

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI
ANADOLU ÜNİVERSİTESİ ORTAK PROGRAMI

**YAPAY SİNİR AĞLARI (YSA) MODELİ İLE SU YÜZEYİNDEN
BUHARLAŞMANIN TAHMİNİ: ATATÜRK BARAJI ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

ÖZGE TÜTÜNCÜ

TEZ DANIŞMANI
PROF. DR. MUSTAFA TOMBUL

İKİNCİ TEZ DANIŞMANI
DR. ÖĞRETİM ÜYESİ ASLI ÜLKE KESKİN

BİLECİK, 2022

10451026

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI
ANADOLU ÜNİVERSİTESİ ORTAK PROGRAMI

**YAPAY SİNİR AĞLARI (YSA) MODELİ İLE SU YÜZEYİNDEN
BUHARLAŞMANIN TAHMİNİ: ATATÜRK BARAJI ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

ÖZGE TÜTÜNCÜ

TEZ DANIŞMANI
PROF. DR. MUSTAFA TOMBUL

İKİNCİ TEZ DANIŞMANI
DR. ÖĞRETİM ÜYESİ ASLI ÜLKE KESKİN

BİLECİK, 2022

10451026

BEYAN

‘Yapay Sinir Ağları (YSA) Modeli İle Su Yüzeyinde Buharlaşmanın Tahmini: Atatürk Barajı Örneği’ adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.	
DESTEK ALINMIŞTIR	DESTEK ALINMAMIŞTIR
Destek alındı ise;	
Destekleyen kurum;	
Desteğin Türü	Proje Numarası
1- BAP (Bilimsel Araştırma Projesi)	
2- TÜBİTAK	
Diğer;.....	
ETİK KURUL onayı var ise;	
ETİK KURUL karar tarih/sayı:	/.....

Özge TÜTÜNCÜ

01.02.2022

ÖN SÖZ

Bu çalışma ile açık su yüzeyi buharlaşmasının yapay sinir ağları metodu ile tahmin edebilmesi ve bu tahminin doğruluğu araştırılmak istenmiştir. Amaç, çeşitli nedenlerle su kaynaklarının giderek azalmasına bağlı olarak buharlaşma kayıplarının hesaplanması ile mevcut su kaynakları yönetimine ve planlanmasına katkı sağlamak olmakla birlikte yapay sinir ağlarının bu alandaki başarısını da gözlemlemektir.

Bu tez çalışmasının yazılmasında, çalışmamı sahiplenerek takip eden danışmanım Sayın Prof. Dr. Mustafa Tombul'a ve Dr. Öğretim Üyesi Aslı Ülke Keskin'e değerli katkı ve emekleri için teşekkürlerimi ve saygılarımı sunarım.

Ayrıca bu günlere ulaşmamdaki emeklerinden ve çalışmalarım esnasında bana verdikleri sonsuz destekten dolayı değerli aileme teşekkür ederim.

ÖZGE TÜTÜNCÜ

01.02.2022

ÖZET

YAPAY SİNİR AĞLARI (YSA) MODELİ İLE SU YÜZEYİNDEN BUHARLAŞMANIN TAHMİNİ: ATATÜRK BARAJI ÖRNEĞİ

Başta küresel ısınma etkili olmak üzere artan nüfus da göz önüne alındığında su kaynaklarımızın ileriki yıllarda yetersiz kalması, yaşanması muhtemel başlıca büyük problemler arasındadır.

Günümüzde ele alınan mühim konulardan biri de mevcut su potansiyelinin her geçen gün daralması ve ileride yaşanabilecek su kıtlığına karşı önlem alınmasıdır. Buna dayanarak mevcut suyun ne kadarını kullanabildiğimizin yanında, gelecekte su potansiyelinin ne derece daralacağını önceden tahmin etmek planlama açısından şarttır.

Bu çalışmada Atatürk Barajı'ndaki bir istasyona ait 2016-2018 yılları arası günlük minimum sıcaklık, maksimum sıcaklık, ortalama sıcaklık, güneş radyasyonu, bağıl nem, rüzgar hızı ve buharlaşma verileri kullanılmıştır. Buharlaşmayı etkileyen parametreler girdi olarak ağı verilmiş ve ağı çıktığı olarak gösterilen gerçek buharlaşma değerlerine ne derece yakın sonuçlar ürettiği gözlemlenmiştir. Bunun için farklı modeller denemiş ve bulgular analiz edilmiştir. Sonuç olarak %90 doğruluk oranıyla YSA ile buharlaşma tahmininde başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Modelleme, Tahmin, Günlük Buharlaşma, Atatürk Barajı

ABSTRACT

FORECASTING WATER SURFACE EVAPORATION WITH ARTIFICIAL NEURAL NETWORKS (ANN) MODEL: EXAMPLE OF ATATURK DAM

Considering the increasing population, especially with the effect of global warming, the insufficiency of our water resources in the coming years is among the major problems that are likely to be experienced.

One of the important issues discussed today is the shrinking of the existing water potential day by day and taking precautions against water scarcity that may occur in the future. In this context, besides how much of the existing water we can use, it is essential for planning to predict how much the water potential will shrink in the future.

In this study, daily minimum temperature, maximum temperature, average temperature, solar radiation, relative humidity, wind speed and evaporation data of a station in Atatürk Dam between 2016-2018 were used. The parameters affecting the evaporation are given to the network as input and it is observed how close the network produces results to the actual evaporation values shown as output. For this, different models were tried and the findings were analyzed. As a result, successful results were obtained in evaporation estimation with ANN with 90% accuracy.

Keywords: Artificial Neural Networks, Modelling, Prediction, Daily Evaporation, Ataturk Dam

İÇİNDEKİLER

	Sayfa No
ÖN SÖZ	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR LİSTESİ.....	viii
1. GİRİŞ	1
2. LİTERATÜRDEKİ BENZER ÇALIŞMALAR	2
3. BUHARLAŞMA	7
3.1. Buharlaşmayı Etkileyen Faktörler	7
3.1.1. Meteorolojik Faktörler.....	7
3.1.2. Buharlaşma Yüzeyi Özellikleri	8
3.2. Buharlaşma Ölçümü	9
3.3. Buharlaşma Tayin Metotları	11
4. YAPAY SİNİR AĞLARI.....	15
4.1. Yapay Sinir Ağlarına Genel Bakış	15
4.2. Yapay Sinir Ağlarının Çeşitli Tanımları ve Genel Özellikleri	17
4.3. Yapay Sinir Ağı Hücresinin Yapısı	20
4.3.1. Biyolojik Sinir Sistemi.....	20
4.3.2. Yapay Sinir Ağı Hücresi	21
4.4. Yapay Sinir Ağlarının Sınıflandırılması	24
4.4.1. Mimari Yapılarına Göre Sınıflandırılması.....	24
4.4.1.1. İleri Beslemeli Yapay Sinir Ağları (FeedForward)	24
4.4.1.2. Geri Beslemeli Yapay Sinir Ağları (FeedBack)	24

4.4.2. Öğrenme Algoritmalarına Göre Sınıflandırılması.....	24
4.4.2.1. Danışmanlı Öğrenme.....	25
4.4.2.2. Danışmansız Öğrenme.....	25
4.4.2.3. Takviyeli (Destekli) Öğrenme	26
4.5. Yapay Sinir Ağlarında Öğrenme Kuralları	26
4.5.1. Çevrim İçi (On-Line) Öğrenme	26
4.5.2. Çevrim Dışı (Off-Line) Öğrenme.....	26
4.5.3. Temel Öğrenme Kuralları	26
5. MATERYAL VE METOT	28
6. BULGULAR	30
7. SONUÇ VE ÖNERİLER.....	35
KAYNAKÇA	36

TABLÖLAR LİSTESİ

Sayfa No

Tablo 6.1. Farklı eğitim modeli ve ara katman sayılarının performans değerlendirilmesi	30
Tablo 6.2. Buharlaşımaya etki eden parametrelerin bireysel olarak değerlendirilmesi.....	31
Tablo 6.3. Maksimum minimum sıcaklık ve ortalama sıcaklık verilerinin model üzerindeki başarısının kıyaslanması	31
Tablo 6.4. Çeşitli giriş modellerinin ağ üzerindeki performansının incelenmesi	32



ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 3.1. Buharlaşıma tavaşı	9
Şekil 3.2. Türkiye’de 2020 buharlaşma rasatı yapan istasyonlar	10
Şekil 4.1. Biyolojik sinir sistemi blok gösterimi.....	20
Şekil 4.2. Biyolojik sinir hücresi şekli	21
Şekil 4.3. Çok katmanlı bir yapay sinir ağı örnek modeli	22
Şekil 4.4. Yapay sinir ağı hücresi matematiksel modeli işleyişi.....	22
Şekil 6.1. YSA-I ağ modeli performansı	32
Şekil 6.2. YSA-II ağ modeli performansı.....	32
Şekil 6.3. YSA-III ağ modeli performansı	33
Şekil 6.4. YSA-VI ağ modeli performansı	33
Şekil 6.5. YSA-V ağ modeli performansı.....	33
Şekil 6.6. YSA-II ağıının test performansı	34

KISALTMALAR LİSTESİ

YSA : Yapar sinir ağları

ANFIS : Adaptive-Network Based Fuzzy Inference Systems

GEP : Gen ekspresyon programlama

ÇDR : Çoklu doğrusal regresyon

NASA : National Aeronautics and Space Administration

MGM : Meteoroloji Genel Müdürlüğü

DSİ : Devlet Su İşleri

WMO : World Meteorological Organization

FAO : Food and Agriculture Organization

MLP : Multi Layer Perceptron

LVQ : Learning Vector Quantization

RBF : Radial Basis Function

SOM : Self Organization Map

ART : Adaptive Resonance Theory

MSE : Mean Square Error

GDX : Gradient Descent with Momentum& Adaptive LR

LM : Levenberg-Marquardt

LOGSİG : Logaritmik Sigmoid Transfer Fonksiyonu

TANSİG : Hiperbolik Tanjant Sigmoid Transfer Fonksiyonu

PURELİN : Lineer Transfer Fonksiyonu

1. GİRİŞ

Hidrolojik çevrimin bir parçası olan buharlaşma ile mevcut suyun bir kısmı doğrudan atmosfere karışmakta ve haliyle kullanılamamaktadır. Her geçen gün azalan su kaynakları düşünüldüğünde buharlaşma ile oluşan kayıplar da ciddiye kazanmaktadır.

Buharlaşma, küresel ısınmaya bağlı olarak mevsim normallerinin dışındaki hava şartları ile günden güne artmaktadır. Buna karşılık bu alanda yapılan çalışmalar özellikle disiplinler arası olmak üzere son zamanlarda bir hayli ilgilenilen araştırma konuları arasındadır. Günümüzde artık hemen hemen her alanda karşımıza çıkan yapay zeka yöntemlerinin kullanılması ile de buharlaşma tahminleri ve gelecek için öngörüler başarılı bir şekilde sergilenmektedir.

Gelecek nesillerin ve tüm canlıların susuz kalma ihtimali gibi vahim bir senaryoyla karşı karşıya kalmaması için alınacak önlemlerden önce kullanılabilecek net su potansiyelinin hesabı ve bunun için de potansiyel sudaki net kayıpların tahmin edilmesi gerekir. Bu anlamda yapacağımız çalışma su yüzeyinden buharlaşma ile olan kaybı belirleme açısından önem arz etmektedir.

Hayatımızı gelişen teknolojiyi kullandığımız ölçüde kolaylaştırabilmemiz mümkündür. Bu anlamda hayatımıza giren yapay zeka yöntemlerini göz ardı etmek büyük kayıp olur. Her alanda bize yardımcı olan yapay zeka yöntemleri ile tahmin yapmak formüllere dayalı klasik yöntemlere oranla daha kolay olup, daha güvenilir ve başarılı sonuçlar vermektedir.

