



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**REFERANS BUHARLAŞMA
MİKTARININ BULANIK SMRGT,
ANFİS VE ÇOKLU DOĞRUSAL
REGRESYON YÖNTEMLERİ İLE
TAHMİNİ**

Serkan DEMİREL

**İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI**

EYLÜL 2023





**REFERANS BUHARLAŞMA MİKTARININ BULANIK SMRGT, ANFİS VE
ÇOKLU DOĞRUSAL REGRESYON YÖNTEMLERİ İLE TAHMİNİ**

Serkan DEMİREL

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

EYLÜL 2023

Serkan DEMİREL tarafından hazırlanan “REFERANS BUHARLAŞMA MİKTARININ BULANIK SMRGT, ANFİS VE ÇOKLU DOĞRUSAL REGRESYON YÖNTEMLERİ İLE TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mustafa DEMİRCİ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

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

Başkan: Prof. Dr. Mustafa DEMİRCİ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

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

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

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

Üye: Dr. Öğr. Üyesi Şahin Tolga GÜVEL
İnşaat Mühendisliği, Osmaniye Korkut Ata Üniversitesi

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

Tez Savunma Tarihi: 01/09/2023

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

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

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

İmza

Serkan DEMİREL

01/09/2023

REFERANS BUHARLAŞMA MİKTARININ BULANIK SMRGT, ANFİS VE ÇOKLU
DOĞRUSAL REGRESYON YÖNTEMLERİ İLE TAHMİNİ
(Yüksek Lisans Tezi)

SERKAN DEMİREL

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Eylül 2023

ÖZET

Evapotranspirasyon tahmininin doğru bir şekilde yapılması, su kaynaklarını geliştirmek, kontrol etmek ve yönetmek için son derece kritik bir öneme sahiptir. Su kaynaklarının gün geçtikçe azaldığı düşünüldüğünde buharlaşmadan kaynaklanan kayıpların da artan bir önemi bulunmaktadır. Bu çalışmada günlük evapotranspirasyon tahmini yapılmıştır. Çalışmada kullanılacak veriler Meteoroloji Genel Müdürlüğü (MGM) tarafından işletilmekte olan 17351 numaralı Adana Bölge istasyonundan elde edilmiştir. Veriler 2015-2021 yılları arasındaki günlük ortalama sıcaklık (TM), bağıl nem (RH), rüzgâr hızı (U) ve solar radyasyon (SR) değerlerini kapsamaktadır. Toplam 1966 günlük veri kullanılmış olup bu verilerin %75'i (1476 günlük veri) eğitim aşamasında %25'i (490 günlük veri) test aşamasında kullanılmıştır. Meteorolojik veriler ile farklı kombinasyonlar oluşturulmuştur. Bu kombinasyonlar girdi parametresi olarak düzenlenmiştir. Evapotranspirasyon tahmini için Penman Monteith yöntemi referans olarak kabul edilmiştir. (ET_0) Günlük evapotranspirasyon miktarı Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (Bulanık SMRGT) ile Adaptif Sinirsel Bulanık Çıkarım sistemi (ANFİS) yöntemleri kullanılarak tahmin edilmiştir. Elde edilen sonuçlar klasik Çoklu Doğrusal Regresyon (ÇDR) yöntem sonuçları ile karşılaştırılmıştır. Tüm analizlerde göz önüne alınan ölçütler olan determinasyon katsayısı (R^2) ve hata oranlarına (MOH, KKOH) dayanarak, ANFİS modelinin SMRGT ve ÇDR modellerine kıyasla evapotranspirasyon tahminlerinde daha üstün sonuçlar sunduğu gözlemlenmiştir. ANFİS modeli, daha yüksek bir determinasyon katsayısı (0.9988) ve daha düşük hata oranı (MOH: 0.046mm, KKOH: 0.067 mm) değerlerine sahip olmasıyla daha iyi bir performans sergilemiştir.

Anahtar Kelimeler : Bulanık mantık, Basit üyelik fonksiyonları, Bulanık kural oluşturma tekniği, Adaptif sinirsel bulanık çıkarım, Çoklu doğrusal regresyon, Referans evapotranspirasyon tahmini
Sayfa Adedi : 66
Danışman : Prof. Dr. Mustafa DEMİRCİ

ESTIMATION OF REFERENCE EVAPORATION AMOUNT WITH FUZZY SMRGT, ANFİS AND MULTIPLE LINEAR REGRESSION METHODS

(M. Sc. Thesis)

SERKAN DEMIREL

ISKENDERUN TECHNICAL UNIVERSITY
INSTITUTE OF GRADUATE STUDIES

September 2023

ABSTRACT

Accurate estimation of evapotranspiration is critical for developing, controlling and managing water resources. Considering that water resources are decreasing day by day, losses due to evaporation are of increasing importance. In this study, daily evapotranspiration was estimated. The data to be used in the study were obtained from Adana Regional Station No. 17351 operated by the General Directorate of Meteorology (MGM). The data covers daily average temperature (TM), relative humidity (RH), wind speed (U) and solar radiation (SR) values between 2015-2021. A total of 1966 daily data was used, 75% of which (1476 daily data) was used in the training phase and 25% (490 daily data) was used in the testing phase. Different combinations were created with meteorological data. These combinations were organized as input parameters. Penman Monteith method was used as a reference for evapotranspiration estimation. (ET_0) Daily evapotranspiration was estimated using Simple Membership Functions and Fuzzy Rule Generation Technique (Fuzzy SMRGT) and Adaptive Neural Fuzzy Inference System (ANFİS) methods. The results obtained are compared with the results of the classical Multiple Linear Regression (MLR) method. Based on the coefficient of determination (R^2) and error rates (MAE, RMSE), which are the metrics considered in all analyses, it is concluded that the ANFİS model is more accurate in predicting evapotranspiration compared to the SMRGT and MLR models. The ANFİS model performed better with a higher coefficient of determination (0.9988) and a lower error rate (MAE: 0.046mm, RMSE: 0.067mm).

Keywords : Fuzzy logic, Simple membership functions, Fuzzy rule generation technique, Adaptive neural fuzzy inference, Multiple linear regression, Reference evapotranspiration estimation

Number of Pages : 66

Supervisor : Prof. Dr. Mustafa DEMİRCİ

TEŞEKKÜR

Tez konusundaki anlayışımı derinleştirmeme ve araştırmalarımı daha etkili bir şekilde yapmama yardımcı olan, bilgi birikimi, deneyimi ve özverisi ile yaptığı kritik yönlendirmeleri ve önerileri sayesinde bu zorlu süreci başarıyla tamamlamamı mümkün kılan tez danışmanım değerli hocam Prof. Dr. Mustafa DEMİRCİ'ye, katkılarını esirgemeyen sayın hocam Prof. Dr. Fatih ÜNEŞ'e teşekkürlerimi arz ederim. Ayrıca çalışmam esnasında her zaman sabırla sorularıma cevap vererek yardımcı olan, motive edici yaklaşımı ve olumlu enerjisi sayesinde bu süreç boyunca desteklendiğimi hissettiren kıymetli hocam Dr. Bestami TAŞAR'a en içten duygularıyla teşekkürlerimi sunarım.

Bana her daim güvenen, inanan ve yanımda olan kıymetli ailem; sizler bu yolculuğumda en büyük destekçim oldunuz. Sürekli bir çalışma halindeyken sabırla bana moral ve cesaret verdiniz. Sizlerin benimle gurur duyduğunuzu bilmek daha da motive bir şekilde çalışmalarımı sürdürmeme teşvik etti. Beni hiçbir zaman yalnız hissettirmeyen annem Nihayet DEMİREL, babam Cahit DEMİREL, kardeşim Ömer DEMİREL'e ve bana olan inancını tüm samimiyetiyle hissettiren meslektaş kız arkadaşım Hilal MAHMAT'a yürekten teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ÇİZELGELERİN LİSTESİ.....	vii
ŞEKİLLERİN LİSTESİ.....	viii
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR	7
3. MATERYAL VE YÖNTEM.....	19
3.1. Çalışma Alanı.....	19
3.2. Kullanılan Modeller	24
3.2.1. Penman-Monteith (PM) yöntemi	24
3.2.2. Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFİS)	26
3.2.3. Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (SMRGT)	35
3.2.4. Çoklu Doğrusal Regresyon (ÇDR)	38
3.3. Model Performansında Kullanılan İstatistik Parametreler	39
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	42
4.1. ANFİS Model Sonuçları	42
4.2. ÇDR Model Sonuçları.....	51
4.3. Bulanık SMRGT Model Sonuçları	59
5. SONUÇ ve ÖNERİLER.....	61
KAYNAKLAR.....	62

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Modellerin Performans Sonuçları	42



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Buharlaşma ve su döngüsü	2
Şekil 1.2. Enlemlere göre ortalama buharlaşma değerinin değişimi	4
Şekil 1.3. Class A Pan Buharlaşma havuzu	5
Şekil 3.1. Çalışma alanı	19
Şekil 3.2. Çalışılan istasyonda 2015-2021 yılları arasındaki maksimum hava sıcaklığı (°C) değerlerinin günlük değişimi	21
Şekil 3.3. Çalışılan istasyonda 2015-2021 yılları arasındaki minimum hava sıcaklığı (°C) değerlerinin günlük değişimi.....	21
Şekil 3.4. Çalışılan istasyonda 2015-2021 yılları arasındaki ortalama hava sıcaklığı (°C) değerlerinin günlük değişimi	22
Şekil 3.5. Çalışılan istasyonda 2015-2021 yılları arasındaki ortalama rüzgar hızı (m/s) değerlerinin günlük değişimi.....	22
Şekil 3.6. Çalışılan istasyonda 2015-2021 yılları arasındaki solar radyasyon (Mj/m ²) değerlerinin günlük değişimi	23
Şekil 3.7. Çalışılan istasyonda 2015-2021 yılları arasındaki nisbi nem (%) değerlerinin günlük değişimi.....	23
Şekil 3.8. Çalışılan istasyonda 2015-2021 yılları arasındaki referans buharlaşma miktarı(mm) değerlerinin günlük değişimi.....	24
Şekil 3.9. ANFİS yapısı	27
Şekil 3.10. Klasik mantığa ait küme sisteminin üyelik fonksiyonları	31
Şekil 3.11. Bulanık mantığa ait küme sisteminin üyelik fonksiyonları	31
Şekil 3.12. Sinir sistemi elemanlarının Yapay Sinir Ağları modelindeki terminolojisi..	34
Şekil 3.13. Üyelik Fonksiyon için çekirdek değer, anahtar değer ve birim genişliğin gösterimi.....	37
Şekil 4.1. Eğitim aşamasında ANFİS1-Referans ET dağılım grafiği	43
Şekil 4.2. Eğitim aşamasında ANFİS1-Referans ET saçılım grafiği.....	44
Şekil 4.3. Test aşamasında ANFİS1-Referans ET dağılım grafiği	44

Şekil	Sayfa
Şekil 4.4. Test aşamasında ANFİS1-Referans ET saçılım grafiği.....	45
Şekil 4.5. Eğitim aşamasında ANFİS2-Referans ET dağılım grafiği	45
Şekil 4.6. Eğitim aşamasında ANFİS2-Referans ET saçılım grafiği.....	46
Şekil 4.7. Test aşamasında ANFİS2-Referans ET dağılım grafiği	46
Şekil 4.8. Test aşamasında ANFİS2-Referans ET saçılım grafiği.....	47
Şekil 4.9. Eğitim aşamasında ANFİS3-Referans ET dağılım grafiği	47
Şekil 4.10. Eğitim aşamasında ANFİS3-Referans ET saçılım grafiği.....	48
Şekil 4.11. Test aşamasında ANFİS3-Referans ET dağılım grafiği	48
Şekil 4.12. Test aşamasında ANFİS3-Referans ET saçılım grafiği.....	49
Şekil 4.13. Eğitim aşamasında ANFİS4-Referans ET dağılım grafiği	49
Şekil 4.14. Eğitim aşamasında ANFİS4-Referans ET saçılım grafiği.....	50
Şekil 4.15. Test aşamasında ANFİS4-Referans ET dağılım grafiği	50
Şekil 4.16. Test aşamasında ANFİS4-Referans ET saçılım grafiği.....	51
Şekil 4.17. Eğitim aşamasında ÇDR1-Referans ET dağılım grafiği	51
Şekil 4.18. Eğitim aşamasında ÇDR1-Referans ET saçılım grafiği	52
Şekil 4.19. Test aşamasında ÇDR1-Referans ET dağılım grafiği	52
Şekil 4.20. Test aşamasında ÇDR1-Referans ET saçılım grafiği	53
Şekil 4.21. Eğitim aşamasında ÇDR2-Referans ET dağılım grafiği	53
Şekil 4.22. Eğitim aşamasında ÇDR2-Referans ET saçılım grafiği	54
Şekil 4.23. Test aşamasında ÇDR2-Referans ET dağılım grafiği	54
Şekil 4.24. Test aşamasında ÇDR2-Referans ET saçılım grafiği	55
Şekil 4.25. Eğitim aşamasında ÇDR3-Referans ET dağılım grafiği	55
Şekil 4.26. Eğitim aşamasında ÇDR3-Referans ET saçılım grafiği	56
Şekil 4.27. Test aşamasında ÇDR3-Referans ET dağılım grafiği	56

Şekil	Sayfa
Şekil 4.28. Test aşamasında ÇDR3-Referans ET saçılım grafiği	57
Şekil 4.29. Eğitim aşamasında ÇDR4-Referans ET dağılım grafiği	57
Şekil 4.30. Eğitim aşamasında ÇDR4-Referans ET saçılım grafiği	58
Şekil 4.31. Test aşamasında ÇDR4-Referans ET dağılım grafiği	58
Şekil 4.32. Test aşamasında ÇDR4-Referans ET saçılım grafiği	59
Şekil 4.33. Test aşamasında Bulanık SMRGT-Referans ET dağılım grafiği	60
Şekil 4.34. Test aşamasında Bulanık SMRGT-Referans ET saçılım grafiği.....	60



SİMGELER VE KISALTMALAR

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

Simgeler

ET

Açıklamalar

Evapotranspirasyon

ET₀

Referans Evapotranspiration

R

Korelasyon katsayısı

RH

Bağıl Nem

R²

Determinasyon katsayısı

SR

Solar Radyasyon

TM

Günlük Ortalama Sıcaklık

U

Rüzgâr Hızı

Kısaltmalar

ANFİS

Açıklamalar

Adaptif Sinirsel Bulanık Çıkarım sistemi

BM

Uyarlamalı sinirsel bulanık çıkarım sistemi

ÇDR

Çoklu Doğrusal Regresyon

FAO

Food and Agriculture Organization

KKOH

Ortalama karesel hataların karekökü

MGM

Meteoroloji Genel Müdürlüğü

MOH

Mutlak ortalama hata

OKH

Ortalama karesel hata

PM

Penman-Monteith

SMRGT

Basit Üyelik Fonksiyonları ve Bulanık Kural

Oluşturma Tekniği

USGS

US Geological Survey Institute

YSA


Yapay Sinir Ağı

1. GİRİŞ

Su yaşamın temel öğelerinden biridir. İnsanlık tarihinden daha eskiye dayanan, dünyanın oluşumuyla birlikte ortaya çıkan su; canlıların hayatsal faaliyetlerini gerçekleştirebilmesi için gerekli doğal bir kaynaktır. Suyun varlığı, yaşamın meydana gelmesindeki temel etmenlerden biri olduğu gibi kendi aynı zamanda bir habitattır. Yani susuz yaşam bir ütopyadır, su yaşam ve canlılık için gerekli olup canlının varoluşu ve canlılığın temelidir. Suyun önemi, yaygın kullanımı ve benzersizliği nedeniyle giderek daha fazla vurgulanmaktadır. Ancak, su kaynaklarının coğrafi dağılımındaki dengesizlik ve su miktarındaki sürekli azalmadan dolayı su kaynakları artan ihtiyaçların karşılanması noktasında her geçen gün daha da yetersiz kalmaktadır.

Doğada tatlı suların devamlılığı su döngüsü ile gerçekleşir. Hidrolojik döngü, yeryüzündeki suyun sürekli bir dönüşümünü ifade eder. Bu döngü, göllerden, akarsulardan, denizlerden ve okyanuslardan atmosfere doğru su buharı yükselmesi ve daha sonra tekrar yeryüzüne yağış olarak dönmesi şeklinde gerçekleşir. Bu doğal döngü, yağışın düşmesi, buharlaşma, yeraltına sızma, yüzey akışı ve yoğunlaşma gibi süreçleri içerir.

Buharlaşma, su döngüsünün önemli bir parçası olarak öne çıkar. Buharlaşma sürekli bir hareket olup su buharının atmosferdeki kaynağı, yeryüzündeki su bulunduran denizlerden, göllerden, nehirlerden, nemli topraklardan, karla kaplı veya buzla kaplı yüzeylerden, ormanlardan ve bitki örtüsüne sahip arazilerden gelir. Dünya yüzeyinden buharlaşan su miktarı ile atmosfere düşen su miktarı arasında yaklaşık bir denge olduğundan, atmosferdeki su buharı miktarı uzun süreli olarak değişmez, ancak coğrafi olarak farklılıklar gözlenir. Buharlaşma ve su döngüsü aşağıda verilmiştir. (Şekil1.1)



Şekil 1.1. Buharlaşma ve su döngüsü (<https://www.mgm.gov.tr/arastirma/buharlasma.aspx>)

Su yüzeyinden buharlaşarak atmosfere geçen kayıplara buharlaşma (evaporasyon), bitki kaynaklı su kayıplarına terleme (transpirasyon) denir. Meydana gelen toplam su kaybı da evapotranspirasyon olarak adlandırılır. Araştırmalara göre atmosferdeki su buharının yaklaşık %90'lık bir kısmını evaporasyon, kalan %10'u da transpirasyon oluşturmaktadır. (USGS, 2016)

Su yüzeyi ve nemli alanlarda meydana gelen buharlaşma, sürekli bir döngü içinde gerçekleşir. Meteorolojik koşulların yanı sıra suyun ve çevresinin özelliklerine bağlı olarak, su yüzeyinden atmosfere geçen su buharı miktarı değişim gösterir. Suyun bu değişimi, enerji etkisiyle gerçekleşmekte olup 1 gram suyun buharlaşması için ihtiyaç duyulan enerji, 539-597 kalorilik bir aralıkta değişiklik gösterir.

Buharlaşma, sıvı bir maddenin (örneğin su) moleküllerinin, ısı alarak gaz haline dönüşmesi sürecidir. Buharlaşma, sıvı maddenin yüzeyinden veya içinden gerçekleşebilir. Buharlaşma, su moleküllerinin sıvı yüzeyinden kaçmasına ve gaz haline geçmesine dayanır. Bu süreç, su moleküllerinin kinetik enerjilerinin artmasıyla gerçekleşir. Sıvı su molekülleri, ısı alarak hızlanır ve moleküler bağları geçici olarak aşarlar. Yeterli enerjiye ulaştıklarında, sıvı yüzeyini terk ederler ve su buharı haline dönüşürler.

Buharlaşma; sıcaklık, nem oranı, rüzgar hızı, güneş ışınları ve basınç gibi faktörlerden etkilenir. Sıcaklık arttıkça buharlaşma hızı genellikle artar, çünkü su moleküllerinin kinetik enerjisi artar. Rüzgar, havada bir su buharı tabakası oluşturarak buharlaşma hızını artırabilir. Güneş ışınları, su yüzeyinden enerji alınmasını sağlayarak buharlaşma sürecini

hızlandırır. Ayrıca, düşük nem oranı ve düşük atmosfer basıncı buharlaşmayı artırabilir. Buharlaşma, suyun atmosfere geri dönüşümünü sağlayan önemli bir süreçtir. Denizler, göller, akarsular, nemli topraklar, bitki yaprakları gibi yüzeylerde sürekli olarak buharlaşma gerçekleşir. Buharlaşan su buharı, atmosferde su döngüsünün bir parçası olarak yükselir, soğur, bulutları oluşturur ve sonunda yağış olarak dünyaya geri döner. Bu, suyun sürekli döngüsünü sağlayan önemli bir adımdır ve iklim ve hava koşullarını etkileyen faktörlerden biridir.

