAR, M., RAGHUWANSHI, N.S., SINGH, R., "Artificial Neural Networks Approach in Evapotranspiration Modeling: A Review", *Irrigation Science*, doi:10.1007/s00271-010-0230-8, 2010.
- [10] BEHMANESH, J., MEHDIZADEH, S., "Estimation of Soil Temperature using Gene Expression Programming and Artificial Neural Networks in a Semiarid Region", *Environ Earth Sci.*, 76 (2), 76, 2017.
- [11] MEHDIZADEH, S., BEHMANESH, J., KHALILI, K., "Comparison of Artificial Intelligence Methods and Empirical Equations to Estimate Daily Solar Radiation", *J. Atmos Sol Terr Phys*, 146, 215–227, 2016.
- [12] BUYUKYILDIZ, M., TEZEL, G., YILMAZ, V., "Estimation of the Change in Lake Water Level by Artificial Intelligence Methods", *Water Resour Manag*, 28, 4747–4763, 2014.
- [13] SUDHEER, C., MAHESWARAN, R., PANIGRAHI, B.K., MATHUR S., "A Hybrid SVM-PSO Model for Forecasting Monthly Streamflow", *Neural. Comput. and Applic*, 24, 1381–1389, 2014.
- [14] MOHANDÉS, M.A., "Modeling Global Solar Radiation using Particle Swarm Optimization (PSO)", *Sol Energy*, 86, 3137–3145, 2012.
- [15] GOCIC, M., MOTAMEDİ, S., SHAMSHIRBAND, S., PETKOVIC, D., CH, S., HASHİM, R., ARİF, M., "Soft Computing Approaches for Forecasting Reference Evapotranspiration", *Comput Electron Agric*, 113, 164–173, 2015.
- [16] TEZEL, G., BUYUKYILDIZ, M., "Monthly Evaporation Forecasting using Artificial Neural Networks and Support Vector Machines", *Theor Appl Climatol*, 124,69–80, 2016.

A. ÖZEL, M. BÜYÜKYILDIZ

- [17] DESWAL, S., PAL, M., “Modeling of Pan Evaporation Using Support Vector Machines Algorithm”, *Journal of Hydrologic Engineering*, 14(1), 104-116, 2008.
- [18] GOYAL, M.K., BHARTI, B., QUILTY, J., ADAMOWSKI, J., PANDEY, A., “Modeling of Daily Pan Evaporation in Sub-Tropical Climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS”, *Expert Syst. Appl.*, 41 (11), 5267–5276, 2014.
- [19] MEHDIZADEH, S., BEHMANESH, J., KHALILI, K., “Using MARS, SVM, GEP and Empirical Equations for Estimation of Monthly Mean Reference Evapotranspiration”, *Computers and Electronics in Agriculture*, 139, 103–114, 2017.
- [20] ÖZEL, A., *Meteorolojik Verileri Kullanarak Aylık Tava Buharlaşmasını Tahmin Etmek için Yapay Zeka Metotlarının Uygulanması, Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Konya, 2018.*
- [21] SPECHT, D. F., “A General Regression Neural Network”, *IEEE Transactions on Neural Networks*, 2, 568-576, 1991.
- [22] ALP, M., CİĞİZOĞLU, H.K., “Farklı Yapay Sinir Ağı Metodları ile Yağış Akış İlişkisinin Modellenmesi”, *ITU Dergisi*, 3(1), 80–88, 2004.
- [23] BROOMHEAD, D., LOWE D., “Multivariable Functional Interpolation and Adaptive Networks”, *Complex Systems*, 2(6), 568–576, 1988.
- [24] OKKAN, U., DALLKILIÇ, H.Y., “Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi”, *İMO Teknik Dergi*, 5957-5966, 2012
- [25] PRINCIPE, J.C., EULIANO, N.R., LEFEBVRE, W.C., *Neural and Adaptive Systems: Fundamentals through Simulations*, John Wiley & Sons Inc., New York, 2000.
- [26] HAYKIN, S., *Neural Networks: A Comprehensive Foundation*, 2nd edn. Prentice Hall, Upper Saddle River, 1999.
- [27] JANG, J.S.R., “ANFIS: Adaptive-Network-Based Fuzzy Inference System, *Systems, Man and Cybernetics*, IEEE Transactions on, 23(3), 665-685, 1993.
- [28] VAPNIK, V. N., *The Nature of Statistical Learning Theory*, Springer and Verlag, New York, 1995.
- [29] VAPNIK, V.N., *Statistical Learning Theory*, John Wiley and Sons, New York, 1998.
- [30] EKİCİ, S., *Elektrik Güç Sistemlerinde Akıllı Sistemler Yardımıyla Arıza Tipi ve Yerinin Belirlenmesi*, Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Şanlı Urfa, 2007.
- [31] ANONİM, *Konya Kapalı Havzası Sektörel Su Tahsis Planının Hazırlanmasına Yönelik Teknik Destek Hizmet Alımı İşİ, Taslak Su Talepleri Analizi Raporu, T.C. Orman ve Su İşleri Bakanlığı, Su Yönetimi Genel Müdürlüğü, 2017.*