2. LİTERATÜRDEKİ BENZER ÇALIŞMALAR

Keskin ve ark. (2004), Eğirdir Gölü'nün 2001 yılına ait 245 adet verisi ile bulanık mantık model yaklaşımı kullanılarak buharlaşma tahmini yapmışlardır. Hydrological Sciences Journal dergisinde yayımladıkları bildirilerine göre buharlaşma tahmini için günlük hava sıcaklığı, su sıcaklığı, güneş radyasyonu ve hava basıncı parametreleri kullanılmıştır. Elde edilen sonuçlar ölçülen günlük tava buharlaşma değerleri ve Penman metoduyla karşılaştırılmıştır. Karşılaştırmadan sonuçla oluşturulan bulanık modelin ölçülen tava buharlaşma değerleriyle daha fazla uyum içerisinde olduğu görülmüştür.

Terzi ve Keskin (2005), yapay sinir ağları yöntemin kullanarak tava buharlaşması tahmini yapmışlardır. Çalışmada tava buharlaşmasında etkili parametreleri etkinlik derecesine göre sıralayıp en etkin olan ilk dört parametreyi yani 2001 ve 2002 yıllarına ait hava sıcaklığı, su sıcaklığı, güneş radyasyonu ve hava basıncı verilerini kullanmışlardır. 2, 3 ve 4 girdili kombinasyonlar ile modeller oluşturulmuş ve en iyi modelin giriş parametreleri ortalama hava sıcaklığı, su sıcaklığı ve güneş radyasyonu olan 3 girişli model olduğu, bunun yanında bu modelin gerçek buharlaşma değerleri ile oldukça yakın olduğu görülmüştür. Bu çalışma bizlere kullanılan klasik yöntemlere ek olarak yapay sinir ağlarının buharlaşma tahmini için etkin olarak kullanılabileceğini ve gerekli verilerin azaltılması konusunda da yardımcı olduğunu göstermiştir.

Keskin ve Terzi (2006), bir başka çalışmasında hava ve su sıcaklığı, güneş radyasyonu, hava basıncı, güneşlenme süresi, bağıl nem ve rüzgar hızı parametrelerini kullanarak 6 farklı kombinasyon ile yapay sinir ağları yöntemini kullanarak buharlaşma tahmini yapmışlardır. Çalışmada test verileri ile elde edilen sonuçların performansına bakıldığında en iyi sonuçları sırasıyla 7, 6 ve 3 girişli modellerin verdiği gözlenmiştir. 6 ve 7 girişli modeller en iyi sonucu vermiş olsa da 3 girişli model de bunlara benzer sonuçlar elde etmiştir. Buradan da anlaşıyor ki YSA metodu kullanılarak az veri ile gerçeğe en yakın ve gerçek değerlerle uyum içinde olan sonuçlar elde edilebilmektedir.

Kişi (2007), ABD'nin Los Angeles eyaletinde bulunan 3 istasyondan alınan hava sıcaklığı, rüzgar hızı, güneş radyasyonu, bağıl nem gibi mevsimsel verileri kombinasyonlayarak yapay sinir ağları ile evapotranspirasyon tahmini yapmıştır. Bu modelleme için Levenberg-Marquardt eğitim algoritmasını ve ileri beslemeli yapay sinir ağları yöntemini kullanmıştır. İklimsel değişkenlerin her biri yapay sinir ağı modeline girdi olarak verilerek her değişkenin evapotranspirasyon üzerindeki etkisi gözlenmiştir. Elde edilen bulgular ampirik yöntemlerden

Penman, Hargreaves ve Turc denklemleri ile karşılaştırılmıştır. Karşılaştırmalara göre mevsimsel değişkenlik gösteren verilerle evapotranspirasyon tahmininde yapay sinir ağı modelinin başarılı bir şekilde kullanılabileceği ve diğer ampirik metotlara göre daha iyi performans sergilediği kanıtlanmıştır.

Doğan ve ark. (2007), Sapanca gölüne ait 1990-2004 yılları arasındaki minimum ve maksimum sıcaklık, rüzgar hızı, göreceli nem, gerçek güneşlenme süresi ve maksimum güneşlenme süresi verileri ile buharlaşma tahmini üzerine çalışmışlardır. Çalışmada ileri beslemeli geri yayımlı yapay sinir ağı ve radyal tabanlı yapay sinir ağları kullanılarak günlük buharlaşma tahmini yapılmış ve elde edilen sonuçlar ampirik metotlardan Penman-Monteith yöntemi ile karşılaştırılmıştır. Sonuç olarak ileri beslemeli geri yayımlı yapay sinir ağı yönteminin ölçülen gerçek günlük buharlaşma değerlerine en yakın sonucu verdiği görülmüştür.

Afşar (2008), yaptığı çalışmada Kayseri, Kırşehir, Nevşehir ve Yozgat illerine ait 4 istasyondan alınan verileri kullanarak buharlaşma tahmini için YSA ve bulanık mantık modelleri geliştirmiştir. Ortalama sıcaklık, minimum ve maksimum sıcaklık ve ortalama nem verilerini kombinasyonlayarak her bir girdi parametresinin buharlaşmaya olan etkisini incelemiştir. Bunu yaparken çok katmanlı YSA, radyal tabanlı YSA, Genelleştirilmiş Regresyon YSA, Adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve çoklu doğrusal regresyon yöntemlerini kullanmıştır. Sonuç olarak kombinasyonlardan en iyi sonucu ağırlıklı olarak 4 parametrenin de giriş değeri olarak verildiği model göstermiş olup, kullanılan yöntemlerden de radyal tabanlı yapay sinir ağlarının (Nevşehir hariç diğer 3 istasyonda) en iyi sonuçlar verdiği gözlenmiştir.

Dindar (2010), yapay sinir ağları yöntemi ile Tahtaköprü Barajı'ndaki aylık buharlaşma miktarının tahminini yapmıştır. Bu çalışmanın diğer çalışmalardan farkı, giriş verileri olarak geçmiş yıllardaki buharlaşma miktarlarının ağa verilmesidir. Ağ yapısı çok katmanlı algılayıcı olarak seçilmiş ve geriye yayılım algoritmali ileri beslemeli ağ modeli tercih edilerek ağ üzerinde Bayesian düzenleme yöntemi kullanılmıştır. Baraj rezervuarındaki su seviyesindeki değişimler Multi Lineer Regresyon modeli, Otoregresif model ve Yapay Sinir Ağları modeli olmak üzere 3 farklı metotla belirlenmiştir. Çalışma sonuçları yapay sinir ağları yönteminin baraj haznesindeki aylık buharlaşma miktarı tespitinde daha başarılı olduğunu göstermiştir.

Shiri ve ark. (2011), ABD'nin Illinois eyaletine bağlı 3 hava istasyonunun verilerini kullanarak yapay sinir ağları (YSA) ve ANFIS modelleri ile buharlaşma üzerine çalışmışlardır.

Giriş verileri olarak 2005-2008 yılları arası hava sıcaklığı, güneş radyasyonu, rüzgar hızı, bağıl nem, yüzeyin toprak sıcaklığı ve toplam yağış parametrelerini kombinasyonlayarak kullanmışlardır. İncelenen 3 istasyonda da tüm parametrelerin giriş olarak verildiği model en iyi performansı sergilemiştir. Bunun yanında güneş radyasyonunun dahil edilmediği kombinasyon da ikinci en iyi sonuçları vermiştir. Çalışma neticesinde YSA modelleri kabul edilebilir bir doğrulukta tahmin yapsa da ANFIS modellerinin çok daha başarılı olduğu gözlenilmiştir.

Kumar ve Tiwari (2012), Hindistan'nın US Nagar bölgesindeki Pantnagar kasabasının aylık potansiyel buharlaşma tespitini iklim parametrelerini kullanarak yapay sinir ağı modelleri ile yapmıştır. Bunun için bölgenin yaklaşık son 20 yıllık (236 ay) bağıl nem, rüzgar hızı, güneş radyasyonu ve buharlaşma verilerini kullanmışlardır. Çalışmada öncelikle iklimsel veriler bireysel olarak denenmiş ve buharlaşmada en etkin parametreler sırasıyla hava sıcaklığı, rüzgar hızı, bağıl nem ve güneşlenme süresi olarak belirlenmiştir. Çeşitli kombinasyon denemeleri sonucu bu 4 iklimsel parametreye ait veriler ile en iyi uyumu gösteren yapay sinir ağı modeli olarak bir gizli katmana sahip çok katmanlı algılayıcı modeli kullanılmıştır. Çalışma sonucu yüksek korelasyon katsayısı ve minimum ortalama karekök hata ile YSA modelinin buharlaşma tahmini için uygulanabilir olduğu açıkça belirtilmiştir.

Gümüş ve ark. (2016), Adana istasyonunun 1986-2008 yıllarına ait ortalama sıcaklık, nem, rüzgar hızı, atmosfer basıncı, güneşlenme şiddeti ve güneşlenme süresi verilerini kullanarak üç farklı yapay zeka yöntemi ile aylık buharlaşma tahmini yapmıştır. Bu çalışmada ağ tabanlı bulanık yapay sinir ağı (ANFIS), yapay sinir ağı (YSA) ve gen ekspresyon programlama (GEP) modelleri kullanılmıştır. Çeşitli kombinasyonlar oluşturularak (2, 4 ve 6 girdili) yapılan tahminde metotların test sürecinden elde edilen performans kriterlerine bakıldığında 6 girdili ANFIS modelinin en başarılı sonucu verdiği gözlenmiştir.

Antonopoulos ve ark. (2016), Yunanistan'ın batısındaki Vegiritis Gölü için yapay sinir ağı ve klasik metotları kullanarak buharlaşma tahmini yapmıştır. Bunun için gölün 500 m. uzaklığındaki iki istasyondan elde ettikleri günlük hava sıcaklığı, bağıl nem, rüzgar hızı, güneşlenme süresi ve buharlaşma verilerini kullanmışlardır. Meteorolojik verileri kombinleyerek birçok farklı giriş ve farklı ağ mimarileri ile yapay sinir ağı eğitilerek test edilmiş ve en uygun model tespit edilmiştir. Bulunan sonuçlar ile klasik yöntemlerden Penman, Priestley-Taylor ve kütle transfer metodu kullanılarak yapılan buharlaşma tahminleri karşılaştırılmıştır.

Pallavi ve Rajeev (2016), çalışmasında iklimsel verileri kullanarak yapay sinir ağı yöntemi ile Hindistan'ın Maharashtra eyaletinde bulunan Nathsagar rezervuarı (Jayakwadi Dam) için buharlaşma tahmini yapmıştır. İlk olarak baraja ait 2000-2006 yılları arasındaki maksimum ve minimum sıcaklık, rüzgar hızı, güneşlenme süresi, bağıl nem verilerinden her bir değişkenin buharlaşmaya olan etkisinin analizini yapmıştır. Buna göre buharlaşmayı sırasıyla en çoktan en aza doğru etkileyen parametreler maksimum sıcaklık, bağıl nem, güneşlenme süresi, minimum hava sıcaklığı ve rüzgar hızıdır. Ardından 4 farklı kombinasyon (5, 4, 3 ve 2 girişli) ile ileri beslemeli geri yayımlı yapay sinir ağı yardımıyla buharlaşma tahminini yapmıştır. Tahmin sonucuna göre en iyi performansı rüzgar hızının dahil edilmediği 4 girişli kombinasyon vermiştir. Ancak sonuçlardan görülmektedir ki çok küçük bir farkla ikinci en iyi kombinasyon olan, buharlaşmada en çok etkili iki parametrenin yani yalnızca maksimum sıcaklık ve bağıl nemin giriş olarak verildiği kombinasyon da oldukça başarılı sonuç vermiştir. Bu da yine verilerin kısıtlı olması durumunda ya da araştırmacıların işini kolaylaştırmak açısından önem arz etmektedir.