Buharlaşma, su yüzeyinden atmosfere geçiş olayıdır. Su yüzeyi ve atmosfer arasındaki buhar basıncı farkına bağlı olarak gerçekleşir. Bu olay, suyun yüzeyinden buharlaşan moleküllerin hava içindeki boş alanlara geçmesiyle gerçekleşir. Su yüzeyi ile hava arasındaki buhar basınç farkı, buharlaşma hızını etkiler. Eğer su yüzeyindeki buhar basıncı atmosferdeki buhar basıncından yüksekse, buharlaşma hızı artar. Sıcaklık, nem ve hava koşulları, suyun yüzeyinden buharlaşan su moleküllerinin atmosfere ne kadar geçtiğini etkileyen faktörlerdir.

Buharlaşma hızı, hava ve su sıcaklıkları ile doymuş buhar basıncına bağlı olarak önemli ölçüde değişir. Buharlaşma, günlük ve yıllık sıcaklık değişimleri ile benzer bir desen gösterir. Genellikle öğleden sonra buharlaşma en yüksek seviyeye ulaşır. Akşamları ise güneş batışıyla birlikte sıcaklık düşer ve buharlaşma azalır. Sıcak mevsimlerde (yaz), güneş ışınlarının daha dik açıyla gelmesi buharlaşmayı artırır. Soğuk mevsimlerde (kış), güneş ışınlarının daha düşük açıyla gelmesi ve daha az enerji taşınması buharlaşmayı azaltır. Buharlaşma süreci, su buharının su yüzeyinden uzaklaşması için difüzyon ve konveksiyon yoluyla gerçekleşir. Bu süreçlerin sağlanması için hava hareketi (rüzgâr) önemlidir. Rüzgâr hızı arttıkça buharlaşma miktarı da artar.

Sonuç olarak buharlaşma, su yüzeyi ve atmosfer arasındaki buhar basıncı farkı ve çeşitli çevresel faktörlerin etkisiyle gerçekleşen önemli bir süreçtir. Bu süreç, su döngüsünün bir parçasıdır ve suyun atmosfere geri dönüşümünü sağlar.

Buharlaşmanın oluşacağı bölgenin coğrafi konumu ve güneşe karşı pozisyonu buharlaşma sürecinde önemli bir rol oynamaktadır. Bu rol oynayan faktörler enlem, yükseklik ve bakı olarak karşımıza çıkmaktadır. Özellikle açık su yüzeylerinde oluşan buharlaşma miktarının enlem derecesine bağlı olarak farklılık gösterdiği tespit edilmiştir. Serbest su yüzeylerinde, çeşitli enlem derecelerine sahip bölgelerde meydana gelen yıllık ortalama buharlaşma değerleri aşağıda listelenmiştir. (Şekil 1.2)

Enlem Derecesi	Ortalama Buharlaşma (mm/yıl)
0°-10° (Ekvator Bölgesi)	1150
10°-30° (Alize Bölgesi)	2250
30°-40°	1600
40°-50°	1000
50°-60°	450

Şekil 1.2. Enlemlere göre ortalama buharlaşma değerinin değişimi

Diğer koşullar sabit tutulduğunda, yükselti arttıkça buharlaşma miktarı da artar. Bunun nedeni, deniz seviyesinden yukarılara çıkıldıkça hava basıncının azalmasıdır. Benzer olarak, yükselti arttıkça hava sıcaklığı azalır. Hava sıcaklığı azaldığından dolayı buharlaşma miktarı azalır. Fakat buharlaşma miktarındaki yükseltiden dolayı kaynaklanan azalma hava basıncından kaynaklanan artışı tam olarak dengeleyemez, bu yüzden yükselti arttıkça buharlaşmanın az bir miktar da olsa arttığı kabul edilir. Buna ek olarak, Güney ve Batı yamaçları, Kuzey ve Doğu yamaçlarına oranla Güneş'in ışınlarına daha fazla maruz kaldığından buharlaşma bu yamaçlarda bakı etkisinden dolayı daha yüksek olur.

Suyun kalitesi ve bulunduğu ortam buharlaşma miktarı üzerinde etkilidir. Su kütleinin boyutu, tuz içeriği, berraklığı ve akıcılığı, buharlaşma miktarını belirleyen etmenler arasında yer alır. Hava sıcaklığındaki değişimlere derin su kütleinin uyum sağlaması daha uzun sürer. Bu nedenle derin sular yaz aylarında sığ sulara kıyasla daha az buharlaşırken, kış aylarında daha fazla buharlaşma görülür. Tatlı sular, tuzlu sulara göre daha fazla buharlaşır. Bunun nedeni suda çözülmüş tuzların buhar basıncını düşürmesidir. Durağan suyun üstündeki kirlilik ve yabancı maddeler, buharlaşma hızını olumsuz yönde etkileyebilir. Akışkan sularla karşılaştırıldığında, durgun sulardaki buharlaşmanın %7 ile %9 oranında daha yüksek olduğu araştırmalarla tespit edilmiştir.

Ülkemizde, buharlaşma gözlemleri açık su yüzeylerinde gerçekleştirilir. Otomatik gözlem istasyonları, çevresel değişkenleri ölçmek ve izlemek için çeşitli yöntemler kullanırlar. Bu yöntemler, ölçülmek istenen değişkene ve istasyonun amacına bağlı olarak farklılık

gösterebilir. Otomatik gözlem istasyonları, çeşitli çevresel parametreleri sürekli olarak izlemek ve kaydetmek amacıyla tasarlanmış teknolojik sistemlerdir. Bu istasyonlar, atmosferik koşullar, su kalitesi, toprak durumu gibi çeşitli çevresel değişkenleri ölçebilirler. Otomatik gözlem istasyonları, manuel gözlemlere kıyasla daha kesin ve sürekli veri toplama sağlar.

Meteoroloji istasyonlarımızda açık su yüzeyinde buharlaşma miktarı ölçümü için Class A Pan tipi buharlaşma havuzları kullanılmaktadır. (Şekil 1.3) Rasat parklarının yağış, rüzgâr ve güneşin etkilerini alabilen bölgelerine galvaniz sac veya paslanmaz çelik malzemeden imal edilmiş, dairesel şeklindeki buharlaşma havuzları konumlandırılır.



Şekil 1.3. Class A Pan Buharlaşma havuzu

<https://www.mgm.gov.tr/arastirma/buharlasma.aspx?s=3>

Serbest su yüzeyinden buharlaşma miktarını en doğru şekilde tespit etmek için, metal kaplardan oluşan buharlaşma tavaları (evaporimetre) kullanmak en elverişli yöntemdir. 1 metrekarelik bir alan ve 25 santimetrelilik bir derinliğe sahip olan A sınıfı buharlaşma tepsisi, 20 santimetre derinliğinde su ile doldurulur ve su seviyesindeki düşüş, Limmimetre olarak adlandırılan bir suyun yüzey seviyesini ölçmek veya izlemek amacıyla kullanılan bir cihazla ölçülerek buharlaşma miktarı tespit edilir. Göldeki buharlaşma miktarını hesaplamak için, tavanın gösterdiği değer tava katsayısı ile çarpılır. A sınıfı buharlaşma tavaasının yıllık buharlaşma için genellikle kabul edilen katsayısı 0,7'dir, fakat bu katsayının değişim aralığı 0,6 ile 0,8 arasındadır. Buharlaşma miktarını kaydetmek için, Evaporograf adı verilen ölçekler ve yazıcılar da kullanılabilir.

Evapotranspirasyon tahmininin doğru bir şekilde yapılması, su kaynaklarını geliştirmek, kontrol etmek ve yönetmek için son derece kritik bir öneme sahiptir. Buharlaşma nedeniyle atmosfere karışan su haliyle kullanılamamaktadır. Su kaynaklarının gün geçtikçe azaldığı düşünüldüğünde buharlaşmadan kaynaklanan kayıpların da artan bir önemi bulunmaktadır. İleriki yıllarda küresel ısınma ile birlikte artan nüfusu da düşünecek olursak su kaynaklarımızın yetersiz kalması en büyük sorunlarımızdan biri olarak karşımıza çıkmaktadır. Su potansiyelinin ne kadar azalacağını ve mevcut suyun ne kadarını kullanabileceğimizi tahmin etmek, gelecek kuşakların ve tüm yaşam formlarının susuzluk riski gibi korkunç bir senaryoyla karşılaşmaması için planlama açısından önemlidir. Küresel ısınma temelinde mevsim standartları dışındaki hava durumları ile buharlaşma miktarı günden güne artmaktadır. Kurak dönemler için buharlaşma miktarının doğru tahmin edilmesi oldukça önemlidir. Günümüzde tartışılan en önemli konulardan biri de su kaynaklarının günbegün azalması ve gelecekte oluşabilecek su sıkıntısına karşı alınacak tedbirlerdir. Buharlaşma, güvenilir bir formül elde etmeyi zorlaştıran karmaşık ve doğrusal olmayan bir hidrolojik süreç olarak karşımıza çıkar. Bu nedenle, yapay zekâ teknikleri son yıllarda hidrolojik değişkenlerin tahmininde sıkça tercih edilmektedir. Günlük evapotranspirasyon miktarının tahmin edilmesi için bu çalışmada Bulanık SMRGT, ANFİS ve ÇDR yöntemleri kullanılmış ve elde edilen sonuçların performansları birbiriyle karşılaştırılmıştır.

2. ÖNCEKİ ÇALIŞMALAR

Teknolojinin gelişmesi, hayatımızı kolaylaştırmak için kullandığımız imkanları artırmaktadır. Yapay zeka yöntemleri günümüzde hemen her alanda karşımıza çıkarak bize yardımcı olmaktadır. Bu yöntemlerin kullanımı, buharlaşma tahminleri ve gelecek için öngörülerin başarılı bir şekilde gerçekleştirilmesine yardımcı olmaktadır. Yapay zeka teknikleri, geleneksel formüllere dayanan yaklaşımlara kıyasla tahmin yapmayı daha kullanışlı hale getirirken, aynı zamanda daha güvenilir ve başarılı sonuçlar sunmaktadır.

Sudheer ve diğerleri (2002), günlük buharlaşma tahmini için Yapay Sinir Ağı (YSA) modeli kullanılmışlardır. İklim verilerinin analiziyle, buharlaşma miktarını tahmin etmek için etkili bir biçimde YSA modelinin kullanılabileceği gösterilmiştir.

Kumar ve diğerleri (2002), yapay sinir ağları (YSA) yöntemini kullanarak günlük referans bitki evapotranspirasyonunu (ET_0) tahmin etmişlerdir. Yapay sinir ağı sonuçlarını Penman-Monteith yöntemi ile karşılaştırmışlardır.

Kılınç (2004), İstanbul'un su ihtiyacını karşılamak amacıyla planlanan Yeşilçay Sistemi için barajlarının işletme çalışmaları, geleneksel metotlar ve yapay sinir ağlarının kullanımıyla elde edilen sonuçlar arasında karşılaştırma yapmıştır. Yapay sinir ağları yardımıyla, her bir barajın aylık su akışları, aylık toplam buharlaşma ve ay sonu su hacimleri tahmin etmek üzere analizler yürütülmüştür. Ardından, bu tahminlere dayalı yeni işletme stratejileri oluşturulmuş ve bu stratejilerin sonuçları, geleneksel yöntemlerle elde edilen sonuçlarla karşılaştırılmıştır..

Zanetti ve diğerleri (2007), referans evapotranspirasyon (ET_0) tahmini için bir yapay sinir ağını (YSA) test etmişlerdir. Bu YSA test aşamasında elde edilen sonuçlara göre, sadece maksimum ve minimum hava sıcaklıkları dikkate alındığında, Campos dos Goytacazes'te ET_0 'nun tahmin edilmesinin mümkün olduğu sonucuna varılmıştır.

Toprak (2009), açık kanal akış modellemesi için bulanık mantık yöntemini kullanılmıştır. Her biri farklı kesit şekli için iki bulanık model, SMRGT'nin bir uygulaması olarak bu

çalışmada sunulmuştur. Karşılaştırma, çeşitli istatistiklere ve ortalama mutlak bağıl hataya dayanarak yapılmıştır. Ayrıca, kontur haritaları kullanılarak, bulanık modellerin açık kanal akış modellemesinde başarılı olduğu ve SMRGT'nin MF (üyelik işlevi) ve FR (bulanık kural) üretimi için yararlı olduğu gösterilmiştir.

Traore, Wang ve Kerh (2010), Sudano-Sahelian bölgesinde referans buharlaşma miktarını tahmin etmek için yapay sinir ağı yöntemini uygulamışlardır. Bu bölgedeki doğrusal olmayan ve karmaşık referans buharlaşma sürecini başarılı bir şekilde modellemek için rüzgar değişkeninin en etkili olduğu belirlenmiştir.

Shiri, Kisi (2011), kısa vadeli operasyonel su seviyesi tahminleri yapmak amacıyla bulanık mantık (BM) metoduyla çalışmışlardır. Yeraltı suyu derinliği tahmini için genetik programlama (GP) ve uyarlanabilir nöro-bulanık çıkarım sistemi (ANFİS) tekniklerinin yeteneğini araştırmışlardır. GP'nin, problem için açık ifadeler vermede ANFİS'ten daha iyi sonuç verdiği görülmüştür.

Chen D. (2012), destek vektör makinelerini kullanarak günlük referans evapotranspirasyonunu tahmin etmiş ve sonuçları Penman-Monteith denklemi ve yapay sinir ağı modelleriyle karşılaştırmışlardır.

Gocić ve diğerleri (2015), FAO-56 Penman-Monteith denklemini, Sırbistan'da 1980–2010 döneminde toplanan verilere dayalı olarak ET_0 belirlemek için kullanmışlardır. ET_0 'ı tahmin etmek için dört yumuşak hesaplama yöntemi; genetik programlama (GP), destek vektör makine-ateş böceği algoritması (SVM-FFA), yapay sinir ağı (YSA) ve destek vektör makine-dalgacık (SVM-Wavelet) analiz edilmiştir. Bu hesaplama modellerinin güvenilirliği, simülasyon sonuçlarına dayalı olarak ve Pearson korelasyon katsayısı, belirleme katsayısı, kök ortalama kare hatası, mutlak yüzde hatası ve mutlak ortalama hata dahil olmak üzere beş istatistiksel test kullanılarak analiz edilmiştir. SVM-Wavelet'in ET_0 tahmini için en iyi metodoloji olduğu görülmüştür. SVM-Wavelet ve SVM-FFA modellerinin YSA ve GP hesaplama yöntemleriyle karşılaştırıldığında daha yüksek korelasyon katsayısına sahip olduğunu görülmüştür.

Kaya, Üneş, Mamak (2016), evapotranspirasyon tahmini için nöro-bulanık çıkarım mekanizmasını ve Hargreaves-Samani pratik denklemini kullanarak araştırmalarını gerçekleştirmişlerdir. Elde ettikleri sonuçlar, Hargreaves-Samani modeli için hesapladıkları korelasyon katsayısının 0.874 olduğunu göstermiştir. Uyarlanabilir nöro-bulanık çıkarım mekanizması için ise korelasyon katsayısının 0.912 olduğu görülmüştür.

Kaya, Mamak, Üneş (2016), evapotranspirasyonu tahmin etmek için MST yöntemi ve Turc ampirik formülü kullanılmışlardır. Araştırma kapsamında, güneş radyasyonu, hava sıcaklığı, bağıl nem ve rüzgar hızı gibi meteorolojik veriler 1543 günlük periyotta kaydedilmiştir. Yapılan çalışmada, evapotranspirasyon tahmin yöntemlerinin ve ampirik denklemlerin, farklı hidrolojik bölgelere göre değişken çıktılara sahip olabileceği ifade edilmiştir.

Gümüş ve diğerleri (2016), Adana istasyonundaki aylık ortalama buharlaşmayı tahmin etmek için yürüttükleri çalışmada, Gen Ekspresyon Programlama (GEP), Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFİS) ve Yapay Sinir Ağı (YSA) yöntemlerini kullanmışlardır. Elde edilen sonuçları karşılaştırmak amacıyla, her bir yöntemle farklı girdi parametre kombinasyonları oluşturmuşlardır. Kullanılan yöntemlerin karşılaştırılması sonucunda tüm metodların kabul edilebilir derecede başarılı olduğu ifade edilmiştir.

Taşar ve diğerleri (2018), Massachusetts, Amerika Birleşik Devletleri, Cambridge Hazne ve havzasındaki verileri kullanarak, buharlaşma miktarını öngörmek için Yapay sinir ağları (YSA) yaklaşımı uygulanmıştır. YSA sonuçları, geleneksel Hargreaves-Samani, Ritchie ve Turc yöntemleriyle karşılaştırılmıştır. Bu karşılaştırma, yapay sinir ağları modelinin buharlaşma miktarını tahmin etmede geleneksel yöntemlere göre daha üstün performans sergilediğini ortaya koymuştur.

Demirci ve diğerleri (2018), ABD'nin Massachusetts eyaletinde bulunan Stony Brook barajının rezervuar kapasitesi tahmin edilmeye çalışılmışlardır. Veri seti US Geological Survey Institute (USGS) web sitesinden alınmıştır. Rezervuar kapasitesi Adaptif Neuro Fuzzy (NF) ve Multilinear Lineer Regresyon Analizi (MLR) ile tahmin edilmiştir. NF model sonuçları MLR sonuçları ile karşılaştırılmıştır. Karşılaştırma için Ortalama Karesel

Hata (MSE), Ortalama Mutlak Hata (MAE) ve korelasyon katsayısı istatistikleri kullanılmıştır.

Gavili ve diğerleri (2018), ET_0 'ı modellemek için üç farklı yumuşak hesaplama yöntemini ele almışlardır. Yapay sinir ağının (YSA), uyarlanabilir nöro-bulanık çıkarım sisteminin (ANFİS) ve gen ifade programlamanın (GEP) yetenekleri karşılaştırılmıştır. FAO56 Penman–Monteith modeli referans model olarak kabul edilmiştir. Yumuşak bilgi işlem modellerinin, ET_0 modellemesinde ampirik yöntemlerden üstün olduğu; esnek hesaplama yöntemlerinden YSA'nın, ANFİS ve GEP'e göre daha iyi olduğu görülmüştür.

Yihdego, Webb (2018), Avustralya, Burrumbeet Gölü'nün 37 yıllık bir enerji bütçesi analizinden elde edilen sonuçlara dayalı olarak, ölçülen (tava buharlaşması) ve tahmin edilen (Penman) buharlaşma hızındaki farklılığı mevsimsel olarak değerlendirmişlerdir. Meteorolojik verilerin ayrıntılı analizi, buharlaşmanın tamamen radyasyon kaynaklı olduğunu ve rüzgar etkisinin minimum düzeyde olduğunu göstermiştir. Duyarlılık analizi, buharlaşma tahmininin kısa dalga radyasyona ve ardından bağlı neme karşı daha duyarlı olduğunu göstermiştir. Penman kombinasyon yönteminin rüzgar hızına nispeten en az duyarlı olan yöntem olduğu görülmüştür. Mevcut analizle, çeşitli meteorolojik parametreler aracılığıyla göl suyu bütçesi analizinde tahmini buharlaşmaya aylar arası bir mevsimsel ayarlama faktörü uygulayarak, göl yüzeyinden buharlaşma oranını modüle etmede radyasyon, sıcaklık, nem ve rüzgar hızının göreceli rolleri vurgulanmıştır.

Demirci (2019), yağış akış ilişkisini kestirmek için Destek Vektör Makineleri (SVM) ve M5 Karar Ağacı (M5T) yöntemlerini kullanmışlardır. Elde edilen sonuçlar, gerçek ölçüm sonuçlarıyla karşılaştırıldığında M5 Karar Ağacı (M5T) algoritmalarının akış tahmininde üstün bir performansa sahip olduğunu göstermiştir.

Üneş ve diğerleri (2019), günlük su rezervuarı seviyelerini tahmin etmek amacıyla uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFİS), destek vektör makineleri (SVM), radyal tabanlı sinir ağları (RBNN) ve genelleştirilmiş regresyon sinir ağları (GRNN) metotlarını kullanmışlardır. Özellikle, su rezervuarı seviyeleri için bir tahmin modeli olarak ANFİS'in pratik uygulanabilirliği incelenmiştir. Model sonuçları, en iyi girdi kombinasyonları için geleneksel otomatik gerileyen modeller (AR), otomatik gerileyen

hareketli ortalama (ARMA), çoklu lineer regresyon (MLR) modelleri ve yapay zeka modelleri ile kıyaslanmıştır. ANFİS modellerinin su rezervuarı seviye tahmininde klasik ve diğer yapay zeka modellerine göre daha üstün performans sergilediği gözlenmiştir.