Kaya (2016), çalışmasında kullandığı 2004-2010 yıllarına ait güneş radyasyonu, bağıl nem, rüzgar hızı, hava sıcaklığı ve buharlaşma verilerini Amerika'nın Florida eyaletinde bulunan bir gözlem istasyonundan almıştır. Bu verileri 2'li ve 3'lü kombinasyonlar yaparak adaptif sinirsel bulanık çıkarım metodu (ANFIS) ile çoklu lineer regresyon yöntemini kullanarak buharlaşma tahmini yapmıştır. Bunun yanında ampirik denklemlerden Hargreaves-Samani, Turc, Ritchie ve Penman-Monteith yöntemleri de kullanılmıştır. Tüm yöntemlerden elde edilen sonuçlar karşılaştırıldığında adaptif sinirsel bulanık çıkarım sistemi olan ANFIS metodunun en iyi sonuçları verdiği görülmüştür. Çoklu lineer regresyon yöntemi de yine ampirik denklemlere göre daha iyi bir performans göstermiştir. Klasik yöntemleri kendi aralarında kıyaslayacak olursak da Turc yönteminin daha iyi sonuçlar verdiği görülmektedir.

Gümüş ve ark. (2018), Şanlıurfa ve Diyarbakır istasyonlarından alınan yalnızca ortalama sıcaklık verilerini kullanarak YSA, ANFIS ve GEP yöntemleri ile buharlaşma tahmini yapmışlardır. Çalışma sonunda tüm yöntemlerin de başarılı olduğu gözlenmiş olup, iki istasyon için de çok az bir farkla GEP yönteminin daha iyi sonuç verdiği görülmüştür.

Taşar ve ark. (2018), buharlaşma tahmini için Amerika'nın Massachusett bölgesinden elde edilen 2014-2017 yıllarının ortalama günlük hava sıcaklığı, rüzgar hızı, güneşlenme miktarı ve bağıl nem verilerini kullanarak klasik denklemler ile YSA metodunu kullanmışlardır. YSA metodu ampirik denklemlere kıyasla en iyi sonuçları vermiştir.

Yeşiltaş (2018), GAP bölgesindeki 8 istasyona ait sıcaklık, rüzgar hızı, nisbi nem, basınç, güneşlenme şiddeti ve aylık güneşli gün sayısı verileri ile 3 farklı kombinasyon yaparak, yapay zeka metotlarından da YSA, ANFIS, GEP ve Çoklu Doğrusal Regresyon metotları yardımıyla buharlaşma tahmini yapmıştır. Çalışmada 8 istasyondan her biri için farklı yöntemler iyi sonuç verse de genel anlamda GEP ve ÇDR yöntemlerinin daha başarılı olduğu belirtilmiştir. Ayrıca sadece sıcaklık ve rüzgar hızı parametrelerinin ele alındığı iki girdili kombinasyonun da başarılı sonuç verdiği gözlenmiş ve az veri ile yapay zeka metotları kullanılarak yüksek doğruluk sağlanabileceği ispatlanmıştır.

Üneş ve ark. (2018), yine Amerika'nın South Carolina bölgesinden elde ettikleri 2013-2017 yıllarına ait 4 yıllık verilerle yapay sinir ağları ve ampirik denklem yöntemlerini kullanarak buharlaşma analizi yapmışlardır. Ortalama günlük hava sıcaklığı, maksimum ve minimum hava sıcaklığı, rüzgar hızı, güneş radyasyonu ve bağıl nem günlük ortalama buharlaşma tahmini için kullanılmıştır. Uygulanan yöntemlerin sonuçlarına bakarsak yapay sinir ağları yönteminin daha az hata ile ampirik denklemlerden daha iyi sonuçlara ulaştığı aşikardır.

Özel ve Büyükyıldız (2019), yayınladıkları bir makalede aylık buharlaşma tahmini için yapay zeka yöntemlerinin işlevselliği üzerinde durmuşlardır. Çalışmalarında Karaman istasyonuna ait iklimsel veriler ile 8 farklı kombinasyon oluşturarak yapay sinir ağları, adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve destek vektör regresyonu metotlarını buharlaşma tahmininde kullanmışlardır. Bulgulara göre en başarılı giriş kombinasyonu kullanılan yapay zeka yöntemine göre değişiklik göstermektedir.

Özdülkar ve ark. (2019), Amerika Birleşik Devletleri Jeolojik Araştırma Enstitüsü (USGS) 'den alınan Texas Lewisville Gölü'ne ait verilerle bulanık mantık yöntemlerini kullanarak günlük buharlaşma tahmini yapmışlardır. 2008 ve 2012 yılları arasındaki hava sıcaklığı, rüzgar hızı, bağıl nem, güneş ışıması verileri ile Mamdani ve Sugeno bulanık mantık yöntemleri kullanılmıştır. Çalışma neticesinde Sugeno bulanık modelinin daha iyi sonuç verdiği görülmüştür.

Yukarıda bahsi geçen çalışmalar yapay sinir ağları ve bulanık mantık yöntemleri ile günlük ve aylık buharlaşma miktarı tahmini üzerine yapılan çalışmaların yalnızca bir kısmıdır. Buharlaşma (evaporasyon) ve evapotranspirasyon tahmini için bu yöntemlerin dışında farklı birçok metotla daha tahmin yapılmakta ve bu metotlar kıyaslanarak en iyi ve en yakın olasılığı veren yöntem aranmaya devam etmektedir.

3. BUHARLAŞMA

Su doğada sürekli bir döngü içerisinde. Yer kürenin çeşitli yerlerinde ve çeşitli fazlarda bulunan suyun dönüp durduğu bu sistematik döngüye hidrolojik çevrim denir. Atmosferdeki buhar şeklindeki su yoğunlaşarak katı veya sıvı halde yağış olarak yeryüzüne düşer. Yeryüzüne düşen suyun bir kısmı yerçekimi ve yer şekillerinin etkisiyle yüzeysel akışa geçer, bir kısmı sızma ile yerin altına süzülerek yeraltındaki su akiferlerini besler ve yeraltı akışını oluşturur. Bir kısmı bitkiler tarafından tutulur ve bir kısmı da zeminden ve su yüzeylerinden buharlaşma (evaporasyon) ile bitkilerden de terleme (transpirasyon) yoluyla atmosfere geri döner.

Buharlaşma hidrolojik çevrimin temel unsurlarından biridir. Genel haliyle buharlaşma, suyun sıvı halden gaz (su buharı) haline geçmesi olayıdır. Su molekülleri hava ve su ortamları arasında sürekli bir gidiş geliş halindedir. Su ortamında çeşitli etkenlerle yeterli kinetik enerjiye ulaşmış olan su molekülleri kendilerini tutan diğer su moleküllerinin çekim etkisinden kurtulup hava ortamına karışırlar. Buharlaşmanın varlığından bahsedilebilmesi için de su ortamından havaya geçen moleküllerin daha fazla olması gereklidir.

3.1. Buharlaşmayı Etkileyen Faktörler

Buharlaşmada hem meteorolojik etkenler hem de buharlaşma yüzeyinin özellikleri rol oynamaktadır. Su ve hava sıcaklığı, nisbi nem, rüzgar hızı, buhar basıncı, güneş radyasyonu, güneşlenme süresi gibi iklimsel değişkenlik gösteren parametreler ve yüzeyin fiziksel ve coğrafi özellikleri buharlaşma hızını etkilemektedir.

3.1.1. Meteorolojik Faktörler

- **Sıcaklık:** Buharlaşmada etkili temel öge olan sıcaklık, buharlaşmaya iki şekilde etki eder. Hem doygun buhar basıncını artırarak havanın su buharı taşıma kapasitesini artırır, hem de buharlaşma için gerekli enerjiyi sağlar.
- **Güneş Radyasyonu:** Isının temel kaynağı güneşten gelen radyasyondur. Isıdaki artan ve azalan değişimler buharlaşmada önemli bir etkindir. Güneş ışınları aracılığıyla gelen enerji mevsime, günün saatine ve havanın açıklılık-bulutluluk durumuna göre değişir. Bunun yanında güneş radyasyonunun enerjisi enlem, yükseklik ve yöne göre de değişiklik göstermektedir. Yeryüzüne ulaşan güneş radyasyonunun yaklaşık %25'i yüzeyi buharlaşma yoluyla terk eder (NASA, 2010: MGM'den).

Su moleküllerinin buharlaşmasını sağlayan enerjide güneş radyasyonunun rolü büyüktür. Buharlaşma güneş radyasyonunun doğrudan gelmesiyle artar, aksi durumda buharlaşma hızı düşer.

- **Buhar Basıncı:** Dalton Yasası'na göre buharlaşma miktarı su yüzeyinin buhar basıncı ile suyun üstündeki havanın buhar basıncı arasındaki farkla ilişkilidir. Su sıcaklığının artması su moleküllerinin sahip olduğu kinetik enerjiyi ve dolayısıyla molekül hızlarını artırarak yüzeysel gerilimi azaltacak ve su yüzeyindeki buhar basıncı da artırarak buharlaşmanın daha kolay gerçekleşmesine neden olacaktır (Bayazıt, 2011: 36).

- **Nisbi Nem:** Havadaki nem miktarının artışıyla havanın su buharı taşıma kapasitesi düşer, hava daha fazla su buharı alamaz hale gelir. Dolayısıyla da buharlaşma hızı azalır.

- **Rüzgar Hızı:** Su yüzeyinden buharlaşan su hemen üzerindeki havayı doymun hale getirir ve buharlaşmanın azalmasına neden olur. Rüzgar su ortamı üzerindeki doymun hava kütlelerini oradan uzaklaştırarak doymun olmayan hava ile yer değişimini sağlar. Rüzgar hızı ile buharlaşma doğru orantılı olup rüzgar hızı arttıkça buharlaşma miktarı da artmaktadır.

- **Atmosfer Basıncı:** Atmosfer basıncında meydana gelen artış ile su moleküllerinin hareketleri kısıtlanacağı için sudan havaya su molekülü transferi zorlaşır ve buharlaşma azalır (Usul, 2008: 118).

3.1.2. Buharlaşma Yüzeyi Özellikleri

İklimsel etkenler dışında buharlaşmanın gerçekleştiği yüzeyin özellikleri de buharlaşma açısından önemlidir.

Buharlaşmanın meydana geldiği su yüzeylerinin **enleme** bağlı olarak farklı ölçüde güneş radyasyonlarına maruz kalması yüzeylerin buharlaşma oranının birbirinden farklı olmasına neden olacaktır (Özel, 2018: 12).

Su derinliği mevsimlik buharlaşma miktarı üzerinde etkilidir. Derin su kütleleri hava sıcaklığındaki değişimlere daha geç tepki verirler. Bu nedenle de derin sularda buharlaşma sığ sulardaki buharlaşmaya oranla yazın daha az kışın ise daha fazladır (Bayazıt, 2011: 37).

Bakıdan dolayı güneye ve batıya bakan yamaçlar daha fazla güneş ışınlarına maruz kalacağı için bu kısımlarda buharlaşma fazla olur.

Yükseklik arttıkça hava basıncı azalır ve buharlaşma artar. Bunun yanında yüksekliğin artmasıyla hava sıcaklığı da düşeceği için buharlaşma azalır. Ancak hava basıncı azalmasından ileri gelen buharlaşma artışı daha fazla olduğu kabul edildiğinden yükseklik arttıkça buharlaşmanın az miktarda da olsa arttığı düşünülür (Özel, 2018: 13).

Suda erimiş tuzlar, yani su kütlesinin tuzluluğu buharlaşmayı ters yönde etkilemektedir. Tuzluluk %1 oranında arttığında buharlaşma %1 oranında azalır (Harbeck, 1955: Usul'dan (2008): 119).

Ayrıca yüzeyin pürüzlülüğüne ince yada kalın taneli oluşuna ve yüzeyin güneş radyasyonunu yansıtma katsayısına (albedosuna) göre de buharlaşma miktarı değişmektedir (Usul, 2008: 119).

3.2. Buharlaşma Ölçümü

Buharlaşma denilince ilk olarak su yüzeyindeki buharlaşma akla gelmektedir. Ancak buharlaşma sadece su yüzeyinde olmaz. Zemin ve kar yüzeyinde de buharlaşma meydana gelmektedir. Bununla birlikte bitkilerin ihtiyaçları doğrultusunda topraktan alıp kullandıkları suyun fazlasını terleme yoluyla atmaları da havadaki su buharı miktarını artırmaktadır.

Su yüzeyinden buharlaşma miktarını hesaplanması işlemi buharlaşmayı etkileyen faktörlerin çokluğu nedeniyle zordur. Bu yüzden mümkün merteye doğrudan ölçüm yapılmalıdır. Bunun için yaygın olarak kullanılan buharlaşma tavaşı ile direkt olarak buharlaşma ölçümü yapılmaktadır. WMO (1966)' ya göre bu alanda en çok kullanılanı A.B.D. İklim Örgütü'nün A sınıfı buharlaşma kabı olarak nitelendirdiği kaptır. 122 cm. çapında ve 25.4 cm. derinlikte standart ölçülere sahip olan kap 20 cm. derinliğinde su ile doldurulur ve günlük seviye ölçümüyle buharlaşma miktarı hesaplanır. Buharlaşma miktarı ölçülen seviyeler arasındaki fark kadardır. İkinci olarak ölçülü bir kaptan belirli bir seviyeye kadar buharlaşma kabına su ilave edilmesi yöntemiyle de buharlaşma hesaplanır. Tavanın yanında rüzgar ölçümü için bir anemometre ve yağış ölçer bulunmalıdır (Usul, 2008: 119).




Şekil 3.1. Buharlaşma tavaşı

(Kaynak: MGM resmi web sayfası, 2021)

Buharlařma kabı ile yapılan ölçümlerde bir tava katsayısı kullanılmasına ihtiyaç vardır. Çünkü buharlařma tavařında meydana gelen buharlařma derin su kütlelerinde meydana gelen buharlařmadan daha fazladır. Bu sebeple kaptaki buharlařma değeri 1’den küçük bir düzeltme katsayısı ile çarpılır. Türkiye’de bu değeri genellikle 0.7 olarak alınır.

Açık su yüzeylerindeki buharlařmayı tespit için buharlařma kabı 3 farklı şekilde kullanılabilir. Buharlařma miktarı elde edilmek istenen gölün kenarında toprak üzerine konularak, su ile toprak yüzeyinin aynı seviyede olduđu noktada toprađa gömülerek ya da gölde yüzer şekilde duracak şekilde buharlařma kabı yerleřtirilir. Göldeki toplam buharlařma kaptan elde edilen buharlařma değeri ile su yüzey alanının çarpılması sonucu bulunur (Usul, 2008: 120).

Ülkemizdeki buharlařma rasatları açık su yüzeyinde yapılmaktadır. Seçilmiş otomatik gözlem istasyonlarında OMGİ hesaplama metodu ile evapotranspirasyon değeri de hesaplanmaktadır. Ülkemizde açık su yüzeyindeki buharlařma ölçümünü yapan istasyonların tümünde Şekil 3.1.’de gösterilen A sınıfı yuvarlak buharlařma tavařı (Class A Pan) kullanılmaktadır. Galvaniz sac ya da paslanmaz çelikten yapılan silindirik şeklindeki buharlařma havuzları rasat alanlarının yağış, rüzgar ve güneş alan uygun yerlere kurulmaktadır (MGM, 2021).



Şekil 3.2. Türkiye’de 2020 buharlařma rasatı yapan istasyonlar

(Kaynak: MGM resmi web sayfası, 2022)

Yukarıda Şekil 3.2.'deki açık yüzey buharlaşma rasatı için 100 istasyondan faydalanılmıştır.

3.3. Buharlaşma Tayin Metotları

Buharlaşma hesabı yapılmış yahut yapılacak olan rezervuarlar için önem taşımaktadır. Yapılmış kullanılmakta olan bir baraj haznesindeki buharlaşma tespiti en iyi işletme performansı açısından önemlidir. Bunun yanında haznenin tasarım aşamasındayken buharlaşmanın tayin edilmesi haznenin yapılacağı yerin yeniden gözden geçirilmesini hatta yerinin değiştirilmesini gerektirebilmektedir.

Buharlaşmanın tespitinde kullanılan yöntemler istenilen hassaslığa ve meteorolojik verilerin temini için elde bulunan aletlere göre değişkenlik gösterir. Bu yöntemlerden bazıları su bütçesi (su dengesi) metodu, enerji dengesi metodu, kütle transfer yöntemi, Penman metodu ve ampirik denklemlerdir. Su dengesi, enerji dengesi, kütle transfer metodu ve Penman yöntemi su yüzeyinden olan buharlaşma tespitinde kullanılırken ampirik denklemler evapotranspirasyon (buharlaşma+terleme) hesabı için kullanılmaktadır.

Su Bütçesi Metodu: Bir su kütesine süreklilik denkleminin uygulanması ile buharlaşma bulunur. Kullanılan terimler belirli bir Δt süresindeki toplam hacim ya da derinlik cinsinden ifade edilir.

$$E = P + Q_i + \Delta S - (Q_e + Q_{ii}) \quad (3.1)$$

E = Buharlaşma

P = Yağış

Q_i = Giren akım miktarı

ΔS = Sürenin başında ve sonundaki depolama miktarı farkı ($S_2 - S_1$)

Q_e = Çıkan akım miktarı

Q_{ii} = Sızma miktarı

Burada baz alınan süre en az bir haftadır. Genellikle haznelerdeki aylık ya da yıllık buharlaşmanın belirlenmesinde kullanılır.

Enerji Dengesi Metodu: Su kütesine enerjinin korunumu denklemini uygulanır.

$$Q_0 = Q_N + Q_v + Q_h + Q_e \quad (3.2)$$

Q_0 = Su kütlesi tarafından depolanan enerjideki artış

Q_N = Su kütlesinin absorbe ettiği net radyasyon

Q_v = Su kütlesindeki net enerji (ıslak çevrede giren ve çıkan akımın enerjisi)

Q_h = Hissedilen ısı transferi (ısı olarak su kütlesinden iletilen enerji)

Q_e = Buharlaşma için kullanılan enerji

Buradaki Q_N ' i açmak istersek aşağıdaki denklemi görürüz:

$$Q_N = Q_s - Q_r - Q_b \quad (3.3)$$

Q_s = Su yüzeyindeki solar radyasyon (Kısa dalga güneş radyasyonu)

Q_r = Yansıyan solar radyasyon

Q_b = Atmosfere giden uzun dalga radyasyon

Değişkenler Langley/gün birimindedir. 1 Langley ise birim alanda 1 Kalori/cm², ye eşit olan enerji birimidir (Usul, 2008; 122)

Buharlaşma miktarı 3.2 denkleminde elde edilen aşağıdaki şekilde bulunur.

$$E = \frac{Q_N + Q_v - Q_0}{\rho L_e (1 + R)} \quad (3.4)$$

E = Buharlaşma miktarı

ρ = Su yoğunluğu (gr/cm³)

L_e = Buharlaşma ısınma ısısı (kal/gr)

R = Kondüksiyonla kaybedilen ısının buharlaşmayla olan oranı

Burada;

$$R = \gamma \frac{T_s - T_a}{e_s - e_a} \quad (3.5)$$

γ = Psikrometre sabiti: 0.66 mb/°C

T_s = Su yüzeyi sıcaklığı (°C)

T_a = Hava sıcaklığı (°C)

e_s = Su yüzeyi sıcaklığında doymuş buhar basıncı (mb)

e_a = Havanın buhar basıncı (mb)

Enerji bütçesi metodu en doğru yöntem olarak kabul edilse de radyasyon, buhar basıncı, sıcaklık gibi her yerde ölçülmeyen atmosferik verilerin doğru şekilde toplanmasını gerektirir (Usul, 2008: 123).

Kütle Transfer Metodu: Buharlaşma miktarını su yüzeyinden iki farklı yükseklikte ölçülen sıcaklık, nem ve rüzgar hızı cinsinden veren formüller ileri sürülmüştür. Bunlardan biri de aşağıda gösterilen Thorntwaite-Holzman formülüdür.

$$E = \frac{K(e_1 - e_2) - (w_2 - w_1)}{T \ln(z_2/z_1)^2} \quad (3.6)$$

E = Saatlik buharlaşma miktarı

e_1 ve e_2 = Yerden z_1 ve z_2 yükseklikte havanın buhar basıncı

w_1 ve w_2 = Yerden z_1 ve z_2 yükseklikte rüzgar hızı

T = Havanın ortalama sıcaklığı

K = Sabit değer

Penman Metodu: 1948’de Penman enerji dengesi yöntemi ile kütle transfer metodunu harmanlayarak güneşlenme, sıcaklık, nem ve rüzgar hızı gibi iklimsel verilerle serbest su yüzeyinden buharlaşmayı hesaplamak için bir denklem ortaya sürmüştür.

Göl yüzeyinden buharlaşmayı tahmin etmede sıkça kullanılan Penman denklemi Monteith (1965) tarafından geliştirilince Penman-Monteith denklemi ortaya çıkmıştır. Monteith bitkilerin terlemesi üzerindeki biyolojik etkileri de dikkate almıştır.

Penman denklemi son halini ise Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) tarafından Penman-Monteaith denklemi üzerinde aerodinamik etkiler ve bitki yetişmesindeki yüzey mukavemetleri de göz önüne alınarak oluşturulan denklem ile almıştır. Bu denklem aşağıda verilen FAO-Penman Monteith denklemi olarak geçmektedir.

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (3.7)$$

ET_0 : Referans evapotranspirasyon (mm/gün)

R_n : Bitki yüzeyindeki net radyasyon (MJ/m² gün)

G: Toprağın ısı akısı yoğunluğu (MJ/m² gün)

T: Yerden 2 metre yükseklikteki hava sıcaklığı (°C)

u_2 : Yerden 2 metre yükseklikteki rüzgar hızı (m/s)

e_s : Doygun buhar basıncı (kPa)

e_a : Mevcut (gerçek) buhar basıncı (kPa)

Δ : Doymuş buhar basıncı-sıcaklık eğrisinin eğimi (kPa/°C)

γ : Psikrometrik sabit (kPa/°C)

Ampirik Formüller: Buharlaşıma tahmininde kullanılan birçok ampirik denklem bulunmaktadır. Penman denklemi dışında Blaney-Cridde, Thornthwaite, Turc, Priestley-Taylor, Hargreaves bunlardan bazılarıdır.



4. YAPAY SİNİR AĞLARI

İnsan beyninin karşılaşılan en karmaşık ve muazzam şekilde işleyen bir yapı olduğu süregelen bir gerçektir. Bu sebeptendir ki bilim adamları insan beynini, yapısını ve işleyişini uzun yıllarca incelemiş ve bunun üzerine çalışmalar yapmışlardır.

Bunun yanında teknolojinin gittikçe artmasıyla bu kusursuz yapıyı, yani insan beynini, modelleyerek makinelere aktarma isteği de bilim adamlarının konusu olmuş böylece yapay zekâ çalışmaları başlamıştır. Biyolojik sinir sisteminden yola çıkılarak insan beyninin genel özellikleri arasında olan algılama, çıkarım yapma, öğrenme, hatırlama gibi özellikler makinelere aktarılmaya çalışılmıştır. Beynin genel yapısı ve özellikleri rolmodel alınarak bilgisayarlar ve makinalar tasarlanmıştır.

Beyin her ne kadar hayranlık uyandırıcı bir sistematikte çalışsa da zaman zaman karmaşık problemleri çözmede zorlanır, hatta çözemez. Bir düşünün; kimi zaman hatırlamada, kimi zaman da karmaşık matematiksel işlemlerin hesabında zorluk çekmiyor muyuz? Ve şimdi tekrar düşünün; öyle bir zeka ki verilen her bilgiyi hafızada tutabilecek, yeri geldiğinde bu bilgileri hatırlayacak ve bunları kullanarak minimum hata ile en karmaşık problemleri bile mikrosaniyeler içinde çözebilecek, en önemlisi de öğrenecek ve bir sonraki benzer problemde yorum yapabilecek, doğruluğu yüksek olasılıklarla tahmin edebilecek bir sistem mekanizması mümkün... Bilim adamları işte tüm bunları ve fazlasını yaparak insan yaşamını kolaylaştıracak, bizlere zamandan tasarruf ettirecek bir bilgisayar yapısını modellemenin mümkün olabileceğine inanmıştır ve beynin öncelikle yapısı, ardından da özellikleri ve çalışma prensibi baz alınarak yapay sinir ağları çalışmaları başlamıştır.