Özel, Büyükyıldız (2019), Konya Kapalı Havzası'ndaki Karaman istasyonunun meteorolojik verilerini kullanarak çeşitli giriş kombinasyonları oluşturmuşlar ve aylık buharlaşma miktarı tahmini yapmışlardır. Bunun için Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (DVR) ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) yöntemleri tercih etmişlerdir. Elde edilen sonuçlara göre, DVR yöntemi diğer yöntemlere kıyasla aylık buharlaşma tahmininde daha başarılı sonuçlar vermiştir.

Arslan ve diğerleri (2020), Keban Baraj gölünün günlük su seviyesi tahmini için Çoklu Doğrusal Regresyon ve Bulanık Mantık yöntemlerini kullanarak elde ettikleri sonuçları, gerçek gözlem verileriyle karşılaştırmışlardır. Modellerden elde edilen sonuçlar değerlendirildiğinde, gözlem modellerinin uyumlu sonuçlara sahip olduğu tespit edilmiştir.

Chen Z. ve diğerleri (2020), referans evapotranspirasyonunun tahminini gerçekleştirmek için derin öğrenme yöntemlerini (DL) kullanarak bu yöntemlerin performansını değerlendirmişlerdir. Çin'in Kuzeydoğu ovasında eksik meteorolojik veriler kullanılarak günlük referans evapotranspirasyonunu (ET_0) tahmin etmek için kullanılmıştır. Bunun için derin sinir ağı (DNN), zamansal evrişim sinir ağı (TCN) ve uzun kısa süreli bellek sinir ağı (LSTM) modellerini geliştirmişlerdir. Üç DL modelinin performansı, destek vektör makinesi (SVM) ve rastgele orman (RF) gibi iki klasik makine öğrenimi modeliyle ve Hargreaves (H) ve değiştirilmiş Hargreaves (MH) gibi iki ampirik denklemlerle (sıcaklık temelli) karşılaştırılmıştır. Sonuç olarak, sıcaklık temelli özellikler mevcut olduğunda, TCN ve LSTM modellerinin sıcaklık temelli ampirik modellere göre önemli ölçüde daha iyi performans gösterdiği görülmüştür. Ayrıca, radyasyon veya nem temelli özellikler mevcut olduğunda, tüm önerilen DL ve CML modellerinin eğitildikleri çalışma alanlarının ötesinde radyasyon veya nem temelli ampirik denklemlere göre daha iyi performans sergilediği tespit edilmiştir.

Turhan (2021), farklı YSA yöntemleri kullanarak yağış-akış ilişkisini modellemeyi amaçlamıştır. İleri Beslemeli Geri Yayılımlı Sinir Ağı (FFBPNN) ve Genelleştirilmiş

Regresyon Sinir Ağı (GRNN) yöntemleri benimsenmiş ve elde edilen sonuçlar geleneksel yöntem olarak kabul edilen Çoklu Doğrusal Regresyon (MLR) yöntemi ile karşılaştırılmıştır. Ayrıca optimum YSA modellemesi oluşturmak için modeller üç farklı transfer fonksiyonu kullanılarak gerçekleştirilmiştir. Çalışma sonucunda YSA yöntemlerinin yağış-akış modellemesinde istatistiksel olarak iyi sonuçlar verdiği ve geliştirilen modellerin ortalama aylık akışların tahmininde başarılı bir şekilde uygulanabileceği görülmüştür.

Kaya ve diğerleri (2021), Košice'de (Slovakya) günlük evapotranspirasyon tahmini için yumuşak hesaplama tekniklerinin yeteneklerini araştırmışlardır. Günlük güneş radyasyonu (SR), bağıl nem (RH), hava sıcaklığı (T) ve rüzgar hızı (U) modelleme için kullanılan meteorolojik değişkenlerdir. Verilere dayanarak, çok katmanlı perceptron (MLP), destek vektör regresyonu (SVR), çoklu doğrusal regresyon (MLR) modellerinin farklı kombinasyonları oluşturulmuştur. Model sonuçları birbirleriyle ve Hargreaves-Samani, Ritchie ve Turc ampirik denklemleriyle ortalama kare hata (MSE), ortalama mutlak bağıl hata (MAE) ve belirleme katsayısı (R^2) olmak üzere üç istatistiksel kriter kullanılarak karşılaştırılmıştır. Uygulanan ampirik formüller arasında Hargreaves-Samani denklemi Penman FAO 56 denklemi ile en uyumlu sonuçları vermiştir. Referans kriteri olarak hata yüzdesi histogramları oluşturulmuştur. Model sonuçları MLP modelinin kullanılan diğer yumuşak hesaplama tekniklerinden daha iyi performans gösterdiğini ortaya koymuştur.

Gümüş, Yesiltaş ve Simsek (2021), buharlaşmanın tahmininde farklı girdi kombinasyonlarıyla Yapay Sinir Ağları (YSA), Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFİS) ve Genetik Programlama (GP) yöntemlerini kullanılmışlardır. Bu yöntemlerle elde edilen tahmin değerleri ölçülen değerlerle karşılaştırılmış ve GP yönteminin diğer iki yönteme göre daha iyi performans gösterdiği gözlemlenmiştir.

Güzel ve diğerleri (2023), günlük evapotranspirasyon miktarının tahmini için basit üyelik fonksiyonları ve bulanık kural üretme tekniği (fuzzy-SMRGT), çok değişkenli regresyon (MR), yapay sinir ağları (YSA), adaptif nöro-bulanık çıkarım sistemi (ANFİS) ve destek vektör regresyon (SMOReg) yöntemleri kullanılarak modeller oluşturmuşlardır. Model sonuçları birbirleriyle ve geleneksel regresyon hesaplamalarıyla karşılaştırılmıştır. ET miktarı, referans denklem olarak alınan Penman-Monteith (PM) yöntemi kullanılarak

ampirik olarak hesaplanmıştır. Oluşturulan modellerde günlük hava sıcaklığı (T), rüzgar hızı (WS), güneş radyasyonu (SR), bağıl nem (H) ve evapotranspirasyon (ET) verileri Lewisville Gölü (Texas, ABD) yakınlarındaki istasyondan elde edilmiştir. Model sonuçlarını karşılaştırmak için belirleme katsayısı (R^2), kök ortalama kare hatası (RMSE) ve ortalama yüzde hata (APE) kullanılmıştır. Performans kriterlerine göre en iyi model Q-MR (quadratic-MR), ANFİS ve ANN yöntemleri ile elde edilmiştir. En iyi modellerin R^2 , RMSE, APE değerleri sırasıyla Q-MR için %0,991, 0,213, 18,881; ANFİS için %0,996; 0,103; 4,340 ve YSA için %0,998; 0,075; 3,361'dir. Q-MR, ANFİS ve ANN modelleri MLR, P-MR ve SMOReg modellerinden biraz daha iyi performans göstermiştir.

Demirel ve diğerleri (2023), çalışmalarında Penman Monteith yöntemini referans kabul ederek günlük evapotranspirasyon tahmini yapmışlardır (ET_0). Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (Bulanık SMRGT) ile Adaptif Sinirsel Bulanık Çıkarım sistemi (ANFİS) yöntemleri, günlük evapotranspirasyon miktarının öngörülmesi için kullanılmıştır. Elde edilen sonuçlar, klasik Çoklu Doğrusal Regresyon (ÇDR) yönteminin sonuçlarıyla kıyaslanmıştır. Her iki modelin de kararlı sonuçlar sunduğu, referans evapotranspirasyon değerleriyle karşılaştırılarak belirlenmiştir.

Di Nunno ve Granata (2023), Sicilya'daki ET_0 referans evapotranspirasyonu ilk olarak geçmiş ve gelecek iklim parametreleri temelinde değerlendirilmiş ve gelecek değerler için farklı Temsili Konsantrasyon Yolları ile karakterize edilen iki iklim senaryosuna atıfta bulunulmuştur: RCP 4.5 ve RCP 8.5. Ardından, Sicilya'yı her biri belirli ET_0 özellikleriyle karakterize edilen üç homojen bölgeye ayırmak için Hiyerarşik algoritma kullanılmıştır. Buna ek olarak, sadece geçmiş verilere dayalı tahmin modelleri geliştirmek için bazı Makine Öğrenimi (ML) algoritmaları kullanılmıştır. T_{min} ve T_{max}'ın gelecekteki değerlerini tahmin etmek için Destek Vektör Regresyonu (SVR) kullanılırken, ET_0 tahmini için Çok Katmanlı Algılayıcı (MLP) ve M5P Regresyon Ağacına dayalı bir topluluk modeli geliştirilmiştir. MLP-M5P topluluk modeli ile yapılan tahminler, RCP 4.5 ve RCP 8.5 gelecek iklim senaryoları için hesaplanan ET_0 ile karşılaştırılmıştır. Tahmin dönemi boyunca, 2001'den 2091'e kadar, her üç küme için de evapotranspirasyon artışları gözlenmiştir. Kıyı boyunca uzanan C1 kümesi için RCP 4.5 ve RCP 8.5 senaryoları için %7.52, %14.64 ve %10.78'lik artışlar hesaplanmıştır.

Amani & Shafizadeh-Moghadam (2023), uydu görüntüleri, ML modelleri kullanılarak ET tahmini için etkili değişkenler sağlamıştır. Bununla birlikte, giderek artan sayıda ML modeli ve yeni ortaya çıkan uydu görüntüleri, araştırmacıların önünde geniş ve karmaşık bir potansiyel açmıştır. Önceki çalışmalar ET tahmini için fiziksel tabanlı yöntemleri gözden geçirmiş olsa da, bu makale ET tahmini ve gelecekteki görünüm için RS ve ML modelleri tarafından sağlanan ilerleme, zorluklar ve fırsatların son on yıllık bir incelemesini sunmaktadır. Uzaktan algılama görüntüleri ve makine öğrenimi (ML) modellerinin birleştirilmesi, bir dizi varsayımı gevşeten ve geleneksel yaklaşımlardan daha az veri gerektiren ET'yi tahmin etmek için önemli bir kapasite sağlamıştır.

Mostafa ve diğerleri (2023), yeni metasezgisel algoritmalar, kuantum tabanlı kuş navigasyon optimizasyon algoritması (QANA) ve yapay sinek kuşu algoritması (AHA) ile geliştirilmiş iki makine öğrenimi yöntemi olan rastgele vektör fonksiyonel bağlantı (RVFL) ve uygunluk vektör makinesinin (RVM), sınırlı iklim verileri, minimum sıcaklık, maksimum sıcaklık ve dünya dışı radyasyon kullanılarak ET₀'ın modellenmesindeki etkinliği araştırılmıştır. Hibrit RVFL-AHA, RVFL-QANA, RVM-AHA ve RVM-QANA modellerinin sonuçları tekli RVFL ve RVM modelleri ile karşılaştırılmıştır. Çeşitli girdi kombinasyonları ve üç veri bölme senaryosu kullanılmıştır. Sonuçlar, AHA ve QANA'nın ET₀'ın modellenmesinde RVFL ve RVM yöntemlerinin verimliliğini önemli ölçüde artırdığını ortaya koymuştur. Periyodiklik bileşeninin ve dünya dışı radyasyonun girdi olarak dikkate alınması, uygulanan yöntemlerin tahmin doğruluğunu artırmıştır.

Yıldırım ve diğerleri (2023), Türkiye'deki günlük ET₀'ı tahmin etmek için k-en yakın komşu algoritması, çok genli genetik programlama ve destek vektör regresyonu (SVR) dahil olmak üzere üç makine öğrenimi tekniğinin uygulanabilirliğini ve etkinliğini araştırılmışlardır. Ayrıca, Türkiye için en uygun ET₀ haritalarını geliştirmek amacıyla sıradan kriging (OK), ko-kriging, ters mesafe ağırlıklı ve radyal tabanlı fonksiyon dahil olmak üzere farklı enterpolasyon teknikleri karşılaştırılmıştır. Geliştirilen tüm modeller, belirleme katsayısı (R^2), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) gibi performans indekslerine göre değerlendirilmiştir. Taylor, keman ve dağılım grafikleri de oluşturulmuştur. Uygulanan ML modelleri arasında SVR modeli, $R^2 = 0,961$, RMSE = 0,327 mm ve MAE = 0,232 mm performans indeksleri ile ET₀'ın belirlenmesinde en iyi sonuçları vermiştir. SVR modelinin girdi değişkenleri güneş radyasyonu, sıcaklık ve bağıl

nem olarak seçilmiştir. Benzer şekilde, ET_0 'ın mekansal dağılım haritaları, en iyi tahminleri sağlayan OK enterpolasyon yöntemi ile üretilmiştir.

Bayram ve Çıtakoğlu (2023), uzun vadeli aylık referans evapotranspirasyon (ET_0) tahmini için çok genli genetik programlama (MGGP), M5 model ağaçları (M5Tree) ve K-en yakın komşu algoritması (KNN) olmak üzere üç farklı makine öğrenimi (ML) tabanlı yaklaşımın tahmin gücü araştırmışlardır. Girdi verileri, Türkiye'deki 163 meteoroloji istasyonundan elde edilen aylık güneş radyasyonu (Rs), maksimum hava sıcaklığı (Tmax) ve rüzgar hızından (Ws) oluşmaktadır. Farklı girdi kombinasyonları oluşturulmuş ve analiz edilmiştir. Modelin performansı Nash-Sutcliffe etkinliği, Kling-Gupta etkinliği, bağıl kök ortalama karesel hata, ortalama mutlak yüzde hata ve belirleme katsayısı gibi kriterler kullanılarak değerlendirilmiştir. Ayrıca Taylor, radar ve boxplot diyagramları oluşturulmuştur. MGGP modelinin hem M5Tree hem de KNN modellerinden daha iyi performans gösterdiği belirlenmiştir. En iyi performans gösteren Rs-Tmax-Ws kombinasyonu için MGGP modelinden elde edilen denklem sunulmuştur. En iyi hava koşulları Rs, Tmax ve Ws için sırasıyla 0,029 ila 31,814 MJ/m², - 5,8 ila 45,7 °C ve 0,140 ila 5,086 m/s olarak elde edilmiştir. Ayrıca, Rs'nin ET_0 tahmini için en güçlü girdi değişkeni olduğu, Ws'nin ise en zayıf olduğu bulunmuştur.

Hofmann ve diğerleri (2023), 1960 ve 2021 yılları arasında Brezilya Cerrado'sundaki yağış eğilimlerini ve yağışlı günlerin sıklığını, bölgedeki mevsimsel modellere göre dört farklı dönemde analiz etmişlerdir. Ayrıca, tespit edilen eğilimlerin olası nedenlerini aydınlatmak için Cerrado üzerindeki evapotranspirasyon, atmosferik basınç, rüzgarlar ve atmosferik nemdeki eğilimleri de değerlendirmişlerdir. Kuzey ve orta Cerrado bölgelerinde kurak mevsimin başlangıcı hariç tüm dönemlerde yağışlarda ve yağışlı günlerin sıklığında önemli bir azalma kaydedilmiştir. En belirgin olumsuz eğilimler, toplam yağış miktarında ve yağışlı gün sayısında %50'ye varan azalmaların kaydedildiği kurak mevsim ve yağışlı mevsimin başlangıcında kaydedilmiştir. Bu bulgular, atmosferik sirkülasyonu değiştiren ve bölgesel çöküşü artıran Güney Atlantik Subtropikal Antisiklonunun yoğunlaşmasıyla ilişkilendirilmektedir. Ayrıca, kurak mevsim ve yağışlı mevsimin başlangıcında, bölgesel evapotranspirasyonda bir azalma olmuş ve bu da potansiyel olarak yağış azalmasına katkıda bulunmuştur. Sonuç olarak bölgede kurak mevsimin genişlediğini ve

yoğunlaştığını ve potansiyel olarak Cerrado sınırlarını aşan geniş çevresel ve sosyal etkiler getirdiğini göstermiştir.

Hou ve diğerleri (2023), vektör otoregresyon (VAR) modelini kullanarak referans evapotranspirasyonu tahmin etmek ve meteorolojik değişkenlerin referans evapotranspirasyon ile nedensel ilişkisini istatistiksel bir yaklaşım kullanarak araştırmışlardır. Penang, Malezya'dan elde edilen 20 yıllık, 1 yıllık ve 2 aylık araştırma iklim veri setleri %80 eğitim verisi ve %20 doğrulama verisi olarak ayrılmıştır. İlk VAR modelini eğitmek için halka açık hava durumu verileri kullanılmıştır. DHT11 sıcaklık sensörüne bağlı bir Raspberry Pi IoT cihazı, belirlenen deneysel ürün sahasına yerleştirilmiştir. Yerinde veri toplama, ortam sıcaklığını ve nemi ölçmek için DHT11 sıcaklık sensörleri kullanılarak yapılmıştır. Toplanan sıcaklık ve nem verileri, referans evapotranspirasyon tahminini hesaplamak için vektör otoregresyon (VAR) modeli ile birlikte kullanılmıştır. Sonuçlar, 20 yıllık veri setinin, sırasıyla 1.1663 ve -0.0048'lik kök ortalama kare hatası (RMSE) ve korelasyon katsayısı (CORR) kullanılarak elde edilen genel referans evapotranspirasyonun tahmininde daha iyi performans ve tutarlı sonuçlar gösterdiğini ortaya koymuştur. Bir yıllık veri seti modelinde ise RMSE ve CORR sırasıyla 1.571 ve -0.3932 olarak kaydedilmiştir.

Bai, Peng (2023), yaygın olarak kullanılan üç uzaktan algılama ET modeli ele almıştır. Hava bağıl nem tabanlı iki kaynaklı (ARTS) model, Priestley-Taylor Jet Propulsion Laboratory (PT-JPL) modeli ve Penman-Monteith-Leuning (PML) modeli. Bu üç model, 12 girdap-kovaryans (EC) kulesinden alınan ölçümler ve 286 havzadan alınan su dengesi temelli ET tahminleri temelinde değerlendirilmiştir. Değerlendirme sonuçları PML modelinin hem saha hem de havza ölçeğinde en iyi performansı gösterdiğini ortaya koymaktadır. PML modelinin avantajı (i) arazi örtüsüne dayalı parametre yapılandırması ve (ii) toprak buharlaşması ve terlemesinin toprak su açığına verdiği tepkilerdeki farklılıkların dikkate alınmasından kaynaklandığı öngörülmektedir. Ayrıca, ET'nin, yani durdurma kaybı (E_i), toprak buharlaşması (E_s) ve terlemenin (E_t) mekansal-zamansal değişimini ve bileşen bölümlenmesini simüle etmede modeller arasındaki tutarlılık ve farklılıkları da araştırmışlardır. Üç model, ülke çapında çok yıllık ortalama ET (416,3-438,2 mm/yıl) ve bunun mekansal modelini tahmin etmede yüksek tutarlılık gösterirken ET eğilimlerinde (0,10-0,98 mm/yıl²) büyük farklılıklar göstermiştir.

Bjarke, Barsugli ve Livneh (2023), Penman-Monteith tarafından türetilen ET_0 , bunun advektif ve radyasyon bileşenleri, Priestley-Taylor tarafından türetilen ETP ve buhar basıncı açığının 16 CMIP6 projeksiyonu ve dört emisyon senaryosundan elde edilen küresel aylık tahminlerinin yayınlanmış bir veri setinin geliştirilmesi ve doğrulanması açıklanmıştır. CMIP6 buharlaşma talebi topluluğunun tarihsel doğrulaması, İklim Araştırma Birimi (CRU) ve ERA5-Land reanaliz ürünlerinden gözlemsel olarak türetilen ET_0 ve ETP taban çizgileriyle genel bir uyum göstermiştir; GCM sapmaları, esas olarak modellenen nem ve ET_0 'a advektif katkılardaki bölgesel farklılıklardan kaynaklandığı ve genel olarak, buharlaşma talebinin tüm emisyon senaryolarında, kutup bölgelerinde en büyük artışlarla ve özellikle ET_0 'ın daha yüksek olduğu bölgeler için adveksiyondan daha büyük bir katkı ile artması öngörülmüştür.