4.1. Yapay Sinir Ağlarına Genel Bakış

Yapay sinir ağları çalışmalarının 1943'te Warren McCulloch ve Walter Pitts ile başladığı kabul edilir. Bir nörobiyolojist olan McCulloch ile bir istatistikçi olan Pitts 'A Logical Calculus Of The Ideas Immanent In Nervous Activity' isimli makalelerinde ilk yapay sinir hücresi modelini geliştirerek bilim adamlarına ışık tutmuş, yapay sinir ağları çalışmalarına öncü olmuştur.

Bu araştırmacılar elektrik devrelerini kullanarak insan beyninin hesaplama ve analiz yeteneğinden esinlenmiş ve geliştirdikleri yapay sinir hücreleri ile çeşitli mantıksal ifadeleri formüle etmenin mümkün olabileceğini göstermişlerdir (Keskenler ve Keskenler, 2017: 11).

Bilim dünyasında büyük yankı uyandıran bu gelişme ile bilim adamlarının adeta odak noktası haline gelerek hızla gelişme göstermiştir. Araştırmacılar algılayıcı ve ağ modelleri, öğrenme kuralları, algoritmalar üzerinde başarılı çalışmalar elde etmişlerdir.

1949 yılında Donald Hebb sonraki yıllarda kendi adı ile anılan bir öğrenme kuralı ortaya atmıştır. Yapay sinir ağlarında öğrenme için başlangıç sayılan ‘Hebbian Öğreme’ kuralı, bugün geçerli olan öğrenme kurallarının birçoğunun temelidir (Afşar, 2008: 8).

1958’de Frank Rosenblatt’ın keşfettiği ‘perceptron’ olarak adlandırılan tekli doğrusal algılayıcı modeli ve öğrenme kuralı ile çalışmalar hız kazanmıştır.

1960 yılı itibari ile Widrow ve Hoff, ADALINE (ADaptive LINEer NEuron) ve MADALINE olarak adlandırdıkları yapay sinir ağı modellerini geliştirmişlerdir. MADALINE, ADALINE’ların bazılarında elde edilen çıktıların diğer ADALINE’lar için girdi haline gelmesi ve bunların birleştirilmesiyle elde edilen ağ modelidir. Bu iki modelde de Widrow ve Hoff’un geliştirdiği ‘delta kuralı’ ya da LMS (Least Mean Square) algoritması olarak adlandırılan öğrenme kuralı uygulanmıştır.

1969 yılında Minsky ve Papert, algılayıcının analizini yaparak yapay sinir ağlarının karmaşık lojik fonksiyonlar üzerinde kullanılamayacağını, nonlinear işlemleri yapamayacağını ispatlamışlardır. Bunun üzerine yapay sinir ağı alanındaki çalışmalar durma noktasına gelmiştir.

1982’de Hopfield, optimizasyon gibi teknik problemleri çözmek için doğrusal olmayan Hopfield ağını geliştirmiştir. Eş zamanlı olarak Kohonen de öğreticisiz öğrenen ‘SOM’ (Self Organizing Map) olarak adlandırılan ‘Öz Düzenlemeli Haritalar’ ı tanımlamıştır.

1983 yılında Barto, Sutton ve Anderson yayımladıkları bir çalışmada ‘Reinforcement Learning’ den bahsetmişlerdir.

1986’da Rumelhart, Hinton ve Williams’ın çalışmaları ile yapay sinir ağlarının popülaritesi yükselmiştir. Rumelhart ve McClelland günümüzde de yaygın olarak kullanılan yapay sinir ağları için büyük önem taşıyan geriye yayılmalı öğrenme algoritmasını ortaya koymuşlardır (Keskenler ve Keskenler, 2017: 14-15).

1988 yılında Broomhead ve Lowe ‘Radyal Tabanlı Fonksiyonlu Ağlar’ (RBF) tanımlamıştır. Aynı yıl Chua ve Yang ‘Hücrel Sinir Ağları’ tanımını yapmıştır.

Özellikle 1990 yılı ve sonrasında ise yapay sinir ağlarına dair sayısız çalışma bulunmaktadır. Bilim adamları yapay sinir ağlarını hemen her alanda günlük yaşantımıza

uygulamayı başarmıştır. Biz fark etmesek de uygulamalarıyla hayatımızın içinde yer alan yapay sinir ağları halen üzerinde çalışılan ve geliştirilen, bunun yanında birçok sektörde uygulanan ve uygulanmaya da devam eden güncel bir konudur.

4.2. Yapay Sinir Ağlarının Çeşitli Tanımları ve Genel Özellikleri

Yapay sinir ağları insan beyinin çalışma prensibinden ve biyolojik sinir hücrelerinin yapısından esinlenerek oluşturulmuş bilgi işleme yapısıdır.

Yapay sinir ağları insan beyninin geleneksel bilgisayarlardan tamamıyla farklı çalıştığının ve hesap yaptığının düşünülmesi ile gelişmiştir. Beyin, oldukça karmaşık, doğrusal olmayan ve paralel çalışan bir bilgisayar gibidir. En genel şekli ile bir sinir ağı; beynin ilgilenilen belirli bir görevi ya da işlevi yerine getirme şeklini modellemek için tasarlanmış bir makine olarak düşünülebilir. Haykin, (1999) ağı genellikle elektronik bileşenler kullanılarak uygulandığını veya dijital bir bilgisayardaki yazılımla simüle edildiğini ifade etmektedir.

Haykin'e (1999) göre, bir sinir ağı basit işlem birimlerinden oluşan deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemci olduğu şeklinde tanımlanır.

İlk ticari yapay sinir ağını geliştiren Dr. Robert HECHT-NIELSEN ise şu tanımlı yapmıştır: "Yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemidir."

Bir başka tanım da yapay sinir ağları çalışmalarına oldukça katkısı olan Kohonen'e ait bir tanımdır: 'Yapay sinir ağları paralel olarak bağlantılı ve çok sayıdaki basit elemanın, gerçek dünyanın nesneleriyle biyolojik sinir sisteminin benzeri yolla etkileşim kuran olan, hiyerarşik bir organizasyonudur.'

Salchenberger, Çınar ve Lash, (1992), yapay sinir ağlarını, çok değişkenli ve değişkenler arasındaki karmaşık karşılıklı etkileşimin bulunduğu veya tek bir çözüm kümesinin bulunmadığı durumlarda başarılı sonuçlar üreten bir yapay zeka teknolojisi şeklinde tanımlamaktadır.

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem biriminden (nöronlar) oluşan matematiksel sistemlerdir. Bu işlem birimi, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genel olarak, işlem birimleri gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır (Çakır, Ertunç ve Ocak, 2009: 72).

Bilimsel çalışmaların bir anda yapay sinir ağları üzerinde yoğunlaşmasının sebebine bakıldığında klasik bilgisayarlardan farklı ve üstün birçok özellik görülebilmektedir. Bunun yanında sinir ağının ağ modellerine göre sahip olduğu karakteristik özellikler de değişmektedir.

Yapay sinir ağları aşağıdaki faydalı ortak özelliklere sahiptir:

- **Paralel Veri İşleme:** Klasik bilgisayarların çoğu seri çalışmaktadır. Bu da işlem hızını düşürmektedir. Bununla birlikte ara elemanda meydana gelecek herhangi bir sorunda sistem olumsuz etkilenecektir. Yapay sinir ağlarının paralel çalışma özelliği sayesinde nöronlardan birinde meydana gelecek olan sıkıntıdan ya da herhangi bir nöronun devre dışı kalmasından ağ yapısı büyük ölçüde etkilenmeyecek istenilen sonuca büyük oranda yaklaşma göstermeye devam edecektir.

- **Doğrusal Olmama:** Yapay sinir ağlarının yapısı doğrusal değildir. Bu sayede lineer yapıda olmayan eğrisel sistemlerin çözümünde de başarılı sonuç vermektedir.

- **Yerel Bilgi İşleme:** Herhangi bir problemin çözümünde sinir ağları problemin tümüyle ilgilenmek yerine gerekli birimler sadece ilgili olan kısım ile ilgilenir. Bu görev paylaşımı da kompleks problemlerin bile kolayca çözümüne olanak sağlamaktadır.

- **Genelleme Yeteneği:** Ağ öğrenme sürecinin ardından kendisine gösterilen problemler hakkında genelleme yapabilir. Eğitim esnasında kullanılan problemin analizini yaparak probleme dair kaba bilgileri hafızasında tutar ve test edildiğinde bu bilgileri kullanarak benzer problemlere dair doğru sonuçlar üretebilir.

- **Uyarlanabilir Olma:** Belirli bir ortamda çalışmak üzere eğitilmiş bir yapay sinir ağı ortam koşullarındaki küçük değişikliklerin ardından yeniden kolayca eğitilebilir.

Bu özelliği ile yapay sinir ağları, hedef ve örnek tanıma, otomatik kontrol, sistem kimliklendirme gibi alanlarda da kullanılabilir (Yaşar, 2004: 46)

- **Öğrenme:** Geleneksel veri işleme yöntemlerinde programlama yolu ile hesap yapılmaktadır. Ancak bu şekilde tam olarak tanımlanmamış problemlere dair bir çözüm elde edilemez ve problemin çözümü için o probleme ait bir algoritma oluşturulması gerekir. Bu ağları diğer yöntemlerden ayıran özelliği de budur. Yapay sinir ağları problemleri daha önceden gösterilen örnekler ile çözer. Ağı elde edilmek istenilen davranışı gösterebilmesi için amaca uygun şekilde düzenlenmesi gerekir. Yani, hücreler arası bağlantıların doğru bir şekilde yapılması ve bağlantı ağırlıklarının uygun seçilmelidir.

Öğrenme süreci, ağı gösterilen giriş ve çıkış değerlerinden yola çıkarak ağı bu veriler ile ağırlık değerlerini ilişkilendirmesi ve bundan sonraki ağı verilecek benzer örneklerde doğru çıkarımlarda bulunmaya hazır hale gelmesi olarak düşünülebilir.

○ **Hata Toleransı:** Yapay sinir ağlarında nöronlar problemlerin çözümünde eş zamanlı olarak çalışmaktadır. Bu esnada nöronlardan birinin işlevini yerine getirememesi durumunda dahi sistem bundan büyük ölçüde etkilenmeyip güvenilir şekilde çalışmasına devam etmektedir (Özel, 2018: 28).

YSA'nın hata toleransına sahip olması paralel çalışma özelliğinin bir sonucudur denilebilir.

Yapay sinir ağlarının tüm bu olumlu ortak özelliklerinin yanında;

○ YSA'ların yapısı gereği paralel veri işleme yetenekleri olduğundan sadece paralel çalışan donanım üzerine gerçekleştiğinde (paralel çalışan işlemciler ile) performans gösterebilmeleri,

○ Uygun ağ yapısının belirlenmesi için genel belirli bir kuralın olmayışı,

○ Ağın parametre değerlerinin belirlenmesinde kesin kuralların bulunmaması ve her problem için farklı bir yaklaşıma ihtiyaç duyulabileceği ihtimali,

○ YSA'nın kullanacağı problemlerin nümerik bilgilere (sayısal verilere) dönüştürülmesi gerekliliği,

○ Ağın eğitiminin ne zaman biteceğinin bilinmemesi ve buna dair geliştirilmiş etkin bir yöntemin olmayışı,

○ Probleme karşılık çözüm üreten ağın bunu nasıl ürettiğine dair bilgiye ulaşılamaması,

○ Ağın davranışının açıklanamaması

gibi olumsuz özellikleri de bulunmaktadır.

Ancak olumlu özellikleri ile fazlasıyla başarılı sonuçlar elde edildiği için bu olumsuz özellikleri geri planda kalmakta ve yapay sinir ağlarına olan ilgiyi azaltmamaktadır.

Yapay sinir ağları günümüzdeki en iyi örüntü tanıyıcı ve sınıflandırıcılardan biridir. Bu ağları bu kadar iyi yapan ise eksik bilgiler ile çalışabilmesi ve normal olmayan verileri işleyebilme kabiliyetidir. Bu özelliği ile çok sayıda veriyi işleme gerektiren durumlarda oldukça iyi sonuçlar elde edebilmektedir. Günümüzde endüstriyel ve sosyal alanda çokça görülen örnekleri ile başarılı oldukları tescillenmiştir (Öztemel, 2012: 33).