Rajput, ve arkadaşları (2023), yapay sinir ağı (YSA) ve k-en yakın komşu (KNN) modelleri gibi yumuşak hesaplama araçları, Hindistan Tarımsal Araştırma Enstitüsü (IARI) çiftlik gözlemevi, Yeni Delhi, Hindistan'ın 1990-2020 yılları arasındaki iklim verileri kullanılarak Penman-Monteith modeli (PM) ile performansları karşılaştırılarak günlük ET_0 tahmini için değerlendirilmiştir. Bu modellerin performansı, ortalama mutlak hata (MAE), ortalama karesel hata (MSE), korelasyon katsayısı (r), ortalama mutlak yüzde hata (MAPE) ve uyum indeksi (d) gibi istatistiksel performans indeksleri kullanılarak değerlendirilmiştir. Sonuçlar, sigmoid aktivasyon fonksiyonuna ve L-BFGS (Sınırlı bellek-Broyden-Fletcher-Goldfarb-Shanno) öğrenme algoritmasına sahip YSA modelinin 36 YSA modeli arasında en iyi performans gösteren model olarak seçildiğini ortaya koymuştur. Geliştirilen ve test edilen 4 KNN modeli arasında, K4 KNN modelinin günlük ET_0 tahmininde en iyisi olduğu görülmüştür. Genel olarak, en iyi YSA modeli (M11), eğitim ve test dönemlerinde sırasıyla 0.075, 0.018, 0.997, %2.76 ve 0.974 MAE, MSE, r, MAPE ve d değerleri ve sırasıyla 0.091, 0.053, 0.984, %3.16 ve 0.969 ile K4 KNN modelinden daha iyi performans göstermiştir. Böylece, YSA tekniğinin günlük ET_0 tahmininde KNN tekniğinden daha iyi performans gösterdiği sonucuna varılmıştır. En iyi YSA modelinin duyarlılık analizi, rüzgar hızının en etkili girdi değişkeni olduğunu ortaya koymuştur.

Shang ve arkadaşları (2023) Dünyanın Üçüncü Kutbu olan Tibet Platosu (TP) için daha doğru ve sürece dayalı uydu evapotranspirasyon (ET) tahmini için yüzey iletkenliğine

dayalı bir ML modeli (ML-Gs) ve toprak buharlaşmasına dayalı bir ML modeli (ML-Es) olmak üzere iki hibrit model geliştirmişlerdir. Bu hibrit modeller, parametrelerden veya bileşenlerden birinin ML kullanılarak modellendiği biyofiziksel bir çerçeveye sahiptir. Hibrit modeller, iyi fiziksel mekanizma ve yüksek model performansı arasında optimum bir bağlantı bulmak için ML'yi süreç tabanlı ET çerçevesini tamamlayıcı hale getirir. Günlük ET tahminleri, 28 girdap kovaryans akı kulesi sahasında ve iki süreç tabanlı ET algoritması (Penman-Monteith tabanlı ET-PM algoritması ve Priestley-Taylor tabanlı ET-PT algoritması) ve veri odaklı saf ML yöntemi ile karşılaştırılarak değerlendirilmiştir. Hibrit modeller, iki fiziksel algoritmanın kök-ortalama-kare-hatasını (RMSE) (ET-PM için 1,11 mm/gün, ET-PT için 1,09 mm/gün) 0,50 mm/gün'e düşürmüş ve Kling-Gupta verimliliğini (KGE) (ET-PM için 0,35, ET-PT için 0,36) 0,92'ye yükseltmiştir. Hibrit modellerin ayrıca veri açısından seyrek bölgelerde ve aşırı hava olaylarına verilen yanıtlarda saf ML'ye (KGE 0,62) göre daha iyi performans (KGE 0,65) göstermiştir. Bu da yaklaşımlarının sadece ET simülasyon doğruluğunu artırmakla kalmayıp aynı zamanda ML tabanlı ET tahmininin fiziksel anlayışını da geliştirdiğini göstermiştir. ML-Es TP üzerindeki ET bileşenlerine odaklanır ve ML-Gs'den daha iyi tanımlanmıştır. Verilerin seyrek olduğu bölgeler ve uç durumlar için, daha sağlam fiziksel mekanizma birleştirildiğinde, hibrit modelin daha iyi genelleme performansı elde etmiştir. Hibrit modellerinin dayanan mekansal-zamansal ET modelleri, yerel iklim bölgelerindeki varyasyonlarla tutarlı olduğu, küresel ve bölgesel iklim değişiklikleri altında hidrolojik süreçlerin anlaşılması konusunda kritik bilgiler sağlayabileceğini belirtmişlerdir.

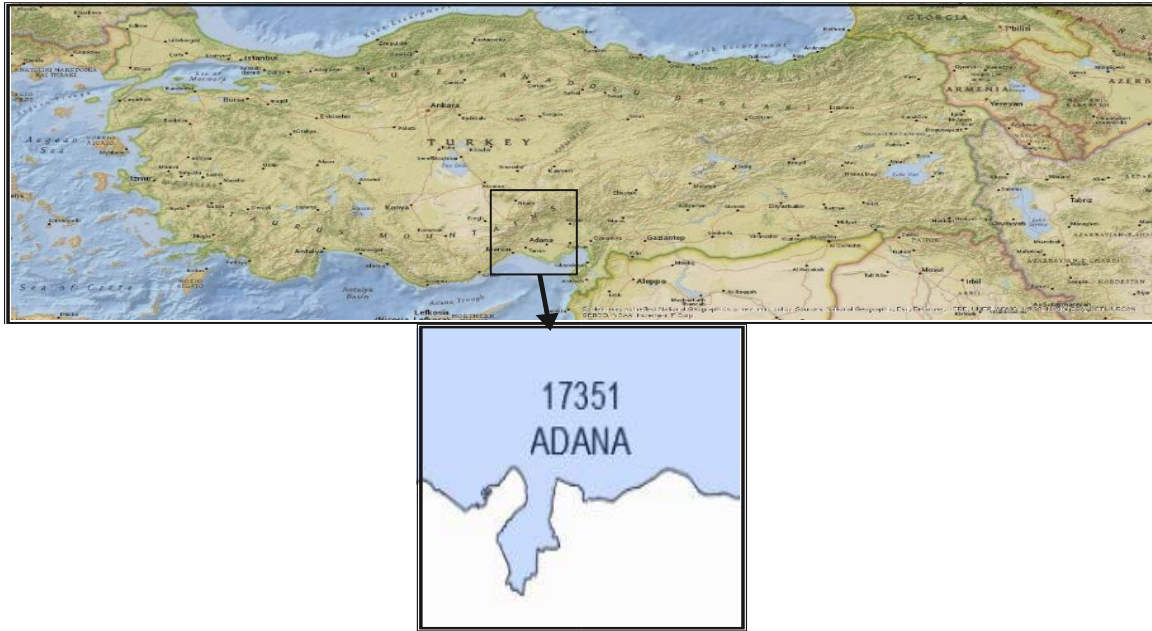
Bu çalışmada evapotranspirasyon tahmini için Penman Monteith yöntemi referans olarak kabul edilmiştir. (ET_0) Günlük evapotranspirasyon miktarı Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (Bulanık SMRGT) ile Adaptif Sinirsel Bulanık Çıkarım sistemi (ANFİS) yöntemleri kullanılarak tahmin edilmiştir. Elde edilen sonuçlar klasik Çoklu Doğrusal Regresyon (ÇDR) yöntem sonuçları ile karşılaştırılmıştır. Referans evapotranspirasyon değerleri ile karşılaştırılan modellerin iyi performans verdiği görülmüştür.

3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı

Bu çalışmadaki veriler Meteoroloji Genel Müdürlüğü (MGM) tarafından işletilmekte olan 17351 numaralı Adana Bölge istasyonundan elde edilmiştir. İstasyon Adana ilinin Yüreğir ilçesinde, "35,34°K, 37,00°D" üzerinde, deniz seviyesinden 23 metre yükseklikte yer almaktadır. Çalışma alanı aşağıda gösterilmiştir. (Şekil 3.1) Veriler 2015-2021 yılları arasındaki günlük ortalama sıcaklık (TM), bağıl nem (RH), rüzgâr hızı (U) ve solar radyasyon (SR) değerlerini kapsamaktadır. Bu veriler farklı kombinasyonlar ile girdi parametresi olarak kullanılmak için düzenlenmiştir. Bu parametreler farklı yöntemlerle günlük evapotranspirasyon tahmini için kullanılmıştır.

Akdeniz iklimi özelliklerini taşıyan Adana'da, kış mevsimleri ılıman ve yağışlı, yaz ayları ise sıcak ve kurak geçer. Adana bölgesi, tarım için elverişli, geniş ve düz arazi yapısına sahip bulunmaktadır. Bu nedenle, bu bölgede buharlaşma süreci son derece kritik bir öneme sahiptir. Buharlaşma, su kaynaklarının yönetim ve planlaması için rehber niteliği taşıdığı gibi, aynı zamanda su kaynaklarının serbest su seviyesinin kontrol edilmesi, belirlenmesi ve işletilmesi açısından da hayati bir role sahiptir.



Şekil 3.1. Çalışma Alanı

Adana bölgesinde buharlaşma tahmini yapılması, su kaynaklarının yönetimi, tarımsal sulama planlaması, hidroelektrik enerji üretimi, su rezervlerinin kontrolü ve doğal ekosistemlerin korunması gibi birçok önemli alanda büyük önem taşır.

Bölgedeki buharlaşma oranının tahmin edilmesi, su rezervlerinin daha etkili bir şekilde yönetilmesine yardımcı olur. Bu tahminler, su havzalarındaki su seviyelerinin ne kadarının buharlaşma yoluyla kaybedileceğini anlamamıza yardımcı olur ve suyun daha verimli kullanılmasını sağlar.

Adana, verimli tarım arazilerine sahip bir bölgedir ve tarıma dayalı ekonomisi büyük ölçüde sulama suyuna dayanır. Tarım faaliyetlerinde kullanılan su, pamuk, narenciye, mısır, buğday gibi birçok ürünün yetiştirilmesi için gereklidir. Tarım, Adana bölgesinde ekonominin önemli bir parçasını oluşturur. Buharlaşma tahminleri, çiftçilere sulama planlaması yaparken ne kadar su kullanmaları gerektiği konusunda rehberlik eder. Bu, sulama suyunun tasarruflu kullanılmasını ve tarımsal üretimde verimliliği artırır.

Adana ilinde Seyhan Barajı ve Ceyhan Nehri üzerindeki hidroelektrik santraller, Adana'nın elektrik enerjisi üretiminde önemli bir rol oynar. Buharlaşma tahminleri bölgedeki hidroelektrik santrallerinin, barajların su seviyelerinin kontrolünü ve elektrik üretim planlamasını etkiler. Bu sayede, su potansiyeli daha iyi yönetilir ve enerji üretimi verimli bir şekilde gerçekleştirilir.


Adana bölgesi, Akdeniz ikliminin etkileri altındadır ve doğal olarak zengin bitki ve hayvan çeşitliliğine sahiptir. Bu ekosistemlerin korunması, su kaynaklarının sürdürülebilir yönetimiyle yakından ilişkilidir. Buharlaşma, bitki örtüsüne ve sucul ekosistemlere doğrudan etki eder. Bu nedenle, buharlaşma tahminleri, bölgedeki doğal ekosistemlerin korunmasına ve yönetilmesine katkıda bulunur.

Adana'nın doğal güzellikleri, su kenarları, gölleri ve barajları turistler ve yerel halk için popüler rekreasyon alanlarıdır. Bu alanlarda suyun kalitesi ve miktarı, turizm sektörünün ve halkın dinlenme ve eğlence ihtiyaçlarını karşılamak için önemlidir.


Buharlaşma tahminleri, bölgede olası kuraklık veya su kıtlığı durumlarında erken uyarı sistemi olarak kullanılabilir. Bu sayede, su kaynaklarının azaldığı durumlarda, toplum ve yetkililer önlem alarak suyun etkin ve adil bir şekilde yönetilmesine yardımcı olabilir. Sonuç olarak, buharlaşma tahmini, su kaynaklarının sürdürülebilir yönetimi ve Adana bölgesinin ekonomik ve ekolojik açıdan gelişimi için kritik bir rol oynamaktadır. Bu tahminler, suyun verimli bir şekilde kullanılmasını ve gelecek nesillerin de su kaynaklarından faydalanabilmesini sağlar.

Bu çalışma kapsamında, Meteoroloji Genel Müdürlüğü (MGM) tarafından işletilmekte olan 17351 numaralı Adana istasyonundan elde edilen hava sıcaklığı (TM), solar radyasyon (SR), rüzgâr hızı (U) ve bağıl nem (RH) verileri kullanılarak günlük buharlaşma


miktarı tahmin edilmiştir. Şekil 3.2'de günlük maksimum hava sıcaklığı ($^{\circ}\text{C}$) değişimleri, Şekil 3.3'te günlük minimum hava sıcaklığı ($^{\circ}\text{C}$) değişimleri, Şekil 3.4'te günlük ortalama hava sıcaklığı ($^{\circ}\text{C}$) değişimleri, Şekil 3.5'te günlük ortalama rüzgar hızı (m/s) değişimleri, Şekil 3.6'da günlük solar radyasyon (Mj/m^2) değişimleri, Şekil 3.7'de günlük nisbi nem (%) değişimleri ve Şekil 3.8'de Penman Monteith yöntemi referans kabul edilerek hesaplanmış günlük buharlaşma miktarı (mm) değişimleri gösterilmektedir.




Şekil 3.2. Çalışılan istasyonda 2015-2021 yılları arasındaki maksimum hava sıcaklığı ($^{\circ}\text{C}$) değerlerinin günlük değişimi



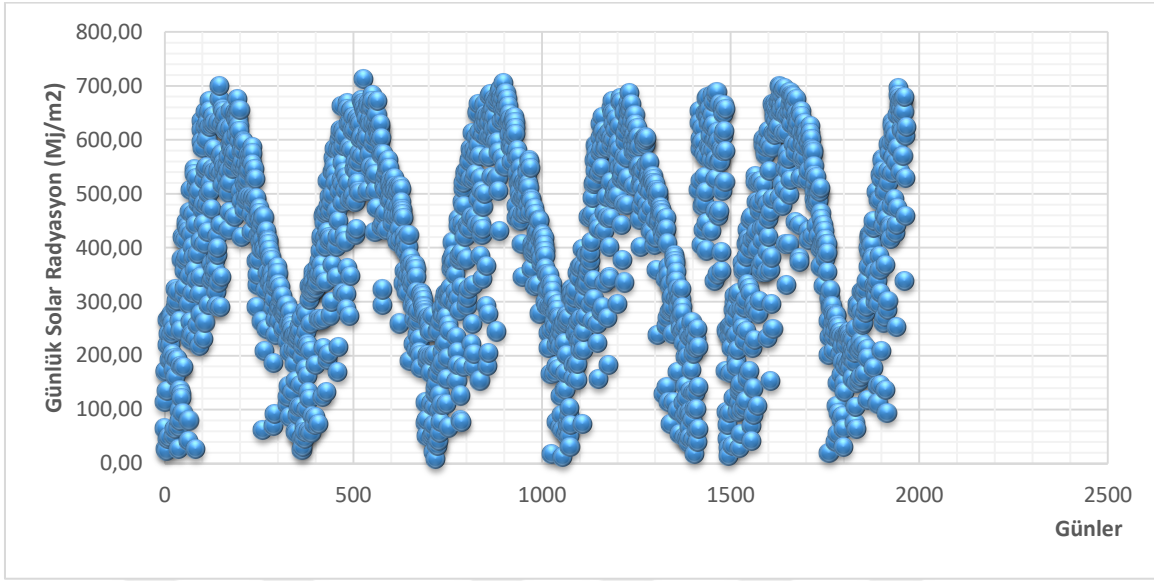
Şekil 3.3. Çalışılan istasyonda 2015-2021 yılları arasındaki minimum hava sıcaklığı ($^{\circ}\text{C}$) değerlerinin günlük değişimi




Şekil 3.4. Çalışılan istasyonda 2015-2021 yılları arasındaki ortalama hava sıcaklığı (°C) değerlerinin günlük değişimi



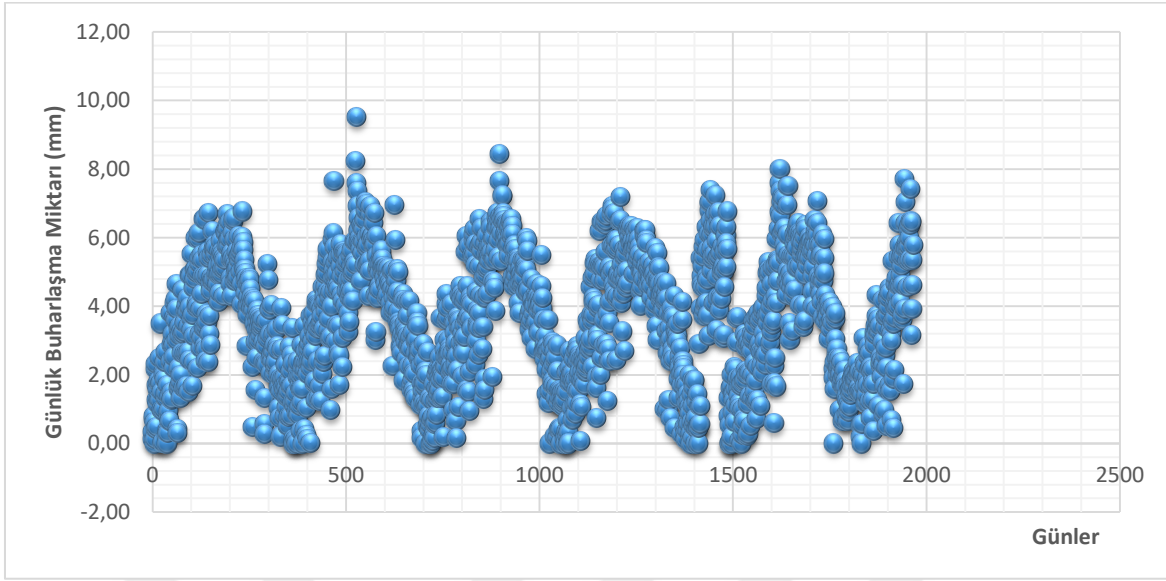
Şekil 3.5. Çalışılan istasyonda 2015-2021 yılları arasındaki ortalama rüzgar hızı (m/s) değerlerinin günlük değişimi



Şekil 3.6. Çalışılan istasyonda 2015-2021 yılları arasındaki solar radyasyon (Mj/m^2) değerlerinin günlük değişimi



Şekil 3.7. Çalışılan istasyonda 2015-2021 yılları arasındaki nisbi nem (%) değerlerinin günlük değişimi



Şekil 3.8. Çalışılan istasyonda 2015-2021 yılları arasındaki referans buharlaşma miktarı (mm) değerlerinin günlük değişimi

3.2. Kullanılan Modeller

Bu çalışmada günlük evapotranspirasyon tahmini için kullanılacak veriler Meteoroloji Genel Müdürlüğü (MGM) tarafından işletilmekte olan 17351 numaralı Adana Bölge istasyonundan elde edilmiştir. Veriler 2015-2021 yılları arasındaki günlük ortalama sıcaklık (TM), bağıl nem (RH), rüzgâr hızı (U) ve solar radyasyon (SR) değerlerini kapsamaktadır. Farklı girdi parametreleri ile günlük buharlaşma miktarını tahmin etmek için Bulanık SMRGT, ANFİS ve ÇDR yöntemleri uygulanmış ve elde edilen sonuçlar kıyaslanmıştır.

3.2.1. FAO Penman-Monteith (PM) yöntemi

FAO Penman-Monteith yöntemi, bitki su gereksinimlerini ve sulama ihtiyacını tahmin etmek için kullanılmaktadır. Tarım alanlarında su yönetimi ve sulama planlaması için yaygın olarak kullanılan bir modeldir. İki önemli bilim insanı olan Penman ve Monteith'in çalışmalarından türetilmiştir. Bu yöntem, referans bitki potansiyelini belirlemek için klimatolojik verilere dayanır. Klimatolojik veriler, ortalama günlük sıcaklık, rüzgar hızı, nispi nem, güneşlenme süresi gibi parametreleri içerir. FAO Penman-Monteith yöntemi, potansiyel bitki transpirasyonunu (ET_0) hesaplamak için kullanılır. ET_0 , bir bitkinin belirli bir alan üzerindeki ideal koşullar altında su tüketim miktarını ifade eder. Güneş radyasyonu, bitkilerin su kaybetme hızını etkiler ve güneşlenme süresi ile alakalıdır.