Yapay sinir ağları sahip olduğu özellikleri ile birçok fonksiyonu yerine getirmektedir. Bunlardan bazıları şu şekildedir:

- ✓ Sınıflandırma
- ✓ Örüntü Tanıma
- ✓ Doğrusal olmayan sistem modelleme

- ✓ Optimizasyon
- ✓ Zeki ve doğrusal olmayan kontrol
- ✓ Sinyal süzme
- ✓ Veri sıkıştırma
- ✓ Doğrusal olmayan sinyal işleme

Tüm bu yukarıda sayılan fonksiyonları yapabilmesinden ötürü birçok alanda yapay sinir ağları kullanılmaktadır. Tıp, mühendislik, havacılık, güvenlik sistemleri, pazarlama, robotik, otomotiv, savunma sıklıkla görülen uygulamaları alanlarındandır.

4.3. Yapay Sinir Ağı Hücresinin Yapısı


Yapay sinir ağları insan beyninin yapısından esinlenerek modellenmiş biyolojik ağların çok ilkel modelleri olarak tanımlanabilir. Doğal olarak bir yapay sinir hücresi de biyolojik sinir hücresi ile benzer bir yapıya sahiptir. Yapay sinir ağlarını anlamak için biyolojik sinir sisteminin yapısını ve çalışma prensibini bilmek gerekir.

4.3.1. Biyolojik Sinir Sistemi

Beyin çok sayıda sinir hücresinden oluşmakta olup bu hücrelerin birbiriyle bağlantılı çalışması ile insan vücudunu kontrol eder, karşılaşılan anlık durumlara karşı tepkiler üretir ve tüm bunları çok kısa bir süre içerisinde yapar.

Girdi sinyalleri nöronlar tarafından duyu organlarından alınır. Alıcı nöronlar bu sinyalleri işleyerek sonraki sinire aktarır ve sinyal merkezi sinir sistemine kadar ulaşır. Bu sinyaller merkezi sinir sisteminde yorumlanarak tepki sinyalleri üretilir. Ardından nöronlar aracılığı ile tepkilerin oluşacağı organlara iletilir. Böylece duyu organlarından gelen sinyallere karşı uygun tepkiler sinir sisteminin komplike çalışmasıyla ilgili organa gönderilir (Yayık, 2013: 6).


Duyu organları



Şekil 4.1. Biyolojik sinir sistemi blok gösterimi

(Kaynak: Fırat ve Güngör, 2004: 3269)

Biyolojik bir sinir hücresi, diğer adıyla nöron; dentrit, akson, çekirdek ve bağlantılar olmak üzere 4 ana kısımdan oluşmaktadır. Dentrit sinir hücresinin ucundaki bitki köküne benzer yapıdır ve görevi bağlı olduğu diğer nöronlardan ve duyu organlarından gelen sinyalleri çekirdeğe iletmektir. Dentritten gelen sinyalleri toplama görevi gören çekirdek bu sinyalleri aksonlara iletir. Aksonlarda toplanan sinyaller burada işlenerek nöronun bir diğer ucundaki sinaptik bağlantılara gönderilir. Bağlantılar da üretilen bu yeni sinyalleri diğer nöronlara iletir ve sinyallerin nöronlar arasındaki dolaşımı bu şekilde devam eder (Yayık, 2013: 7).



Şekil 4.2. Biyolojik sinir hücresi şekli


4.3.2. Yapay Sinir Ağı Hücresi

Yapay sinir ağları girdi katmanı, ara katman ve çıktı katmanı olmak üzere 3 ana kısımdan oluşur.

Girdi katmanı; dış dünyadan alınan bilgileri herhangi bir işleme tabi tutmadan doğrudan ara katmana iletilmekle yükümlüdür.


Ara katman; girdi katmanından gelen verileri işleyerek çıktı katmanına gönderir. Bir ağ yapısında ara katman sayısı bir tane olabileceği gibi birden fazla da olabilir.

Çıktı katmanı; ara katmandan gelen bilgilerin işlenerek, girdilere uygun şekilde üretilmesi gereken çıktının üretildiği yerdir. Üretilen çıktı dış dünyaya gönderilir (Özel, 2018: 28).



Şekil 4.3. Çok katmanlı bir yapay sinir ağı örnek modeli

Yapay sinir ağları da her canlı varlığın temel yapı taşı gibi hücrelerden oluşur. Yapay sinir hücreleri bilgilerin işlendiği en küçük ve temel birimdir. Yapay sinir ağlarının içerisinde bulunan bütün sinir hücreleri bir veya birden fazla girdi alabilir ancak bu girdilerden tek bir çıktı üretir. Bu, dış dünyaya verilen bir çıktı olabileceği gibi başka bir hücreye giriş olarak da verilebilir (Arıkan Kargı, 2015: 38).



Şekil 4.4. Yapay sinir ağı hücresi matematiksel modeli işleyişi

$X_{1,2,3,...,n}$ = Giriş değerleri

$w_{1,2,3,...,n}$ = Ağırlık değerleri

Σ =Toplama fonksiyonu

$f(x)$ = Aktivasyon fonksiyonu

Y= Çıkış

Bir yapay sinir hücresi;

- Girdiler
- Ağırlıklar
- Toplama Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktılar

bileşenlerinden oluşur.

Girdiler: Dış ortamdan hücreye giren bilgilerdir. Giriş katmanı tarafından alınır.

Ağırlıklar: Ağa gelen bilgiler çekirdeğe ulaşmadan önce her bir giriş kendi bağlantısının ağırlığı ile çarpılarak bir sonraki katmana iletilir. Böylelikle giriş değerlerinin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir. Ağırlık değerleri negatif, pozitif ya da sıfır olabilmektedir.

Toplama Fonksiyonu: Hücreye gelen net girdinin hesaplayan fonksiyondur. Net girdi genellikle hücreye gelen girişlerin ilgili ağırlıklarla çarpımlarının toplamına eşit olmaktadır. Toplama fonksiyonu minimum, maksimum ya da çarpım şeklinde de olabileceği gibi buna ağ yapısına göre karar verilir.

Aktivasyon Fonksiyonu: Toplama fonksiyonundan gelen net girdiyi işlemden geçirerek hücrenin çıktısını belirleyen fonksiyondur. Aktivasyon işlemi ile elde edilen nöron çıkışı bir eşik değeri ile karşılaştırılır ve eşik değerinden büyük olması durumunda sinyal oluşturur.

Aktivasyon için genellikle doğrusal olmayan bir fonksiyon seçilir. Ağın gerçekleştirmesi istenen işleve göre çeşitli tipte aktivasyon fonksiyonu vardır. Bunlardan hangisinin kullanılacağı tasarımcıya, verilere ve ağdan ne istenildiğine göre değişmektedir. Bu fonksiyonlardan en çok kullanılanları sigmoid (logsig), hiperbolik tanjant (tansig) ve purelin fonksiyonlarıdır.

$$\text{Logsig} \rightarrow y = F(x) = \frac{1}{1+e^{-x}} \quad (4.1)$$

$$\text{Tansig} \rightarrow y = F(x) = \frac{2}{1+e^{-2x}} - 1 \quad (4.2)$$

$$\text{Purelin} \rightarrow y = F(x) = x \quad (4.3)$$

Çıktılar: Aktivasyon fonksiyonundan geçirilen değerler çıktıyı oluşturur. Üretilen bu değerler çıktı katmanından dış dünyaya gönderilir.

4.4. Yapay Sinir Ağlarının Sınıflandırılması

4.4.1. Mimari Yapılarına Göre Sınıflandırılması

4.4.1.1. İleri Beslemeli Yapay Sinir Ağları (FeedForward)

Herhangi bir giriş örneği için ağın mevcut parametreleri ile üreteceği çıkışı hesaplama işlemidir.

İleri beslemeli ağlarda nöronlar düzenli katmanlar şeklindedir ve bağlantılarda girişten çıkışa doğru tek yönlü bir ilerleme söz konusudur. Bu ağlarda bir katmandaki bütün hücre çıktıları kendinden bir sonraki katmandaki tüm hücrelere giriş olarak verilmektedir.

İleri beslemeli ağlara örnek olarak, çok katmanlı yapay sinir ağları (MLP), doğrusal vektör parçalama modeli (LVQ) ve radyal tabanlı fonksiyon ağları (RBF) verilebilir. Şekil tanıma, sinyal işleme ve sınıflandırma gibi problemlerde bu ağ yapısı tercih edilmektedir (Arıkan Kargı, 2015: 63)

4.4.1.2. Geri Beslemeli Yapay Sinir Ağları (FeedBack)

Geri besleme, bir sinir ağındaki ara veya çıktı katmanlarındaki çıkışların giriş veya ara katmanlardaki nöronlara yeniden giriş olarak verilmesi işlemidir. Bu ağlarda giriş ve çıkış birimleri arasında bir döngü vardır. Bu şekilde ağa gelen veriler hem ileri hem de geri yönde aktarılmaktadır.

Geri beslemeli ağlar dinamik hafızalı ağlar olup, bir andaki çıkış değeri hem o andaki hem de daha önceki giriş değerini yansıtmaktadır. Geri besleme, bir katmandaki işlemci elemanları arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu özelliği ile geri beslemeli ağlar doğrusal olmayan dinamik bir davranış göstermektedir. Bu özelliği sayesinde geri beslemenin yapılış şekline göre farklı yapı ve davranışlara sahip yeni ağ modelleri oluşturulur (Saraç, 2004: 28).

Geri beslemeli ağlara Hopfield, Elman, SOM (Self Organizing Map) ve Jordan ağları örnek olarak gösterilebilir.

4.4.2. Öğrenme Algoritmalarına Göre Sınıflandırılması

Ağın içinde bulunduğu ortam tarafından, devam eden bir süreçte bağımsız ağ parametrelerinin ayarlanması işlemine öğrenme denir

Yapay sinir ağıları, başlangıçta rastgele seçilen ağırlık değerlerini, kendisine örnek gösterdikçe, ağa verilen örnek girişler için doğru çıkışları bulmak amacıyla değiştirirler. Ağ, defalarca gösterilen farklı örnekleri yorumlar ve en uygun ağırlık değerlerini bulmaya çalışır. İşte ağın doğru ağırlık değerlerine ulaşmasına yani kendisine gösterilen örneklerin temsil ettiği olay hakkında genelleme yapabilme yeteneğine kavuşmasına ağın öğrenmesi denilmektedir (Öztemel, 2012: 55).

Yapay sinir ağlarında öğrenme birden fazla şekilde olabilmektedir.

4.4.2.1. Danışmanlı Öğrenme

Danışmanlı öğrenme yönteminde çalışma kümesi, verinin özelliklerini ve gözlemlenebilir çıktılar hakkında bütün bilgileri içerir. Girdilerle çıktılar ilişkisi öğrenilerek model oluşturulur.

Danışmanlı öğrenmede ağa girdi değerlerinin yanı sıra çıktı değerleri de verilir. Girdi değerleri ağ tarafından işleme alınır ve buna karşılık ağın ürettiği çıktı ile ağa verilen gerçek çıktı karşılaştırılır. Bu karşılaştırma sonucu elde edilen aradaki fark hata olarak kabul edilir ve ağa geri verilir. Ağ, ağırlık değerlerini değiştirerek bu hata değerini minimuma indirmeye çalışır. Öğrenme, hata değeri kabul edilebilir bir seviyeye ininceye kadar devam eder.

Ağ bu yöntemde, kendisine gösterilen örneklerden yola çıkarak giriş ile çıkış değerleri arasında bir bağlantı kurmaya çalışır. Ağa ne kadar örnek gösterirsek girişler ve çıkışlar arasındaki bağlantıyı o kadar iyi kuracak ve doğru sonuca da bir o kadar yaklaşıacaktır.

Widrow-Hoff tarafından geliştirilen delta kuralı, Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı ve geriye yayılım algoritması danışmanlı öğrenme algoritmalarına örnektir (Arıkan Kargı, 2015: 66).