Yüksek sıcaklık, bitkilerin daha fazla su buharı kaybetmesine neden olur. Nispi nem, atmosferdeki su buharı içeriğini belirler ve bitkinin su kaybını etkiler. Yüksek rüzgar hızı, bitkilerin su kaybını artırır. FAO Penman-Monteith yöntemi, su kaynağı yönetimi, sulama planlaması, tarımsal üretim tahmini ve su tasarrufu projelerinde önemli bir araçtır. Ancak, veri gereksinimleri ve hesaplama karmaşıklığı nedeniyle uygulaması bazı durumlarda zorlu olabilir. Bu nedenle, bazı durumlarda basitleştirilmiş yaklaşımlar kullanılabilir. Penman (1948), evapotranspirasyonun öngörülmesi konusunda aerodinamik yaklaşımların yetersiz olduğunu vurgulayarak, deneysel yöntemlerin kullanılmasıyla daha güvenilir sonuçlar elde edilebileceğini ifade etmektedir. Penman, serbest su yüzeyinden meydana gelen buharlaşmanın tahmin edilmesi için bir lineer ampirik denklem geliştirmiştir. Jensen, Burman ve Allen (1990) tarafından önerilen ve kullanılmaya başlanan bu denklem "Penman'ın Lineer Eşitliği" olarak adlandırılmıştır (Aydın, 2019). Bu sayede, FAO (Food and Agriculture Organization) tarafından standart metod olarak önerilen PM yöntemi kullanımı, referans evapotranspirasyon ET_0 endeksinin oluşturulmasında yaygınlaşmıştır.

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T+273} U_2 (e_w - e_a)}{\Delta + \gamma(1+0,34U_2)} \quad (3.1)$$

Bu ifadelerde;

ET_0 : referans evapotranspirasyonu [mm gün^{-1}]

Δ : buhar basıncı eğrisinin eğimini [$\text{kPa } ^\circ\text{C}^{-1}$]

R_n : net radyasyonu [$\text{MJ m}^{-2}\text{gün}^{-1}$]

G : toprak ısı akışı yoğunluğunu ($\text{MJ m}^{-2}\text{gün}^{-1}$)

γ : fizikometrik sabiti [$\text{kPa } ^\circ\text{C}^{-1}$]

T : 2m yükseklikteki hava sıcaklığını [$^\circ\text{C}$]

U_2 : 2m yükseklikteki rüzgar hızını [m/s]

e_w : doymuş buhar basıncını [kPa]

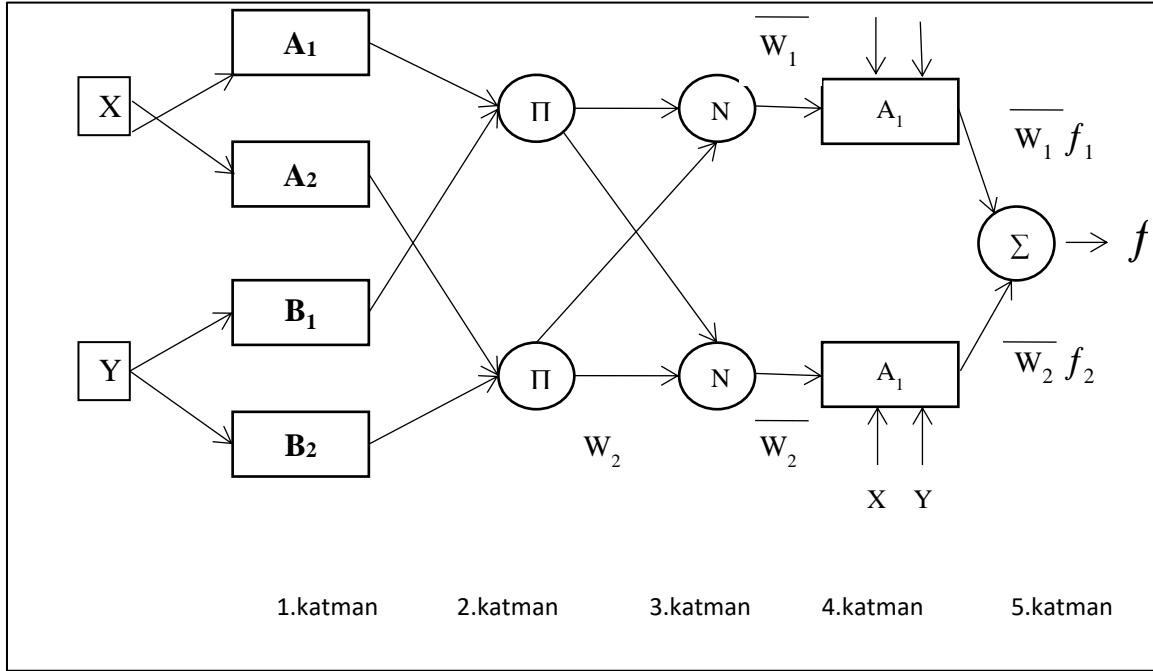
e_a : gerçek buhar basıncını [kPa] temsil etmektedir.

3.2.2. Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFİS)

ANFİS, yapay zeka alanında kullanılan bir bulanık mantık modelidir. ANFİS, bulanık mantık ve yapay sinir ağlarının birleşimini temsil eder. Bu sistem, veri tabanlı çıkarım yapabilme yeteneğine sahip olup, hem bulanık mantık hem de yapay sinir ağlarından en iyi yönleri kullanarak modelleme ve tahmin yapma amacıyla geliştirilmiştir. Jang (1993) tarafından geliştirilmiş olup, hibrit öğrenme algoritması kullanmaktadır. ANFİS, verilerden öğrenme yoluyla kendini uyarlayabilen bir sistemdir. Bu modelin gelişmesine olanak tanıyan faktörler, mevcut sistemlerdeki eksik bilgi girişi ve anlaşılmasındaki güçlüklerdir.

Bulanık kurallar katmanında girdi verileri bulanık kümelerle eşlenir ve bulanık kurallar oluşturulur. Örneğin, "Eğer X büyükse ve Y küçükse, o zaman Z orta" gibi bulanık kurallar tanımlanabilir. Belirleme katmanında, bulanık kuralların ağırlıkları ayarlanır. Bu ağırlıklar, eğitim süreci boyunca uygun verilerle ayarlanır. Son olarak yapay sinir ağı katmanında çıktılar hesaplanır. Bulanık çıkarımlar yapılır. Doğru sonuçlar elde etmek için, önermeler 'Eğer' ve 'İse' biçiminde oluşturulur. Bu bağlamda, sinir ağları verilerden öğrenirken, öğrenilen bilgiyi anlamak zor olabilir. Bunun yerine, bulanık mantık, sistem bilgisini insanların anlayabileceği sözel ifadelerle açıklar. Bu nitelik, sistem ile insan arasında kapalı bir etkileşimin sağlanmasına imkan tanır öyle ki bulanık sistemler, kelimelerle ifade edilen terimler ve eğer-ise kaidelerini kullanarak basitçe anlaşılabilir hale gelir. Ancak, öğrenme algoritmaları içermezler. ANFİS, girdi ve çıktı arasındaki karmaşık ilişkileri modellemek için karmaşık sistemlerde tahmin ve çıkarımlar yapar. Klasik kontrol sistemlerinin matematiksel modellerine ihtiyaç duyan yapılarına karşın, bulanık denetim sistemlerinde sadece hedeflenen çıkışa uygun girdiler ayarlandığından, bulanık denetim uzman bir insanın sistem üzerinde kontrol sağlamasına benzeyen bir şekilde işler.

Kullanılan parametreleri optimize etmek ANFİS modelinin temel amacını oluşturur. Bu yöntem, Takagi-Sugeno-Kang bulanık çıkarım sistemi temeline dayanmaktadır (Doğan, 2016). ANFİS yapısı, Şekil 3.9'da gösterildiği gibi Jang (1993) tarafından tasarlanmıştır.



Şekil 3.9. ANFİS yapısı

Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFİS), giriş verileri ile çıktı arasındaki ilişkileri belirlemek için bulanık mantık kavramlarını kullanırken, yapay sinir ağları sayesinde öğrenme yeteneği kazanır. ANFİS, veri setlerini analiz eder, bu verilere dayalı olarak bulanık kümeleri oluşturur ve ardından yapay sinir ağı yapısı kullanılarak çıkarım ve sonuç üretir. İşleyişini adım adım açıklamak gerekirse:

Veri Toplama ve Hazırlık: Öncelikle, sistemin öğrenmesi gereken veri seti toplanır ve hazırlanır. Bu veri seti giriş-veri çıkışı ilişkilerini içermelidir.

Bulanık Kuralların Oluşturulması: Bu aşamada, giriş verilerinin bulanık kümeleri ve bu kümelerin üyelik fonksiyonları belirlenir. Bu kümeler insan diline benzer terimlerle ifade edilebilir (örneğin, "düşük", "orta", "yüksek").

Bulanık Kural Tabanının Oluşturulması: Bulanık kurallar, giriş verilerinin bulanık kümeleri ve bu kümelerin eğer-ise kuralları şeklinde ifade edilir. Her kural, girişlerin ve çıktının kombine edildiği bir çıkarım kuralları seti oluşturur.

Ağırlıkların Ayarlanması: Bu adımda, yapay sinir ağı kullanılarak bulanık kural tabanındaki ağırlıklar ayarlanır. Bu ağırlıklar, veri setine dayalı olarak öğrenilir. Bu aşama, ağırlıkların girişleri ile çıktıları arasındaki ilişkiyi öğrenmeyi içerir.

Sonuç Üretimi: Ayarlanmış ağırlıklar ve bulanık kural tabanı kullanılarak, giriş verilerinden çıkarılan sonuçlar elde edilir. Bu sonuçlar, giriş verilerinin çıktıya olan etkisini ifade eder.

ANFİS, bu adımları tekrarlayarak (iteratif olarak) daha iyi sonuçlar elde etmeye çalışabilir. Veriye dayalı öğrenme sayesinde, ANFİS sistemi veri setinin özelliklerine uyum sağlayarak en iyi sonuçları elde etmeye çalışır. Sonuç olarak, ANFİS, veri setindeki karmaşık ilişkileri anlamak ve çıkarım yapmak için bulanık mantık ve yapay sinir ağlarını birleştirir. Bu sayede, karmaşık ve belirsiz veri kümeleri üzerinde etkili sonuçlar üretebilir. Bu yöntem, veriye dayalı tahminlerde ve modellemelerde oldukça etkili olabilir çünkü hem bulanık mantığın esnekliği hem de yapay sinir ağlarının öğrenme yeteneği bir araya gelir. Bu sayede karmaşık ve belirsiz veri kümeleri üzerinde de etkili sonuçlar elde etmek mümkün olabilir. ANFİS, özellikle denetim sistemleri, tahmin, sınıflandırma ve veri modelleme gibi çeşitli uygulamalarda kullanılır.

Bulanık Mantık

Bulanık mantık, 1965 yılında Lotfi Zadeh tarafından ilk kez önerildi. Lotfi Zadeh, Kaliforniya Üniversitesi, Berkeley'de bilgisayar bilimleri profesörüdür ve bu mantık türünü, belirsizlikle başa çıkma yeteneğini daha iyi yansıtan bir model olarak geliştirdi. Lotfi Zadeh, 1965 yılında "Bulanık Kümeleme ve Bulanık Mantık" adlı makalesinde, bulanık kümeleri ve bunları kullanarak mantık kurallarını tanıttı. Bu, bulanık mantığın temelini atmış ve daha sonra bu alanın gelişmesine öncülük etmiştir.

Bulanık mantığın ortaya çıkışı, klasik ikili mantığın gerçek dünyadaki belirsizlikleri ve kesin olmayan durumları ele almakta yetersiz kaldığı fikrine dayanır. Geleneksel mantık, sadece "doğru" veya "yanlış" gibi kesin değerlere dayanırken, gerçek dünyadaki birçok kavram ve durum ara değerlerle ifade edilir. Örneğin, "sıcak" veya "soğuk" gibi terimler kesin değil, göreceli terimlerdir ve insanlar arasında farklılık gösterebilir. Bu tür belirsiz veya göreceli durumları ele almak için bulanık mantık geliştirilmiştir. Bulanık mantık gelişimi Lotfi Zadeh'in öncülük ettiği temel çalışmalarla başlamış ve zamanla birçok araştırmacının katkılarıyla daha da ilerlemiştir. Bu gelişmeler, gerçek dünyadaki belirsiz ve karmaşık durumları ele almak için güçlü bir araç olarak bulanık mantığın kullanılmasına olanak tanımıştır. Bulanık mantığın gelişimi şu aşamalardan geçmiştir:

Bulanık Küme Teorisi: Lotfi Zadeh, bulanık mantığın temelini atarken, bulanık küme teorisini geliştirmiştir. Geleneksel küme teorisinin aksine, bulanık küme teorisi her elemanın bir küme içindeki üyelik derecesini ifade eder. Bu, gerçek dünyadaki belirsiz ve kesin olmayan durumları ifade etmeye olanak tanır.

Üyelik Fonksiyonları: Bu aşamada, bulanık küme teorisi daha da geliştirilerek üyelik

fonksiyonları kavramı ortaya çıkmıştır. Üyelik fonksiyonları, bir elemanın belirli bir kümeye ne kadar uygun olduğunu ifade eden fonksiyonlardır. Bu, belirsizlik ve görecelilik kavramlarının matematiksel olarak ifade edilmesini sağlamıştır.

Kurallar ve Çıkarım Motoru: Bulanık mantığın ana bileşenleri olan kurallar ve çıkarım motoru, gerçek dünyadaki durumları işlemek için kullanılır. Bu aşamada, "Eğer... ise..." şeklindeki kurallar oluşturulmuş ve çıkarım motorları tasarlanmıştır. Bu sayede, girdi değerlerine dayalı olarak sonuç üretmek mümkün hale gelmiştir.

Sonuç olarak bulanık mantık, temelde üç ana bileşen üzerine kuruludur. Bunlar üyelik fonksiyonları, kurallar ve çıkarım motorudur. Her giriş değeri için, belirli bir kavramın ne kadar uygun olduğunu ifade eden üyelik derecesi atanır. Bu derece 0 ile 1 arasında değişebilir. Belirli bir durumda nasıl tepki verilmesi gerektiğini belirten kurallar oluşturulur. Bu kurallar, eğer-ise formunda ifadelerdir. Son olarak da giriş değerlerine dayanarak kuralları uygulanır ve çıkarılan sonuçlar hesaplanır.


Klasik mantık, doğru ve yanlış arasındaki ayrımı net bir biçimde belirleyen bir düşünce yapısıdır. Oysa bulanık mantıkta, kesin doğru veya yanlış ifadeler bulunmaz. Belirsizlik, önemli bir yer tutar. Bir şey tam olarak doğru veya yanlış olabilirken, tamamen doğru veya yanlış da olmayabilir. Bazen yanlışlar, içinde bazı doğruları barındırabilir. İnsanlar genellikle sayısal düşünme yerine sözel düşünme eğilimindedirler. Bu, insanların bulanık bir şekilde düşünceleri, bulanık tanımlar yapmaları ve durumları bulanık bir şekilde tasvir etmeleri anlamına gelir (Toprak, 2009). Klasik Mantık ve Bulanık Mantık, iki farklı mantık türüdür ve farklı türde problemler için kullanılırlar.

Bir örnek üzerinden karşılaştırma yapacak olursak; bir restoran sahibi, müşteri sayısına göre klima sıcaklık ayarını yapmak istiyor. Müşteri sayısı azaldığında klimayı az soğutmak, müşteri sayısı arttığında ise klimayı daha fazla soğutmak istiyor. Klasik mantıkta; müşteri sayısı 5'ten azsa, klima sıcaklık ayarı 20°C, müşteri sayısı 5 ile 10 arasındaysa klima sıcaklık ayarı 22°C, müşteri sayısı 10'dan fazlaysa klima sıcaklık ayarı 18°C olarak belirlenir. Klasik mantıkta, müşteri sayısı kesirli olmaz, tam sayı değerlerine göre kesin kararlar alınır. Bulanık mantıkta; müşteri sayısı düşükse, klima sıcaklık ayarı "soğuk" bulanık kümesi, müşteri sayısı orta düzeydeyse "ılık" bulanık kümesi ve müşteri sayısı yüksekse "sıcak" bulanık kümesi ile temsil edilir. Ardından, bulanık kümeler için üyelik dereceleri hesaplanır. Örneğin, müşteri sayısı 7 ise, "soğuk" üyelik derecesi 0, "ılık" üyelik derecesi 0.3 ve "sıcak" üyelik derecesi 0 olabilir. Bu üyelik derecelerine göre klima sıcaklık ayarı "ılık" bulanık kümesine daha yakındır. Klasik mantıkla yapılan kararda


müşteri sayısına kesin değerler atanır ve sıcaklık ayarları belirli aralıklarla belirlenirken, bulanık mantıkla yapılan kararda müşteri sayısı daha esnek bir şekilde bulanık kümelerle ifade edilir ve klima sıcaklık ayarı daha esnek ve gerçekçi bir şekilde belirlenir. Sonuç olarak, bulanık mantık, belirsizlik içeren durumlar için daha esnek ve gerçekçi sonuçlar elde etmek için kullanılırken, klasik mantık daha kesin ve kesirli değerlerle çalışır ve kesin kararlar almak için kullanılır. Bu nedenle, belirsizlik içeren problemlerde bulanık mantık daha uygun bir seçenek olabilirken, kesin ve net kararlar gereken durumlarda klasik mantık tercih edilebilir.

Bulanık mantıktaki üyelik fonksiyonları ele alınan ifade ve değerle ilgili bilgi sahibi olmamızı ve değer aralığını belirler. Bir örnekle açıklayacak olursak; öğrencilerin aldıkları ders sınav notlarının 0 ile 100 arasında değiştiği görülmektedir. Bu ders için oluşturulan başarı kümeleri "çok başarısız", "başarısız", "normal", "başarılı", "çok başarılı" gibi aralıklarla tanımlanır. Klasik kümelerde üyelik fonksiyonları arasında geçiş bölgesi yoktur. Örneğin, klasik bir kümeyle göre; çok başarısız 0 ile 30, başarısız öğrenciler 30 ile 50, normal öğrenciler 50 ile 70, başarılı öğrenciler 70 ile 85 ve çok başarılı öğrenciler ise 85'ten başlamaktadır. Bu alt kümelerle oluşturulan başarı uzayı, klasik küme şeklinde Şekil 3.10'da gösterilmiştir.

Bulanık kümeyle göre oluşturulan üyelik fonksiyonları Şekil 3.11'de, "çok başarısız" notu için sıfırdan başlayarak sınav notu 30 puan olan öğrenciye kadar devam eder. Not 30 olduğunda, "çok başarısız" kümesinin üyelik fonksiyonu değeri 0 olacaktır. Notun artmasıyla birlikte "çok başarısız" kümesinden uzaklaşma ve "başarısız" kümesine yaklaşma meydana gelir. "Çok başarısız" notu ile "çok başarısız" bulanık kümesinin üyelik derecesi, doğrusal bir ilişkiyle dik bir üçgen şeklinde olacaktır. "Çok başarılı" bulanık kümesi incelendiğinde, 80 notu "çok başarılı" kümesinin ilk noktası olarak seçildiğinde, üst notun sınırı kesin değildir. Aynı zamanda, üyelik fonksiyonu 80 notunda iken üyelik derecesi sıfır değerindedir ve lineer bir şekilde 1 değerine ulaşana kadar artmaktadır. Artış 90 notuna ulaşana kadar devam eder ve bu değerden sonra üyelik derecesi sabit olarak 1 olarak devam eder. "Başarısız", "Normal" ve "Başarılı" bulanık kümelerine ait üyelik fonksiyonları sıfır değerinden başlayarak lineer olarak 1 değerine artar ve daha sonra aynı şekilde lineer olarak 1 değerinden 0 değerine doğru azalır. Bu tür bulanık kümeler için üyelik fonksiyonları üçgen şeklinde olacaktır.



Şekil 3.10. Klasik mantığa ait kümelerin üyelik fonksiyonları



Şekil 3.11. Bulanık mantığa ait küme sisteminin üyelik fonksiyonları

Bulanık Mantığın Avantajları

Gerçek dünyada birçok durum belirsizlik içerir. Bulanık mantık, bu belirsizliklerle başa çıkmak için etkili bir yöntemdir. Kesin olmayan verileri işleme ve değerlendirme yeteneği sayesinde, gerçek dünyadaki karmaşık problemleri ele alabilir.

Bulanık mantık, sık sık kesin sınırların veya kesirli değerlerin zor tanımlandığı durumlarda daha esnek ve gerçekçi sonuçlar verir. Üyelik fonksiyonları aracılığıyla ara değerlerle çalışabilir ve net sınırların belirlenmesine gerek kalmaz.

Bulanık mantık kuralları ve üyelik fonksiyonları, basit ve anlaşılır bir yapıya sahiptir. Bu nedenle, karar alma süreçlerini ve sonuçları kolayca açıklamak ve anlamak mümkündür.

Bulanık mantık, doğal dilde ifade edilebilecek durumları modellemek için uygundur. Bu, uzman olmayan kullanıcıların sistemi daha rahat bir şekilde anlamasını sağlar.

Bulanık Mantığın Dezavantajları

Bulanık mantık, hesaplama açısından klasik mantığa göre daha karmaşıktır. Bulanık üyelik fonksiyonları ve bulanık kümelerle çalışmak, bazı durumlarda yüksek hesaplama gücü gerektirebilir.

Bulanık mantık sistemi, uygun üyelik fonksiyonlarının ve kural tabanının tasarımını gerektirir. Doğru üyelik fonksiyonlarının belirlenmesi ve uygun kural setinin oluşturulması, sistemin etkin ve doğru çalışmasını sağlamak için önemlidir.

Bulanık mantık için uygun üyelik fonksiyonlarını belirlemek ve bulanık kümeleri temsil etmek, bazı durumlarda zor olabilir. Doğru verilerin toplanması ve sisteminin gerçek durumu yansıtması önemlidir.

Bulanık mantık, klasik mantık kadar kesin sonuçlar vermeyebilir. Bazı durumlarda, belirli bir derecede belirsizlikle sonuçlar alınabilir, bu da bazı uygulamalarda kabul edilemez olabilir.

Özetle, bulanık mantık, belirsizlik içeren sistemler için etkili bir araçtır ve birçok uygulamada başarıyla kullanılırken, hesaplama karmaşıklığı ve bazı durumlarda kesinlik eksikliği gibi dezavantajları da göz önünde bulundurulmalıdır. Uygun durumda kullanıldığında, bulanık mantık daha gerçekçi ve esnek sonuçlar elde etmeye yardımcı olabilir.

Bulanık mantık, karmaşık ve belirsiz problemlerin modellenmesi ve çözülmesi için kullanılan güçlü bir araçtır. Bu tür mantık, insan zekasının belirsizliği ve karmaşıklığı ele alma yeteneğine benzer bir şekilde çalışabilir. Bu mantık türü, belirsizliği ve karmaşıklığı daha iyi ele alabilme yeteneği sayesinde birçok gerçek dünya probleminin çözümünde etkili olmuştur. Kontrol sistemleri, yapay zeka, veri madenciliği, yapay sinir ağları, otomasyon, robotik gibi birçok alanda bulanık mantık yöntemleri uygulanmaya başlanmıştır. Bu alanlardaki pratik uygulamalar ve deneyimler, bulanık mantığın daha da geliştirilmesine ve rafine edilmesine katkı sağlamıştır.

Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme şeklini taklit etmek üzere tasarlanmış bir yapay zeka modelidir. Bu model, büyük miktarda veriyi analiz ederek öğrenme ve çıkarım yapabilen bir algoritmik yapıya sahiptir. Yapay sinir ağları, özellikle

desen tanıma, tahmin, sınıflandırma ve veri modelleme gibi uygulamalarda kullanılır. Bu sinir ağları, birçok basit birimden ve bu birimler arasındaki bağlantılardan oluşur. Farklı ağlardan oluşan YSA, öğrenme sürecinden sonra bilgiyi saklama ve genelleme yeteneğine sahip paralel ve dağıtılmış bir işlemci olarak işlev görür. Yapay sinir ağları, temel olarak biyolojik sinir hücrelerinin (nöronlar) işleyişini taklit eden matematiksel işlemlerden oluşur. YSA'nın temel yapı taşı olan nöronlar, giriş verilerini alır, bu verileri ağırlıklar ve eşik değerleri kullanarak işler ve çıktı üretirler. Kısaca YSA'lar belirli bir yapıyı oluşturmak için çok sayıda nöronu birleştirir.

Yapay sinir ağları, temel olarak üç ana katmandan oluşur.

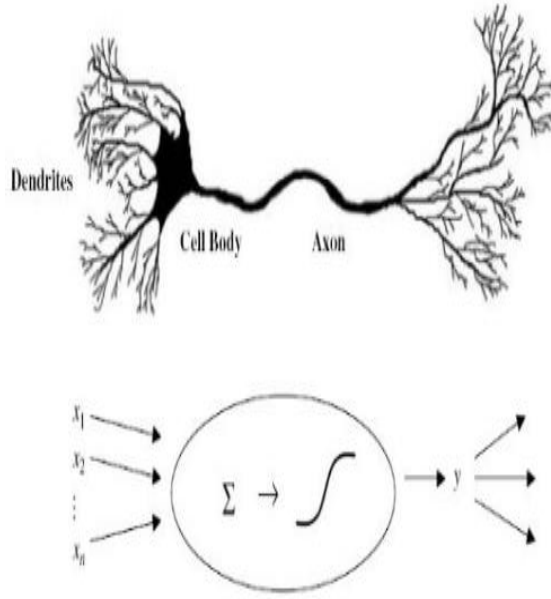
Giriş Katmanı: Dış dünyadan gelen verilerin ağa giriş yaptığı katmandır. Bu veriler, işlenecek probleme uygun şekilde özellik çıkarma ve düzenleme adımlarından geçirilir.

Gizli Katmanlar: Giriş verilerinin işlendiği, öğrenmenin gerçekleştiği ve desenlerin çıkarıldığı katmanlardır. Yapay sinir ağının performansı genellikle gizli katmanların sayısı ve büyüklüğü ile ilişkilidir. Genellikle birden fazla gizli katman kullanılır ve bu katmanlar arasındaki bağlantılar ağırlık değerleriyle belirlenir.

Çıkış Katmanı: Sonuçların elde edildiği katmandır. Bu katmanda yapılan işlemler, genellikle çıktının belirli bir formatta sunulmasını sağlar.

Yapay sinir ağları, eğitim süreciyle çalışır. Eğitim sırasında, ağa giriş verileri ve beklenen çıkışlar verilir. Ağ, bu verileri işler ve çıkışı oluşturur. Gerçek çıkış ile beklenen çıkış arasındaki fark, bir hata fonksiyonu kullanılarak hesaplanır. Bu hata geriye doğru propagasyon yöntemiyle ağın içindeki ağırlık değerleri güncellenir. Propagasyon yapay sinir ağlarının eğitim sürecinde kullanılan bir öğrenme algoritmasıdır. Bu yöntem, ağın eğitim verilerine göre ağırlık değerlerini güncellemek ve hata oranını azaltmak için kullanılır. Yani, ağın ürettiği çıkış ile gerçek çıkış arasındaki hata miktarını geriye doğru ileterek, ağırlık değerlerini ayarlar ve böylece ağın performansını artırır. Bu süreç, hata giderek azalana kadar tekrarlanır. Bu sayede ağ, verileri tanımayı ve öğrenmeyi öğrenir. Sinir sistemi elemanlarının Yapay Sinir Ağları modelindeki terminolojisi Şekil 3.12'de gösterilmiştir.

SİNİR SİSTEMİ	YAPAY SİNİR AĞI
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar



Şekil 3.12. Sinir sistemi elemanlarının Yapay Sinir Ağları modelindeki terminoloji (Toprak, 2009)

Yapay Sinir Ağlarının Avantajları:

Paralel işleme yeteneğine sahiptir, bu da eşzamanlı olarak birden fazla veri örneğini işleyebileceği anlamına gelir. Bu özellik, büyük veri setlerini hızlı bir şekilde işlemek için avantaj sağlar.

Çeşitli karmaşık problemleri çözmek için esnek bir yapıya sahiptir. Eğitim verileri üzerinde yapılan öğrenme sayesinde, ağ belirli bir problemde uzmanlaşabilir ve bu bilgiyi benzer problemlere genelleme yeteneğine sahiptir.

Desen tanıma ve sınıflandırma konusunda başarılıdır. Görüntü işlemeden ses tanımaya kadar birçok alanda kullanılabilir ve doğru sonuçlar elde edebilir.

Eğitim sürecinde verilerle uyum sağlama ve değişen koşullara adapte olma yeteneğine sahiptir. Bu, değişen veri koşullarına uyum sağlayarak performansın artmasına yardımcı olur.

Yapay Sinir Ağlarının Dezavantajları:

Eğitim süreci, büyük veri setleri veya karmaşık yapılarla uzun sürebilir. Ayrıca, bazı durumlarda yüksek hesaplama gücü gerektirebilir.

Eğitim verilerine aşırı uyum sağlayarak, yeni veriler üzerinde düşük performans gösterebilir. Bu duruma aşırı öğrenme denir ve doğru genelleme yapma yeteneğini

olumsuz etkileyebilir.

Karmaşık yapılarından dolayı anlaşılması ve açıklanması zor olabilir. Bu nedenle, ağın iç işleyişini tam olarak anlamak ve sonuçları açıklamak bazen zor olabilir.

Veri yoğun problemlerde iyi sonuçlar verirken, veri yetersizliği durumunda performansı düşebilir. Eğitim için yeterli ve temsil edici veri olmaması, ağın doğru sonuçlar elde etmesini zorlaştırabilir.

Özetle, Yapay Sinir Ağları birçok alanda başarılı sonuçlar veren güçlü bir yapay zeka modelidir. Ancak, eğitim sürecinin uzun olması, aşırı öğrenme riski ve veri yetersizliği gibi bazı dezavantajları vardır. Yine de doğru şekilde kullanıldığında, Yapay Sinir Ağları karmaşık problemleri çözmek ve geniş bir uygulama alanına sahip olmak için etkili bir araçtır.

3.2.3 Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (SMRGT)

Basit üyelik fonksiyonları, bulanık mantık sistemlerinde girdi değişkenlerinin bulanık kümelerini tanımlamak için kullanılan temel matematiksel fonksiyonlardır. Bu fonksiyonlar, belirli bir girdinin bir bulanık kümenin içine ne kadar üye olduğunu belirlemek için kullanılır. Örneğin, "sıcaklık" girdi değişkeni için "soğuk", "ılıman" ve "sıcak" gibi bulanık kümeler tanımlamak istediğimizi düşünelim. Bu kümeleri tanımlamak için basit üyelik fonksiyonları kullanırız. Örneğin, "sıcak" kategorisi için üyelik fonksiyonu, sıcaklığın ne kadar "sıcak" olduğunu belirten bir değerle temsil edilir. Bulanık kural oluşturma tekniği ise, bulanık mantık sistemlerinde kullanılan kural tabanını oluşturma sürecidir. Bu teknik, if-then kuralları şeklinde ifadeler kullanarak, girdi değişkenlerinin bulanık kümeleri arasındaki ilişkileri açıklar. Örneğin, "Eğer sıcaklık sıcak ise ve nem yüksek ise, klimayı aç" gibi bir bulanık kural ifadesi oluşturulabilir. Bulanık mantık sistemleri, belirsizlik ve karmaşıklık içeren sistemleri modellemek ve kontrol etmek için kullanılır. Girdi değerleri genellikle kesin değerler yerine bulanık kümeler olarak ele alındığından, sistemin daha gerçekçi ve esnek bir şekilde çalışmasına olanak tanır. Basit üyelik fonksiyonları ve bulanık kural oluşturma teknikleri, bu tür sistemlerin temel yapı taşlarını oluşturur.


Basit üyelik fonksiyonlarında her girdi değişkeni için bulanık kümeleri tanımlanır. Örneğin, sıcaklık için "soğuk", "ılıman" ve "sıcak" gibi bulanık kümeler tanımlayabiliriz. Her bir kümeyi tanımlamak için bir üyelik fonksiyonu belirlememiz gerekir. Bu fonksiyonlar genellikle üçgen veya üçgensel olabilir. Bir girdi değeri, her bir bulanık

kümenin içine ne kadar üye olduğunu gösteren bir üyelik derecesi ile eşleştirilir. Bu, belirli bir girdi değerinin her bir bulanık küme için ne kadar uygun olduğunu ifade eder. Bulanık kural tabanı, eğer-ise kurallarını içerir. Her kural, girdi değişkenlerinin bulanık kümeleri arasındaki ilişkiyi tanımlar. Örneğin, "Eğer sıcaklık sıcak ise ve nem yüksek ise, klimayı aç" gibi bir kural oluşturulabilir. Bir girdi verildiğinde, bu girdinin bulanık kümeler içindeki üyelik dereceleri hesaplanır. Bu, girdinin her bir bulanık küme için ne kadar uygun olduğunu belirler. Her bir kural, girdi değişkenlerinin üyelik derecelerini kullanarak bir çıktı değeri üretir. Bu çıktılar daha sonra birleştirilir veya ağırlıklandırılır ve sonuç bulanık kümeleri elde edilir. Elde edilen sonuçlar, gerektiğinde kesilme, birleştirme veya ağırlıklandırma gibi işlemlerle düzeltilir ve net bir sonuç üretilir. Elde edilen bulanık sonuçlar, normal değerlere dönüştürülür ve yorumlanır. Bu, genellikle bir karar verme veya kontrol mekanizmasının parçasıdır. Bu süreç, bulanık mantık sistemlerinin temel işleyişini açıklar. Bu sistemler, belirsizlik, karmaşıklık ve gerçek dünyadaki belirli olmayan ilişkileri modellemek ve çözmek için kullanılır.

Üyelik fonksiyonları, bir değişkenin bir bulanık kümedeki üyeliğini ifade eden matematiksel fonksiyonlardır. Bir üyelik fonksiyonu çekirdek değer, anahtar değer ve birim genişliği gibi temel bileşenlerden oluşur.

Çekirdek değer, bulanık kümeye en yüksek üyelik derecesine sahip olduğu noktadaki değerdir. Yani, bu nokta bulanık kümenin en yoğun olduğu bölgeyi ifade eder. Çekirdek değeri, bir üyelik fonksiyonunun zirvesidir. Anahtar değer, bulanık kümenin üyelik fonksiyonunun %50 düzeyinde olduğu noktadaki değerdir. Bu nokta, bulanık kümeyi iki bölgeye böler: bir kısmı bulanık kümeye üye, diğer kısmı ise üye değil. Bu, genellikle üyelik fonksiyonunun "orta noktası" olarak düşünülebilir. Birim genişlik, bulanık kümeye ait üyelik fonksiyonunun anahtar değerden başlayıp, üyelik derecesinin %50 düzeyine ulaştığı iki nokta arasındaki uzaklıktır. Bu, bulanık kümenin yayılma veya genişlik derecesini belirtir. Bu terimleri matematiksel olarak ifade etmek, belirli bir üyelik fonksiyonuna göre değişebilir. Örneğin, üçgen bir üyelik fonksiyonu (genellikle üçgen bulanık küme) için çekirdek değeri üçgenin zirvesi, anahtar değeri üçgenin tabanının orta noktası olabilir ve birim genişlik, üçgenin tabanının genişliği olabilir.

Her değişkenin üyelik fonksiyonları için hesaplanması gereken değerler vardır. Bu değerler; birim genişliği (UW), genişletilmiş taban genişlikleri (EUW), kesişen iki komşu üyelik fonksiyonun değeri (O) ve dik üçgen sayısıdır (Nu). Bu hesaplamalar yapılırken, değişkenin aralığının (X_R) bilinmesi gereklidir (Şekil 3.13).



Şekil 3.13. Üyelik Fonksiyon için çekirdek değer, anahtar değer ve birim genişliğin gösterimi

$$X_R = X_{max} - X_{min} \quad (3.2)$$

$$UW = \frac{X_R}{n_U} \quad (3.3)$$

$$O = \frac{UW}{2} \quad (3.4)$$

$$EUW = \frac{X_R}{n_U} + O \quad (3.5)$$

Bu denklemlerde her X terimi, her bir bağımsız değişkeni temsil etmektedir. Her bir değişken için ayrı ayrı hesaplamalar yapılır. Bu hesaplanan değerler ile birlikte üyelik fonksiyonu için anahtar değerler (Kn) ve çekirdek değeri (Ci) hesaplanmaktadır.

$$K_1 = X_{min} + \frac{EUW}{3} \quad (3.6)$$

$$K_2 = max - \frac{EUW}{3} \quad (3.7)$$

$$C_i = \frac{X_R}{2} + X_{min} \quad (3.8)$$

$$C_{i-1} = \frac{C_i - X_{min}}{2} + X_{min} \quad (3.9)$$

$$C_{i+1} = X_{max} - \left(\frac{X_{max} - C_i}{2} \right) \quad (3.10)$$

Bu denklemlerdeki anahtar değerler ise yapılandırılacak modelin giriş parametrelerini ifade eder. Hesaplamalar sonucunda bulanık girdi ve çıktı değişkenleri oluşturulur. Bu değişkenler arasındaki her bir kombinasyon göz önünde bulundurularak bulanık kural tabanı oluşturulur. Bu model deneme-yanılma yaklaşımı neredeyse hiç kullanılmaz. Bu model, bilgisayar ortamında paket programlara aktarılarak tasarım işlemi gerçekleştirilir.

3.2.4. Çoklu Doğrusal Regresyon (ÇDR)

Regresyon analizi, verilen bir değişkenin bilinen bir başka değişken tarafından tahmin edilmesi için kullanılan güçlü bir istatistiksel analiz yöntemidir. Çoklu doğrusal regresyon, istatistiksel bir modelleme tekniğidir. Bağımlı bir değişkenin birden fazla bağımsız değişkenle ilişkisini analiz etmek için kullanılır ve birden fazla bağımsız değişkenin etkisini aynı anda değerlendirir. Örneğin, bir evin satış fiyatını tahmin etmek istediğimizi düşünelim. Bu durumda, evin büyüklüğü (metrekare), odaların sayısı, konumu gibi birden fazla özellik evin fiyatını etkileyebilir. İşte çoklu doğrusal regresyon, bu tür bir senaryoda birden fazla bağımsız değişkenin ev fiyatı üzerindeki etkisini değerlendirmemize olanak tanır. Bu yöntem, değişkenler arasındaki ilişkilere dayanarak tahminler yapmak ve analiz yapmak için kullanılır. Regresyon analizi, tahmine dayalı analiz olarak da adlandırılabilir ve tarihsel verilere dayanarak gelecekteki bir değeri tahmin etmek için kullanılır. Basit doğrusal regresyonda, bir değişken (Y) diğer bir değişken (X) tarafından tahmin edilmeye çalışılır. Çoklu doğrusal regresyonda ise birden fazla bağımsız değişken (X_1, X_2, \dots, X_n) kullanılarak tahmin yapılır ve çok değişkenli bir model oluşturulur. Doğrusal olmayan regresyonda ise değişkenler arasındaki ilişki doğrusal değilse, daha karmaşık fonksiyonlar kullanılarak tahmin yapılır.

Çoklu doğrusal regresyonda, incelenen bir konuda en etkili faktörleri belirlemek için tüm değişkenler gözlemlenir ve en iyi tahmin için bu faktörler kullanılır. Örneğin, buharlaşma miktarını tahmin etmek için sıcaklık, solar radyasyon, hava buhar basıncı ve rüzgar gibi meteorolojik faktörler incelenir ve buharlaşma tahmininde en etkili olan parametreye göre günlük buharlaşma miktarı tahmin edilir.