4.4.2.2. Danışmansız Öğrenme

Bu öğrenme yönteminde ağa sadece giriş değerleri verilir. Ağın giriş değerlerinden yola çıkarak parametreler arasındaki ilişkiyi kendi kendine öğrenip girişlere uygun çıktı üretmesi beklenir.

Öğrenme kurallarından Grossberg tarafından geliştirilmiş ART (Adaptive Resonance Theory) ve Kohonen'in geliştirdiği SOM (Self Organizing Map) öğrenme kuralları danışmansız öğrenmeye örnek olarak gösterilebilir.

Danışmansız öğrenme genellikle sınıflandırma problemlerinin çözümünde kullanılmaktadır (Arıkan Kargı, 2015: 67).

4.4.2.3. Takviyeli (Destekli) Öğrenme

Takviyeli öğrenmede istenilen çıkışın bilinmesine gerek duyulmaz. Ağa, verilen girişler için ürettiği çıktılar hakkında gerçek çıkışlara ne derece yaklaştığı konusunda bilgi verilir. Ağ eğitimciden aldığı sinyalleri kullanarak öğrenme sürecine devam eder.

LVQ ağları takviyeli öğrenme metodu kullanan başlıca örnektir. Bunun yanında optimizasyon problemlerini çözmede kullanılan Boltzmann kuralı veya eğitimde Genetik Algoritma kullanımı takviyeli öğrenmeye örnek gösterilebilir (Bayır, 2006: 28)

4.5. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarında öğrenme için, öğrenmenin ne şekilde gerçekleştiğine bakılmaksızın belirli kurallar uygulanır. Ağ parametrelerinin değerleri değiştirilirken uygulanan bu kurallara ‘öğrenme kuralları’ denilmektedir. Bu kurallar ağın şekline ve çözülmesi istenen probleme göre farklılık gösterebilir.

4.5.1. Çevrim İçi (On-Line) Öğrenme

Bu kurallar uygulanırken ağ, gerçek zamanlı çalışmaktadır. Bir taraftan fonksiyonlarını yerine getirirken, bir taraftan da öğrenme işlemine devam eder. Kohonen ve ART ağı öğrenme kuralı çevrim içi öğrenme kurallarına örnek gösterilebilir.

4.5.2. Çevrim Dışı (Off-Line) Öğrenme

Çevrim dışı öğrenmede eğitim yani ağın öğrenmesi, gerçek zamanlı değildir. Bu şekilde kullanılan sistemlerde ağ önce eğitilir ardından kullanımdan çıkarılır ve aktif değilken test edilir ve uygulamaya konulur. Uygulamaya konulup kullanıma başlandığı andan itibaren ağda öğrenme gerçekleşmez. Ağı yeniden eğitilmesi gerektiği noktada kullanımdan çıkarılıp eğitim tamamlanır ve ardından yeniden dış dünyadaki uygulamalar için aktif edilir. Delta öğrenme kuralı, çevrim dışı öğrenmenin en yaygın örneklerindendir.

4.5.3. Temel Öğrenme Kuralları

Hebb Kuralı

1949 yılında Donald Hebb tarafından geliştirilmiş olup, bilinen ilk ve en eski öğrenme kuralı olmasının yanında diğer öğrenme algoritmalarının temelini oluşturmuştur.

Hebb’e (1949) göre A hücresi B hücrelerini uyarmak için yeterince yakın olup tekrarlı ve kalıcı bir şekilde ateşlemede yer alıyorsa bir veya her iki hücrede bazı değişiklikler meydana gelir ve A’nın verimliliği (etkinliği) artar.

Hücreler arası bilgi alışverişi aktif (matematiksel olarak aynı işaretli) iki hücre arasında oluyor ise aralarındaki bağlantı güçlendirilmelidir. Yani bu kurala göre aktif olan hücre bağlı olduğu hücreyi aktifleştirmek için çalışırken pasif olan hücre de bağlı olduğu hücreyi pasifleştirmek için çalışmaktadır denilebilir (Öztemel, 2012: 26).

Hopfield Kuralı

Hopfield kuralının Hebb'den farkı, hücreler arası bağlantıların ne kadar güçlendirilmesi ve zayıflatılması gerektiğinin belirlenmesidir. Bunun için kullanıcı tarafından belirlenen 0-1 değer aralığında sabit bir öğrenme katsayısı kullanılır. Şayet girdiler ve üretilen çıktıların ikisi de aktifse bağlantı ağırlıkları öğrenme katsayısı oranında artırılır, tam tersi durumda ise yine öğrenme katsayısı oranında azaltılır.

Delta Kuralı

Bu kurala göre ağdan üretmesi beklenen çıktı ve gerçekte ürettiği çıktı arasındaki farkı en aza indirmek için sürekli olarak nöronlar arasındaki bağlantı ağırlıklarının değiştirilmesi gerekmektedir. Bu kuralda üretilen çıktı ile beklenen çıktı arasındaki farkların karelerinin ortalaması minimuma düşürülmeye çalışılır. En Küçük Kareler Yöntemi (Least Mean Square-LMS) olarak da bilinir.

Hebb kuralının gelişmiş hali olan Delta kuralı, Widrow ve Hoff tarafından geliştirilmiştir.

Kohonen Kuralı

Kohonen 1982 yılında bu kuralı geliştirirken biyolojik sistemlerdeki öğrenmeden esinlenmiştir. Kohonene'e göre hücreler ağırlıklarının değiştirilmesi için birbiri ile yarışmaktadır. Uygun çıktıyı üreten işlemci eleman kazanır ve ağırlığı değiştirilir. Bu sırada kazanan hücreye komşu diğer elemanların da ağırlıklarının değiştirilmesine izin verilir. Komşu sayıları eğitim süresi boyunca değişiklik gösterebilir.

5. MATERYAL VE METOT

Türkiye'nin en büyük baraj gölü olan Atatürk Barajı çalışma alanı olarak seçilmiştir. Fırat nehri üzerine kurulu olan Adıyaman ve Şanlıurfa illeri arasında bulunan Atatürk barajı, hem hidroelektrik santrali ile enerji üretimi amaçlı hem de tarımsal sulama amaçlı kullanılan GAP projesine dahil barajlarımızdandır. Su depolama hacmi toplamda 48,7 milyar m³'tür. Barajın temelden yüksekliği 169 metre, baraj duvarı uzunluğu 1644 metre, eni 15 metre ve gövde hacmi 84,5 milyon m³ olup kaya dolgu barajlar arasında yer almaktadır. Baraj bölgesindeki iklim Güneydoğu Anadolu Bölgesi'nin iklim özelliklerini gösterir. (DSİ, 2022: 01)

Çalışma için Atatürk Barajı kapsamındaki Bozova istasyonundan 2016-2018 yılları arası günlük minimum ve maksimum sıcaklık, ortalama sıcaklık, nisbi nem, rüzgar hızı, global güneş radyasyonu ve buharlaşma verileri temin edilmiştir. Alınan 6937 adet verinin 4937 adedi ağın eğitiminde, kalan 2000 adet veri ise testinde kullanılmıştır.

YSA'da ağ giriş ve çıkışlarında kullanılacak verilerin belirli bir ön işlemden geçirilerek eğitimin daha verimli hale getirilmesi mümkündür. Normalizasyon adımı verdiğimiz bu işlem, modelleyicinin seçtiği formülasyon ile verileri belirli bir aralığa indirger. (Yavuz ve Deveci, 2013: 175) Bu modellemede kullanılacak tüm veriler normalizasyon işleminden geçerek ağa sunulmuştur.

Kullanılan normalizasyon formülü aşağıdaki gibidir:

$$\text{min-max normalizasyonu : } x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (5.1)$$

Tasarlanan çok katmanlı yapay sinir ağı modeli yapısı feed-forward backpropagation yani ileri beslemeli geri yayımlı yapay sinir ağı seçilmiş, eğitim fonksiyonu olarak Levenberg-Marquardt yöntemi ve performans kriteri olarak da MSE (Mean Square Error-En küçük kareler yöntemi) baz alınmıştır. Ara katman sayısı olarak 3 ile 10 aralığında farklı değerler denenmiş en iyi sonucu veren ara katman sayısı ile modellemeye devam edilmiştir. İterasyon sayısı 1000, öğrenme katsayısı 0.01 olarak alınmıştır. Transfer fonksiyonu olarak sigmoid fonksiyon olan logsig kullanılmıştır.

Kullanılan aktivasyon fonksiyonu;

$$\text{Logsig: } Y = \frac{1}{1 + e^{-n}} \quad (5.2)$$

Buharlařmada etkin rol oynayan parametreler ilk olarak aęa tek tek sunularak etkinlik derecelerini gözlemlemek amaçlanmıřtır. Ardından farklı modeller ile aę eęitimi tamamlanmıř ve test edilmiřtir.



6. BULGULAR

Ağ modeli oluşturulurken öncelikli olarak tüm veriler kullanılarak doğru ağ modelinin araştırılması yapılmıştır. Kullanılan eğitim modeli, ara katman sayısı gibi kavramlar değiştirilerek en iyi sonucu verecek modele ulaşılmaya çalışılmıştır. Bunun için eğitim algoritması olarak tahminlerde başarılı olduğu öne sürülen değişken öğrenme oranlı geri yayılım GDX (Gradient Descent with Momentum& Adaptive LR) algoritması ile LM (Levenberg-Marquardt) algoritması karşılaştırılmış ve LM eğitim modelinin daha başarılı olduğu görülerek çalışmalara LM ile devam edilmiştir. (Tablo 6.1)

Eğitim algoritması belirlendiği ağ için bu sefer de farklı ara katman sayıları denenerek en başarılı sonuca erişmek planlanmıştır. Ara katman sayısı olarak sırasıyla 3, 5, 8 ve 10 değerleri kullanılmıştır. Sonuçlar incelendiğinde ara katman sayısı olarak en verimli performansın görüldüğü ara katman sayısı 10 olarak görülmüştür. (Tablo 6.1) Böylelikle iterasyon sayısı ve öğrenme oranı daha önceden seçilerek sabit tutulmuş, LM eğitim algoritmasının kullanıldığı 10 ara katmanlı ağımızın taslağı tamamlanmıştır.

Tablo 6.1. Farklı eğitim modeli ve ara katman sayılarının performans değerlendirmesi

S.N	Kullanılan Eğitim Modeli	Ara Katman Sayısı	R	MSE
1	GDX	10	0,88492	0,00473
2	LM	10	0,89831	0,00462
3	LM	8	0,89425	0,00407
4	LM	5	0,88653	0,00505
5	LM	3	0,86613	0,00547

Buharlaşmayı etkileyen faktörler ağ modeline ilk olarak bireysel halde sunularak her bir unsurun etkinlik derecesi gözlemlenmiştir. Ağa ayrı ayrı sunulan her bir parametreden buharlaşma üzerinde en etkili olan unsurun sıcaklık olduğu görülmüştür. (Tablo 6.2)

Temin edilen veri setinde günlük ortalama sıcaklık ile birlikte maksimum ve minimum sıcaklık verileri de bulunduğu için burada ortalama değer yeterli olup olmadığının gözlemlenmesi fırsatı bulunmuştur. Tablo 6.2 incelendiğinde minimum ve maksimum sıcaklığın ortama sıcaklık değerlerine oranla ağ üzerinde daha iyi sonuç verdiği gözlemlenmiştir.

Tablo 6.2. Buharlaşmaya etki eden parametrelerin bireysel olarak değerlendirilmesi

S.N	Değişken parametreler	R (Korelasyon Katsayısı)	MSE(Hata)
1	Güneş Radyasyonu (w/m^2)	0,42044	0,03764
2	Min-Maks Sıcaklık ($^{\circ}C$)	<u>0,61408</u>	<u>0,02187</u>
3	Ortalama Sıcaklık ($^{\circ}C$)	0,58333	0,02725
4	Nisbi Nem (%)	0,42982	0,03182
5	Rüzgar Hızı (km/h)	0,42271	0,03396

Bu sonucun doğruluğunun sağlamasını yapmak üzere diğer veriler ile birlikte çalışması incelenmiştir. Ağa ilk olarak güneş radyasyonu, nisbi nem ve rüzgar hızı ile birlikte ortalama sıcaklık verileri sunulmuş ve ağın başarısı gözlemlenmiş, ardından da diğer üç veriye ek maksimum ve minimum sıcaklık değerleri verilerek modelin başarısı gözlemlenmiştir. Tablo 6.3’de görülmektedir ki oluşturulan ağ modeline diğer verilerle birlikte maksimum ve minimum sıcaklık değerleri gösterildiğinde daha başarılı sonuç elde edilmiştir. Her iki şekilde de minimum ve maksimum sıcaklık değerlerinin ağ sistemine verilmesi ortalama sıcaklık verilerine oranla performansı artırmıştır. Bu çalışmaya da maksimum ve minimum sıcaklık değerleriyle devam edilmiştir.

Tablo 6.3. Maksimum minimum sıcaklık ve ortalama sıcaklık verilerinin model üzerindeki başarısının kıyaslanması


S.N	Giriş Parametreleri	Ağ modeli	R	MSE
1	GR+Maks S+Min S+RH+BN	5-10-1	<u>0,90179</u>	<u>0,003953</u>
2	GR+Ort S+RH+BN	4-10-1	0,88524	0,004358

Elimizdeki maksimum ve minimum sıcaklık, güneş radyasyonu, nisbi nem ve rüzgar hızı verilerinden farklı girdi modelleri oluşturulmuş (Tablo 6.4) ve en başarılı sonucun elde edildiği model incelenmiştir.


Tablo 6.4. Çeşitli giriş modellerinin ağ üzerindeki performansının incelenmesi

Ağ Modeli	Giriş Parametreleri	R	MSE
YSA-I	GR+Maks S+Min S	0,76612	0,011443
YSA-II	GR+Maks S+Min S+BN+RH	0,89893	0,004620
YSA-III	Maks S+Min S+BN+RH	0,85206	0,007519
YSA-IV	GR+Maks S+Min S+BN	0,84822	0,008310
YSA-V	GR+Maks S+Min S+RH	0,83616	0,009079


Yüksek R korelasyon katsayısı ve düşük MSE hata değeri ile tasarlanan ağ üzerindeki en başarılı model güneş radyasyonu, maksimum ve minimum sıcaklık, bağıl nem ve rüzgar hızının sisteme giriş olarak verildiği YSA-II modeli olmuştur. En az başarılı model ise sadece güneş radyasyonu ve minimum-maksimum sıcaklık verilerinin girdi olarak modele gösterildiği YSA-I olmuştur.




Şekil 6.1. YSA-I ağ modeli performansı




Şekil 6.2. YSA-II ağ modeli performansı



Şekil 6.3. YSA-III ağ modeli performansı




Şekil 6.4. YSA-VI ağ modeli performansı



Şekil 6.5. YSA-V ağ modeli performansı

Oluşturduğumuz ağ modelinde en iyi performansa sahip olan YSA-II modelimizi yeniden teste tabi tuttuğumuzda elde edilen bulgular $R=0,87166$ ve MSE hata oranı ise $0,006029$ şeklindedir.



Şekil 6.6. YSA-II ağıının test performansı

7. SONUÇ VE ÖNERİLER

Atatürk Barajı'ndan elde edilen günlük veriler ile yapay sinir ağı yöntemi kullanılarak tasarlanan ağ modelinin yüksek performans ile başarılı sonuçlar ortaya çıkardığı görülmüştür. Buharlaşmaya etki eden temel faktör olan sıcaklığın ortalama değeri yerine minimum ve maksimum değerlerini kullanmanın performans verimini artırdığı test edilmiştir. Bu da göstermektedir ki veri temin ederken mümkün mertebe ortalama değerler kullanmak yerine alt ve üst, az ve çok değerlerini ayrı ayrı oluşturulan ağ modeline sunmak daha başarılı sonuçlar elde etmeye fayda sağlayacaktır. Oluşturulan farklı girdi modelleri arasından en iyi performans YSA-II modelinden elde edildiği için buharlaşma tahmininde en başarılı sonuçları elde etmek için güneş radyasyonu, sıcaklık, nem ve rüzgar hızı verilerine sahip olunmalı ve hatta olabildiğince minimum maksimum değerler de temin edilerek çalışma tamamlanmalıdır. Bunun yanında diğerlerine oranla daha az başarı elde edilen YSA-I modeli performansından da anlaşılmaktadır ki sadece sıcaklık ve güneş radyasyonu kullanmak yüksek doğruluk istenen noktada yeterli olmayacaktır. Ayrıca diğer modellerin kendi arasında kıyaslanması sonucu buharlaşmayı etkileyen parametrelerin çoktan aza doğru sıcaklık, nem, rüzgar hızı ve güneş radyasyonu olduğu tespit edilmiştir.

Bu çalışma, uygun veriler elde edilerek ve doğru ağ modeli ile YSA kullanılarak buharlaşmayı yaklaşık %90 doğruluk oranında tahmin etmenin mümkün olduğunu bir kez daha göstermiştir.

KAYNAKÇA

- Afşar, S.** (2008). *Yapay sinir ağları ve bulanık mantık yöntemleri kullanılarak tava buharlaşma tahmini yapılması*. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri
- Antonopoulos, V. Z., Gianniou, S. K., & Antonopoulos, A. V.** (2016). Artificial neural networks and empirical equations to estimate daily evaporation: application to Lake Vegoritis, Greece. *Hydrological Sciences Journal* 61 (14), 2590-2599.
- Arıkan Kargı, V. S.** (Bursa). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*. 2015: Ekin Yayınevi.
- Bayazıt, M.** (2011). *Hidroloji*. İstanbul: Birsen Yayınevi.
- Bayır, F.** (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Dindar, K. K.** (2010). *Yapay Sinir Ağları Yaklaşımı İle Tahtaköprü Barajı'ndaki Aylık Buharlaşma Miktarının Tahmini*. Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Antakya
- Doğan, A.** (2019). *Namazgâh Barajı'na ait buharlaşma miktarının yapay sinir ağı ile tahmin edilmesi*. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Doğan, E., Işık, S., & Sandalcı, M.** (2007). Günlük Buharlaşmanın Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. *İMO Teknik Dergi*, 4119-4131.
- Elmas, C.** (2011). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Environment Agency.** (2001). *Estimation of Open Water Evaporation*. Bristol: R&D Technical Report W6-043/TR.
- Fırat, M., & Güngör, M.** (2004). Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *İMO Teknik Dergi* 219, 3267-3282.
- Gümüş, V., Yeniğün, K., Toprak, Z. F., & Baçi, N. O.** (2018). Şanlıurfa ve Diyarbakır istasyonlarında sıcaklık tabanlı buharlaşma tahmininde YSA, ANFIS ve GEP yöntemlerinin karşılaştırılması. *DÜMF Mühendislik Dergisi* 9(1), 553-562.
- Haykin, S.** (2008). *Neural Networks And Learning Machines*. Canada: Prentice Hall.

- Hebb, D. O.** (2002). *The Organization of Behavior: A Neuropsychological Theory*. New York: Psychology Press
- Keskenler, M. F., & Keskenler, E. F.** (2017). Geçmişten Günümüze Yapay Sinir Ağları Tarihçesi. *Takvim-i Vekayi* 5(2), 8-18.
- Keskin, M. E., & Terzi, Ö.** (2006). Artificial Neural Network Models of Daily Pan Evaporation. *Journal of Hydrologic Engineering* 11(1), 65-70.
- Keskin, M. E., Terzi, Ö., & Taylan, D.** (2004). Fuzzy logic model approaches to daily pan evaporation in western Turkey. *Hydrological Sciences Journal* 49(6), 1001-1010.
- Kiş, Ö.** (2007). Evapotranspiration modelling from climatic data using a neural computing technique. *Hydrological Processes*, 1925-1934.
- Kumar, P., & Tiwari, A. K.** (2012). Evaporation Estimation Using Artificial Neural Network', International Journal of Computer Theory and Engineering. *International Journal of Computer Theory and Engineering*, 51-53.
- Mazmancı, K.** (2009). *Çatalan Barajı Haznesindeki Buharlaşma Miktarının Yapay sinir Ağları Modeliyle Tahmini*. Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Antakya/Hatay
- Meteoroloji Genel Müdürlüğü.** (2022). *Analizler-Buharlaşma*: [Erişim:01.02.2022, <https://www.mgm.gov.tr/arastirma/buharlasma.aspx?s=3>]
- Özel, A.** (2018). *Meteorolojik verileri kullanarak aylık tava buharlaşmasını tahmin etmek için yapay zeka metotlarının uygulanması*. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya.
- Özel, A., & Büyükyıldız, M.** (2019). Aylık Buharlaşma Tahmininde Yapay Zeka Yöntemlerinin Kullanılabilirliği. *ÖHÜ Müh. Bilim. Dergisi*, 244-254.
- Öztemel, E.** (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- Pallavi, K., & Rajeev, S.** (2016). Predicting Reservoir Evaporation Using Artificial Neural Network. *International Journal of Innovative Research in Science, Engineering and Technology*, 5851-5857.

- Saraç, T. (2004).** *Yapay Sinir Ağları*. Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı, Ankara
- Sattari, M. T., Fard, A. F., Docherkhesaz, M., & Öztürk, F. (2007).** Yapay Sinir Ağları Yöntemi ile Savalan Sulama Rezervuarının Simülasyonu. *Ankara Üniversitesi Tarım Bilimleri Dergisi* 13(4), 337-345.
- Shiri, J., Dierickx, W., Baba, A.-A., Neamati, S., & Ghorbani, M. A. (2011).** Estimating daily pan evaporation from climatic data of the State of Illinois, USA using adaptive neuro-fuzzy inference system (ANFIS) and artificial neural network (ANN). *Hydroloji Research* 42(6), 491-502.
- Şen, Z. (2002).** *Su Bilimi Temel Konuları*. İstanbul: Su Vakfı Yayınları.
- Taşar, B., Üneş, F., Demirci, M., & Kaya, Y. Z. (2018).** Yapay Sinir Ağları Yöntemi Kullanılarak Buharlaşma Miktarı Tahmini. *DÜMF Mühendislik Dergisi*, 543-551.
- Terzi, Ö. (2007).** Data Mining Approach For Estimation Evaporation from Free Water Surface. *Journal of Applied Sciences* 7(4), 593-596.
- Terzi, Ö. (2013).** Daily pan evaporation estimation using gene expression programming and adaptive neural-based fuzzy inference system. *Neural Computing&Applications* 23(3-4), 1035-1044.
- Terzi, Ö. (2013).** Estimating daily pan evaporation using data mining process. *Scientia Iranica A* 20(4), 1077-1084.
- Terzi, Ö., & Keskin, M. E. (2005).** Yapay Sinir Ağları Yaklaşımı Kullanılarak Günlük Tava Buharlaşması Tahmini. *İMO Teknik Dergi*, 3683-3693.
- Usul, N. (2008).** *Mühendislik Hidrololjisi*. Ankara: ODTÜ Yayıncılık.
- Üneş, F., Doğan, S., Taşar, B., Kaya, Y. Z., & Demirci, M. (2018).** The Evaluation and Comparison of Daily Reference Evapotranspiration with ANN and Empirical Methods. *Naural and Engineering Sciences* 3(3), 54-64.
- Yaşar, M. (2004).** *Günlük akışlardaki boşlukların yapay sinir ağı kullanılarak tamamlanması*. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.

- Yavuz, S., & Deveci, M.** (2012). İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 40, 167-187.
- Yayık, A.** (2013). *Yapay sinir ağı ile kriptoloji uygulamaları*. Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Antakya/Hatay.
- Yeşiltaş, Y.** (2018). *Yapay Zekâ Yöntemleri İle Gap Bölgesindeki Aylık Tava Buharlaşma Değerlerinin Tahmin Edilmesi*. Harran Üniversitesi Fen Bilimleri Enstitüsü, Şanlıurfa .
- Yurdusev, M. A., Acı, M., Turan, M. E., & İçağa, Y.** (2008). Akarçay nehri aylık akımlarının yapay sinir ağları ile tahmini. *C.B.Ü. Fen Bilimleri Dergisi* 4(1), 73-88.