Doğada karşılaşılan olaylarda, olaya etki eden birçok değişken mevcuttur. Bu değişkenler bağımlı ve bağımsız değişkenler olarak olayın var oluş şekline göre sınıflandırılır. ÇDR yöntemi, bir bağımlı değişkenin etkileme ve etkilenme derecesini tespit etmek için bağımsız değişkenlerin değerlerini keşfetmek amacıyla kullanılan bir yöntemdir. Bu ilişkiyi tespit etmek amacıyla oluşturulan denklem aşağıdaki gibidir.

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_jx_j + \dots + \beta_px_p + \varepsilon \quad (3.11)$$

Burada;

y, bağımlı değişken (tahmin etmeye çalıştığımız değişken)

x_1, x_2, \dots, x_p , bağımsız değişkenler (etkilerini analiz etmek istediğimiz değişkenler)

$\beta_1, \beta_2, \dots, \beta_p$ regresyon katsayıları (değişkenlerin etkilerini gösteren katsayılar)

ε , hata terimi (gerçek değerler ile model tahminleri arasındaki fark) ifade etmektedir.

Çoklu doğrusal regresyon analizi, regresyon katsayılarını ve modelin kalitesini değerlendirerek bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini anlamaya çalışır. Bu analiz sayesinde, bağımlı değişkenin tahminlemesi ve değişkenler arasındaki ilişkilerin anlaşılması amaçlanır.

3.3. Model Performansında Kullanılan İstatistik Parametreleri

Determinasyon katsayısı (R^2), ortalama karesel hataların karekökü (KKOH) ve mutlak ortalama hata (MOH) değerleri hesaplanarak model sonuçlarının analizi ve performanslarının değerlendirilmesi için kullanılmıştır.

Determinasyon katsayısı (R^2)

Determinasyon katsayısı (R^2), bir regresyon modelinin veri setine ne kadar iyi uyduğunu ve bağımsız değişkenlerin bağımlı değişkeni ne kadar iyi açıkladığını gösteren bir istatistiksel ölçüdür. R^2 değeri, 0 ile 1 arasında bir değer alır ve genellikle yüzde olarak ifade edilir.

R^2 , 1'e yaklaştıkça regresyon modelinin veri setine daha iyi uyduğunu ve bağımsız değişkenlerin bağımlı değişkeni daha iyi açıkladığını gösterir. Örneğin, R^2 değeri 0.75 ise, modelin veri setine %75 oranında uyduğu ve bağımsız değişkenlerin bağımlı değişkeni %75 oranında açıkladığı anlamına gelir.

Ancak, yüksek bir R^2 değeri her zaman iyi bir regresyon modeli olduğu anlamına gelmez. R^2 , sadece bağımsız değişkenlerin bağımlı değişken üzerindeki ilişkisini gösterir ve regresyon modelinin başka faktörleri veya değişkenleri göz ardı edip etmediğini belirtmez. Aynı zamanda, R^2 değeri yalnızca bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin gücünü ölçer ve korelasyonu ifade eder.

Dolayısıyla, R^2 değeri kullanılırken, modelin yalnızca bağımlı değişkenin ne kadar açıklandığını değil, aynı zamanda diğer önemli değişkenlerin de göz önünde bulundurulması ve modelin doğruluğunun kritik bir şekilde değerlendirilmesi önemlidir. R^2 denklemi (3.12)'deki gibidir.

$$(R^2) = \left(\frac{n\sum xy - (\sum x)(\sum y)}{\sqrt{(n\sum x^2) - (\sum x)^2} \sqrt{(n\sum y^2) - (\sum y)^2}} \right) \quad (3.12)$$

Eğer R^2 değeri 1 ise, model veri setine tam uyum sağlamaktadır, yani tüm varyasyon açıklanmaktadır. Ancak R^2 değeri 0 ise, modelin veri setine uyum sağlamadığı ve bağımsız değişkenlerin bağımlı değişkeni açıklamada başarısız olduğu anlaşılır.

Mutlak Ortalama Hata (MOH)

Mutlak ortalama hata (MOH), regresyon analizinde kullanılan bir hata ölçüsüdür. MOH, tahmin edilen değerlerin gerçek değerlerden mutlak değerlerinin ortalamasını hesaplar ve böylece tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçer.

MOH, her tahmin değerinin gerçek değerden ne kadar uzak olduğunu hesaplar ve bu farkların mutlak değerlerini alarak ortalamasını alır. Bu sayede, negatif ve pozitif hataların etkisi birbirini yok eder ve hata ölçüsü genel bir sapmayı belirtir. MOH değeri ne kadar küçükse, tahminlerin gerçek değerlere ne kadar yakın olduğu anlamına gelir ve modelin performansı o kadar iyi olarak değerlendirilir.

MOH denklemi (3.13)'teki gibidir.

$$MOH = \frac{1}{N} \sum_{i=1}^N |ET_{ölçüm} - ET_{tahmin}| \quad (3.13)$$

Yukarıdaki denklemde (3.13);

ET:buharlaşma miktarı N: veri sayısını temsil etmektedir.

Ortalama Hataların Karekökü (KKOH)

Ortalama Hataların Karekökü, regresyon analizinde kullanılan bir hata ölçüsüdür. KKOH, tahmin edilen değerlerin gerçek değerlerden ne kadar sapma gösterdiğini ve bu sapmaların karelerinin ortalamasının karekökünü hesaplar. KKOH değeri, hataların büyüklüğünü

ölçerken negatif ve pozitif hataları dikkate alır ve büyük hataların görülmesini sağlar. KKOH denklemi (3.14)'te verilmiştir.

$$KKOH = \sqrt{\frac{1}{N} \sum_{i=1}^N (ET_{ölçüm} - ET_{tahmin})^2} \quad (3.14)$$

ET: buharlaşma miktarı *N*: veri sayısını temsil etmektedir.

KKOH değeri, öngörülen değerlerin gerçek değerlere olan uzaklığını ifade eder. Bu değer ne kadar küçükse, modelin performansının o kadar iyi olduğu anlamına gelir, çünkü tahminler gerçek değerlere daha yakın demektir. KKOH, hataların kareleri kullanılarak hesaplandığı için büyük hataların etkisi daha fazla olur ve bu nedenle genellikle büyük hataların farkedilmesinde kullanılır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Günlük evapotranspirasyon tahmini için, ortalama günlük hava sıcaklığı (TM), rüzgar hızı (U), solar radyasyon (SR) ve bağıl nem (RH) gibi parametreler kullanılmıştır. Determinasyon katsayısı R^2 , ortalama karesel hataların karekökü (KKOH) ve mutlak ortalama hata (MOH) değerleri hesaplanarak model sonuçlarının analizi ve performanslarının değerlendirilmesi için kullanılmıştır. Elde edilen sonuçlar Çizelge 4.1'de sunulmuş ve hangi yöntemin günlük buharlaşma tahminleri için daha iyi performans gösterdiği belirlenmiştir.

MODEL İSİMLERİ	MODEL GİRDİLERİ	MOH (mm)	KKOH (mm)	R^2
ÇDR1	SR	0,454	0,583	0,9112
ÇDR2	SR, TM	0,369	0,460	0,9403
ÇDR3	SR, TM, RH	0,178	0,233	0,9824
ÇDR4	SR, TM, RH, U	0,153	0,206	0,9872
ANFİS1	SR	0,448	0,573	0,9151
ANFİS2	SR, TM	0,342	0,423	0,9493
ANFİS3	SR, TM, RH	0,116	0,173	0,9913
ANFİS4	SR, TM, RH, U	0,046	0,067	0,9988
BULANIK-SMRGT	SR, TM, RH, U	0,304	0,383	0,9610

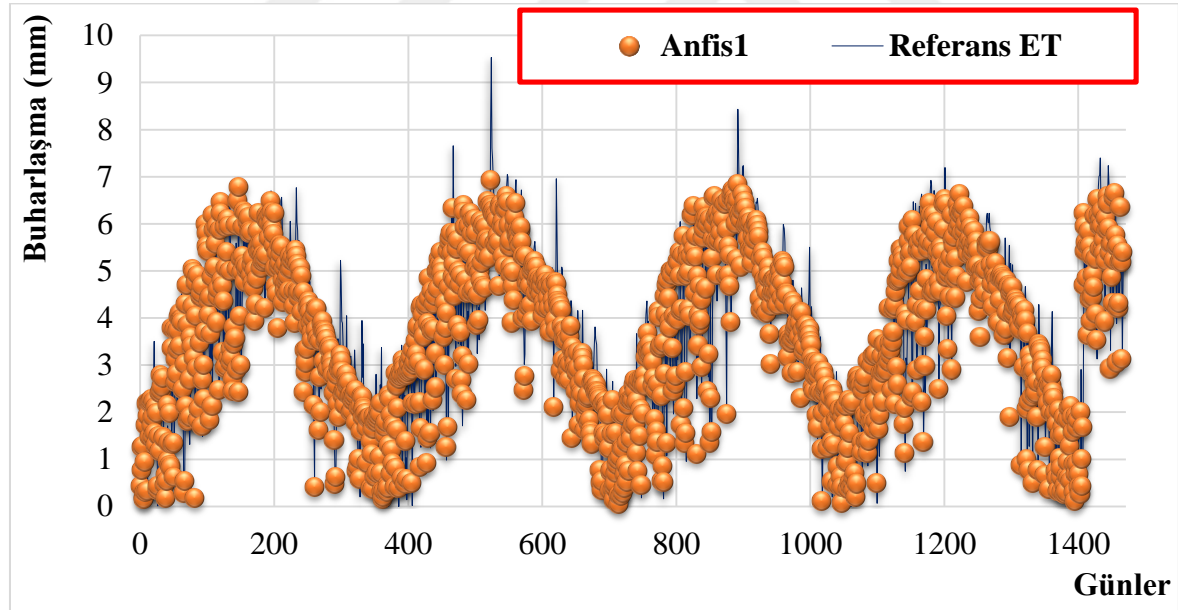
Çizelge 4.1 Modellerin Performans Sonuçları

Bu araştırmada Penman Monteith yöntemini referans kabul edilerek günlük evapotranspirasyon tahmini yapılmıştır (ET_0). Basit Üyelik Fonksiyonları ve Bulanık Kural Oluşturma Tekniği (Bulanık SMRGT) ile Adaptif Sinirsel Bulanık Çıkarım sistemi (ANFİS) yöntemleri, günlük evapotranspirasyon miktarının öngörülmesi için kullanılmıştır. Elde edilen sonuçlar, klasik Çoklu Doğrusal Regresyon (ÇDR) yönteminin sonuçlarıyla kıyaslanmıştır. Her iki modelin de kararlı sonuçlar sunduğu, referans evapotranspirasyon değerleriyle karşılaştırılarak belirlenmiştir. Çizelge incelendiğinde tüm parametreleri kullanarak buharlaşma tahmini yaptığımız Bulanık-SMRGT modelin orta derecede uyumlu sonuç verdiği görülmüştür. Çizelge incelendiğinde ÇDR1 ve ÇDR2'nin kısmen uyumlu bir sonuç verdiği görülmüştür. ÇDR3 modelde parametre sayısını arttırdığımızda determinasyon katsayısının daha hızlı artış gösterdiği, hata oranlarının ise

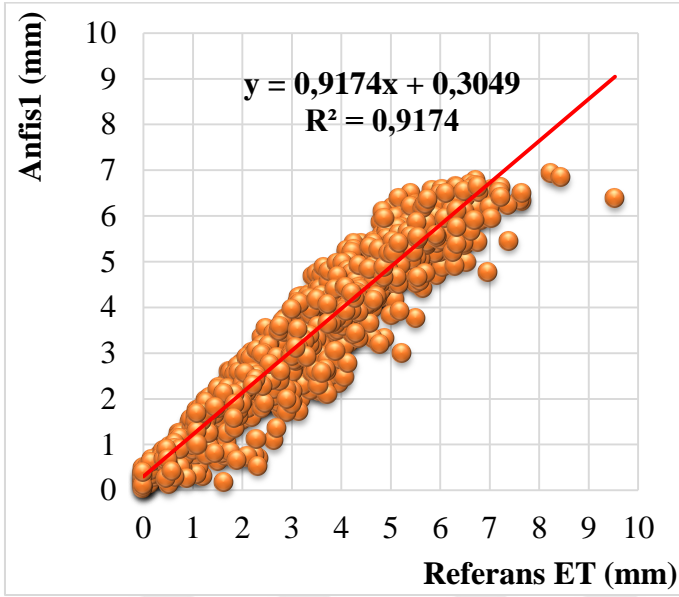
düştüğü görülmüştür. SR, TM, RH ve U parametrelerini kullanarak buharlaşma tahmini yaptığımız ÇDR4 modelde ise en yüksek determinasyon katsayısı ve en düşük hata oranlarına ulaşılmıştır. ANFİS yöntemi kullanılarak yapılan çalışmanın parametre araştırmasına göre test kümesi determinasyon katsayısı R^2 , MOH ve KKOH değerleri çizelgede verilmiştir. Çizelge incelendiğinde ANFİS1 ve ANFİS2'nin kısmen geçerli bir sonuç verdiği görülmüştür. ANFİS3 modelde ise parametre sayısını arttırdığımızda diğer iki modele nazaran dahi iyi sonuçlara ulaşılmıştır. SR, TM, RH ve U parametrelerini kullanarak buharlaşma tahmini yaptığımız ANFİS4 modelde ise en yüksek determinasyon katsayısı ve en düşük hata oranlarına ulaşılmıştır.

4.1. ANFİS Model Sonuçları

Günlük evapotranspirasyon tahminleri SR, TM, RH ve U girdili kombinasyonlar kullanılarak ANFİS yöntemi ile elde edilmiştir. Bu tahminler için ET_0 referans olarak kabul edilmiştir.

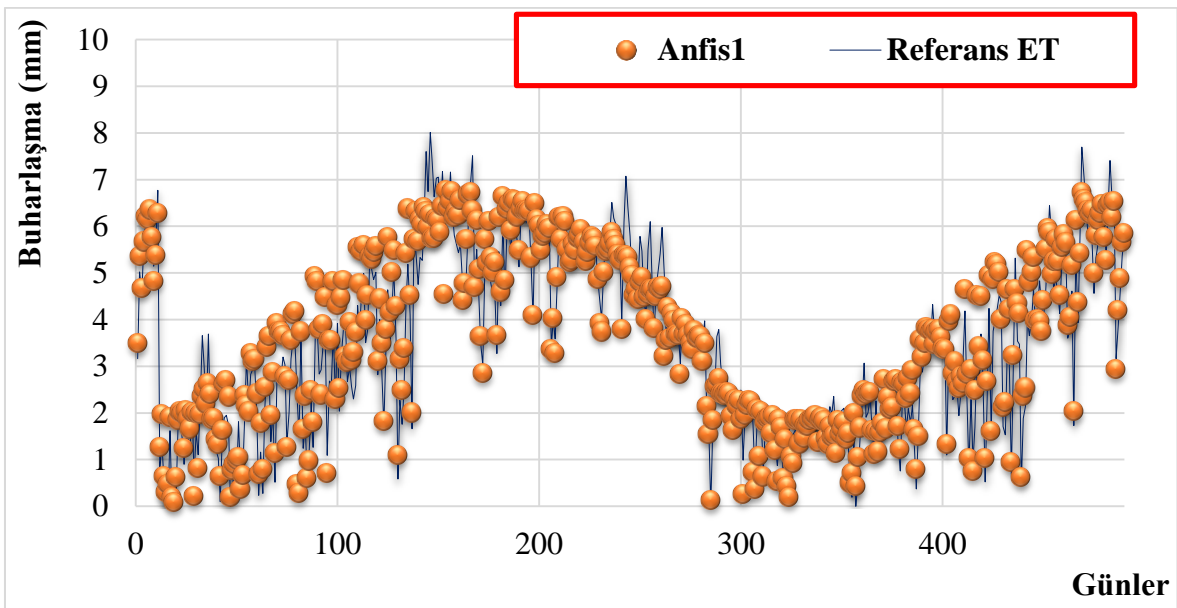


Şekil 4.1. Eğitim aşamasında ANFİS1-Referans ET dağılım grafiği




Şekil 4.2. Eğitim aşamasında ANFİS1-Referans ET saçılım grafiği

Şekil 4.1'de eğitim kümesinde her güne ait ölçülen değerler ve sadece SR parametresinin kullanıldığı ANFİS1 metodu ile yapılan tahminlerin dağılımı görülmektedir. Şekil 4.2'de ise sadece SR parametresinin kullanıldığı ANFİS1 metodu ile yapılan tahminlerin saçılım grafiği bulunmaktadır. Yalnız SR parametresi kullanılarak elde edilen tahminler için R^2 değeri 0.9174 olarak hesaplanmıştır.

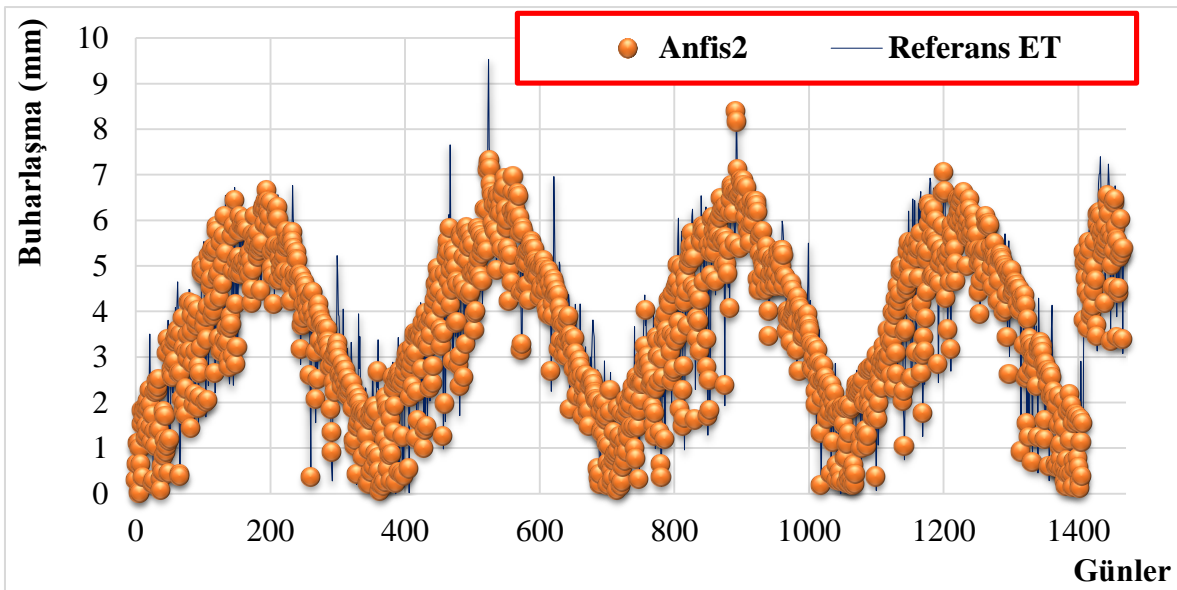


Şekil 4.3. Test aşamasında ANFİS1-Referans ET dağılım grafiği




Şekil 4.4. Test aşamasında ANFİS1-Referans ET saçılım grafiği

Şekil 4.3'te gösterilen test kümesine ait yalnızca SR parametresinin kullanıldığı ANFİS1 metodu ile yapılan tahminlerin dağılımı görülmektedir. Şekil 4.4'te ise sadece SR parametresinin kullanıldığı ANFİS1 metodun saçılım grafiği sunulmuştur. R^2 değeri 0.9151 olarak hesaplanmıştır. Bu değer, SR parametresini kullanan eğitim kümesi için elde edilen sonuçtan daha düşük olduğu fark edilmiştir. Yapılan tahminler ile günlük tahmin değerleri arasında kısmi bir uyum olduğu gözlemlenmektedir.

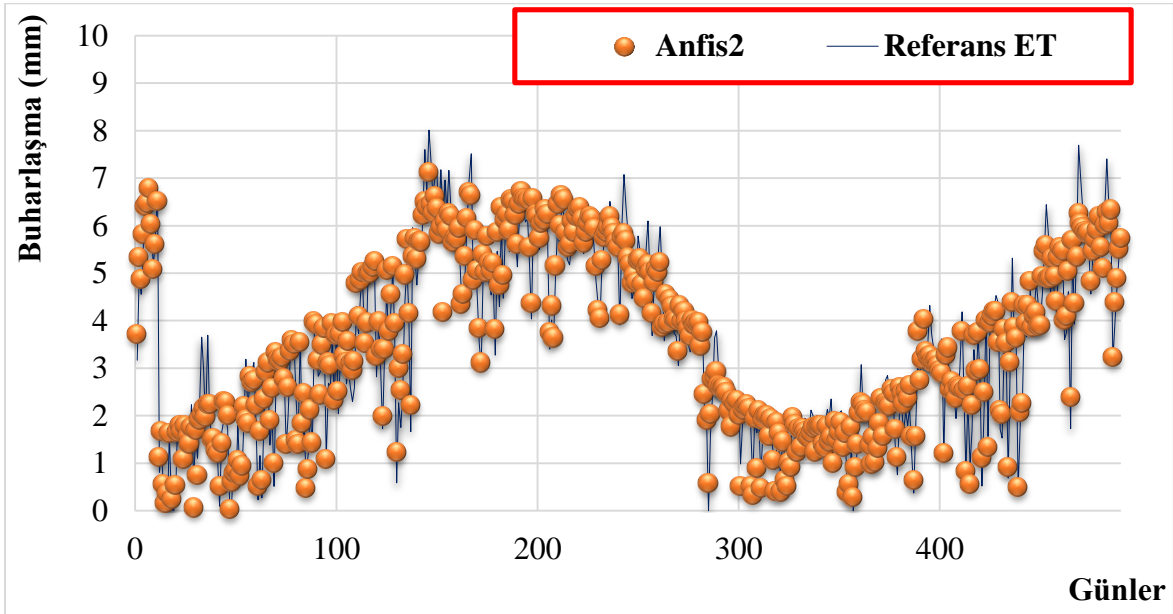


Şekil 4.5. Eğitim aşamasında ANFİS2-Referans ET dağılım grafiği




Şekil 4.6. Eğitim aşamasında ANFİS2-Referans ET saçılım grafiği

Şekil 4.5'te eğitim kümesinde SR ve TM parametrelerinin kullanıldığı ANFİS2 metodunda yapılan tahminlere ait dağılım grafiği sunulmaktadır. Şekil 4.6'da ise SR ve TM parametrelerinin kullanıldığı ANFİS2 metodun ait saçılım grafiği yer almaktadır. Bu parametreler kullanıldığında elde edilen R^2 değeri 0.95 olarak bulunmuştur.




Şekil 4.7. Test aşamasında ANFİS2-Referans ET dağılım grafiği

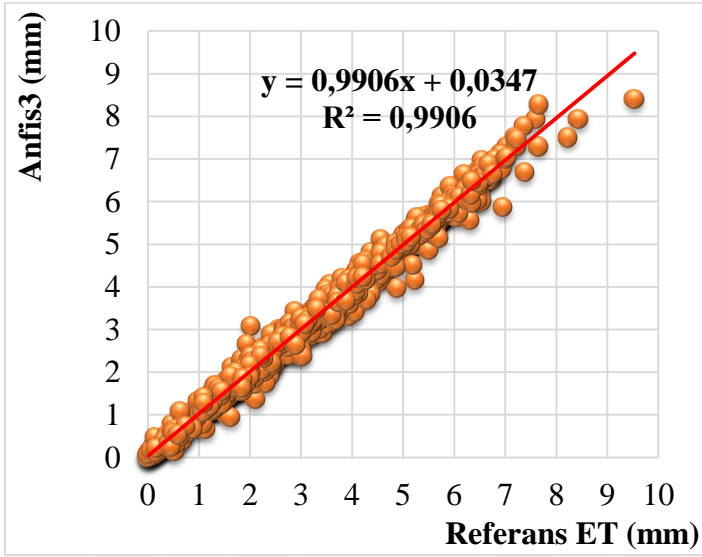


Şekil 4.8. Test aşamasında ANFİS2-Referans ET saçılım grafiği

Şekil 4.7'de, test kümesine ait SR ve TM parametrelerinin kullanıldığı ANFİS2 metodunda yapılan tahminlerin dağılım grafiği sunulmuştur. Yapılan tahminlerin günlük tahmin değerleri ile kısmen uyumlu olduğu görülmüştür. Şekil 4.8'de ise SR ve TM parametrelerinin kullanıldığı ANFİS2 metodun saçılım grafiği sunulmuştur. R^2 değerinin 0.9493 olduğu görülmüştür. Bu değer, aynı parametreleri kullanan eğitim aşamasındaki sonuçtan daha düşük olduğu vurgulanmıştır.

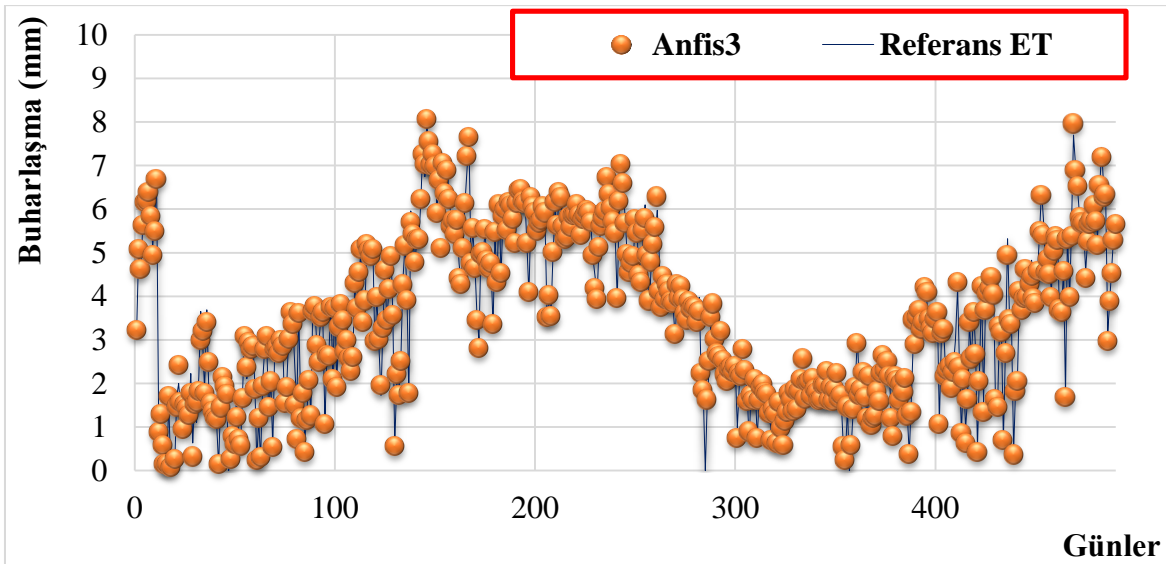


Şekil 4.9. Eğitim aşamasında ANFİS3-Referans ET dağılım grafiği




Şekil 4.10. Eğitim aşamasında ANFİS3-Referans ET saçılım grafiği

Şekil 4.9 ve Şekil 4.10, SR, TM ve RH parametreleri eğitim aşamasında ANFİS3 yönteminde girdi olarak kullanılmıştır. Bu şekilde elde edilen günlük evapotranspirasyon tahminlerinin dağılımını göstermeyi amaçlanmıştır. Elde edilen sonuçlarda R^2 değeri 0.9906 olarak bulunmuştur. Bu değer ET_0 ile büyük ölçüde uyumlu olduğu sonucuna ulaşmayı sağlamıştır.

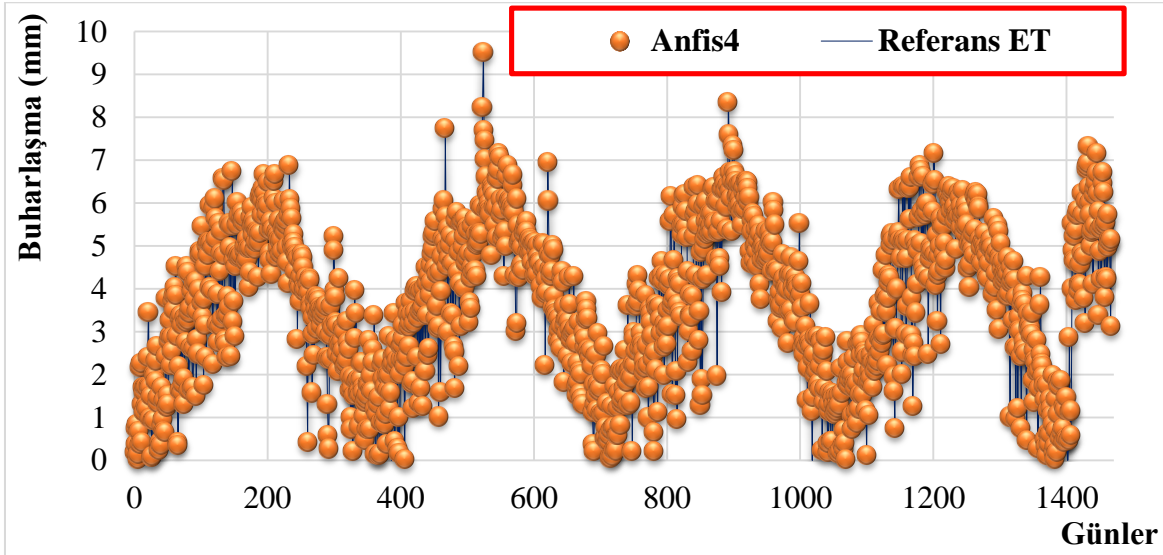


Şekil 4.11. Test aşamasında ANFİS3-Referans ET dağılım grafiği

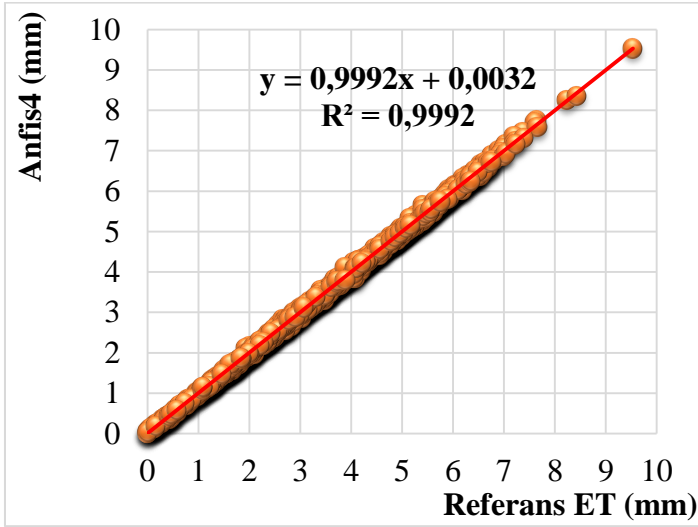


Şekil 4.12. Test aşamasında ANFİS3-Referans ET saçılım grafiği

Şekil 4.11 ve Şekil 4.12, SR, TM ve RH parametrelerinin test kümesinde ANFİS3 yöntemine girdi olarak kullanıldığını göstermektedir. Saçılım grafiğinde R^2 değeri 0.9913 olarak bulunmuştur. Bu sonuç, SR, TM ve RH girdili eğitim kümesine göre daha iyi bir performans sergilemiştir.

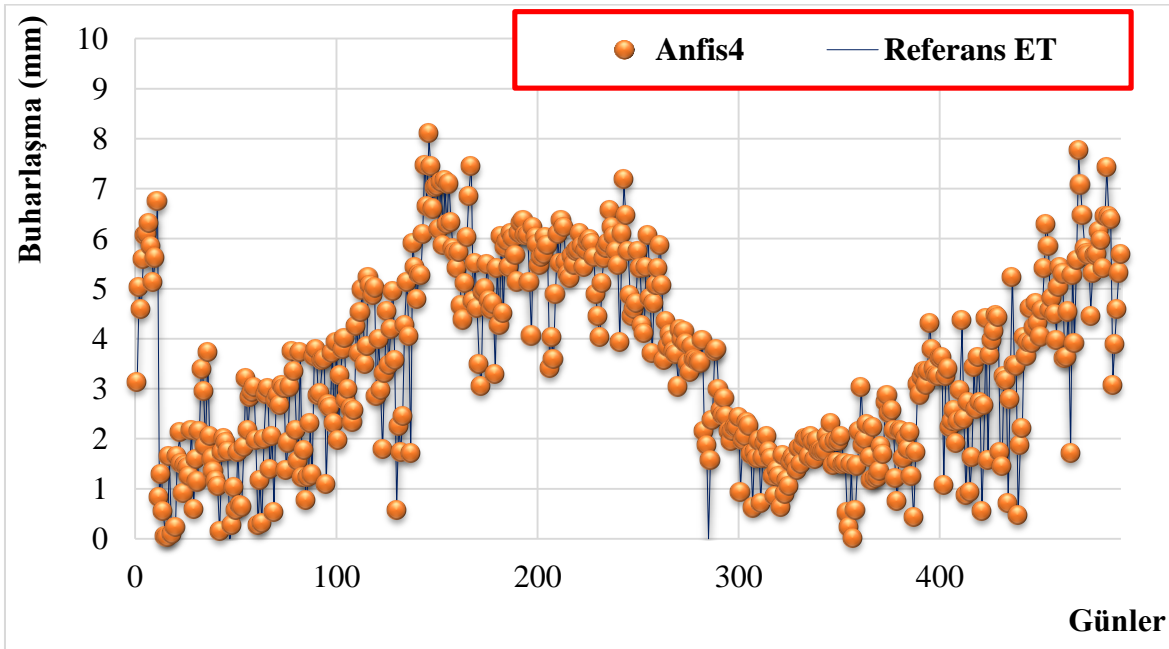


Şekil 4.13. Eğitim aşamasında ANFİS4-Referans ET dağılım grafiği




Şekil 4.14. Eğitim aşamasında ANFİS4-Referans ET saçılım grafiği

Şekil 4.13 ve 4.14, SR, TM, RH ve U parametrelerinin tümünün kullanıldığı kombinasyonunun eğitim kümesinde ANFİS4 yöntemi ile elde edilen tahmin sonuçlarının dağılım ve saçılım grafiğini göstermektedir. Diğer kombinasyonlara göre en uyumlu sonucu veren bu kombinasyonda R^2 değeri 0.9992 olarak hesaplanmıştır. Bu değer, diğer ANFİS yöntemleri arasındaki en yüksek sonuç olması nedeniyle göze çarpmaktadır.



Şekil 4.15. Test aşamasında ANFİS4-Referans ET dağılım grafiği

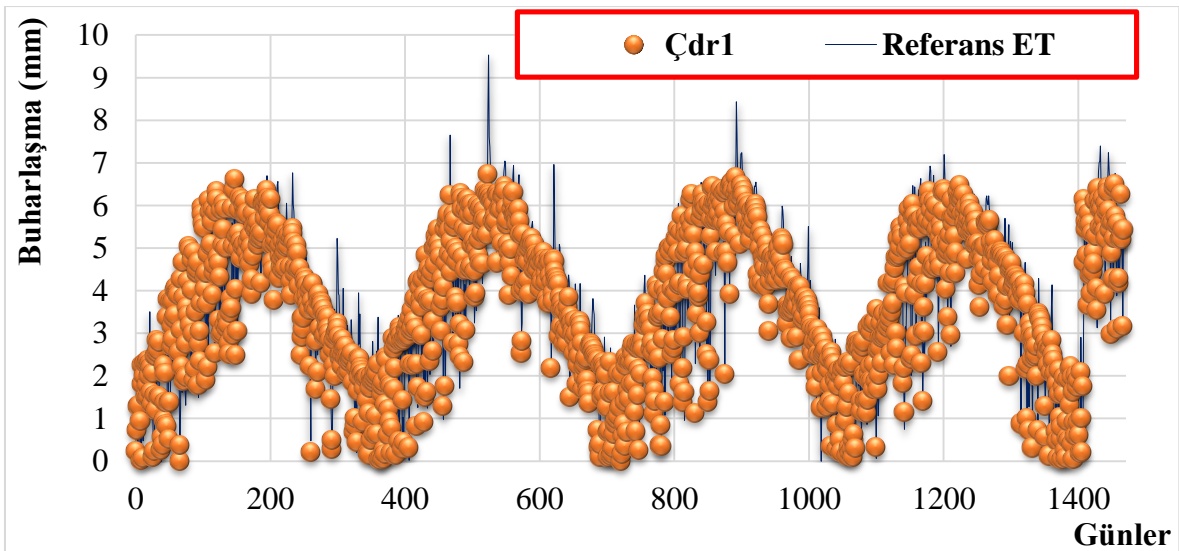


Şekil 4.16. Test aşamasında ANFİS4-Referans ET saçılım grafiği


Şekil 4.15 ve Şekil 4.16, SR, TM, RH, U parametrelerinin girdi olarak kullanıldığı ANFİS4 yönteminin test kümesine ait tahmin sonuçlarının sırasıyla dağılım ve saçılım grafiğini göstermektedir. R^2 değeri 0.9988 olarak hesaplanmıştır. Bu değer, aynı parametrelerin girdi olarak kullanıldığı eğitim kümesine ait değere yakın olduğu gözlenmiştir.

4.2. Çoklu Doğrusal Regresyon Model Sonuçları

Günlük evapotranspirasyon tahminleri SR, TM, RH ve U girdili kombinasyonlar kullanılarak ÇDR yöntemi ile elde edilmiştir. Bu tahminler için ET_0 referans olarak kabul edilmiştir.




Şekil 4.17. Eğitim aşamasında ÇDR1-Referans ET dağılım grafiği

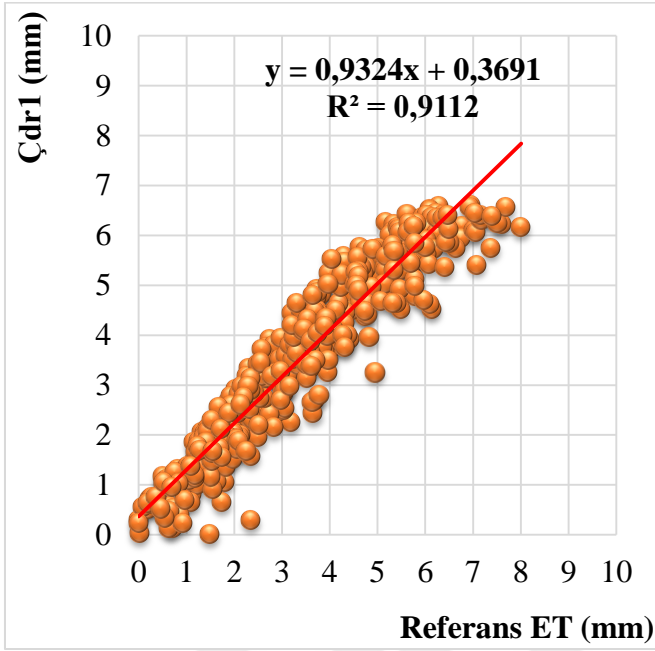


Şekil 4.18. Eğitim aşamasında ÇDR1-Referans ET saçılım grafiği

Eğitim aşamasında ÇDR1 yöntemini uygulayarak yapılan tahminlerin dağılımı Şekil 4.17'de sergilenmektedir. Bu grafik, yalnızca SR girdi parametresi kullanılarak elde edilen sonuçları içermektedir. Şekil 4.18'de ise SR parametresine özgü ÇDR1 metodun saçılım grafiği sunulmuştur. Tek parametre olarak yalnızca SR kullanıldığında, R^2 değeri 0,9158 olarak belirlenmiştir.




Şekil 4.19. Test aşamasında ÇDR1-Referans ET dağılım grafiği




Şekil 4.20. Test aşamasında ÇDR1-Referans ET saçılım grafiği

Şekil 4.19'da sunulan test kümesi için, SR parametresinin kullanıldığı ÇDR1 metodun günlük tahmin değerleriyle kısmen uyumlu olduğu gözlemlenmektedir. Bu grafik, SR parametresi kullanılarak yapılan tahminlerin dağılımını göstermektedir. Şekil 4.20'de ise yalnız SR parametresinin kullanıldığı ÇDR1 yöntemine ait saçılım grafiği verilmektedir. R^2 değeri 0,9112 olarak belirlenmiştir. Bu R^2 değeri, SR parametresini kullanan eğitim kümesine ait sonuçlardan daha düşük bir değer elde edildiğini göstermektedir.




Şekil 4.21. Eğitim aşamasında ÇDR2-Referans ET dağılım grafiği




Şekil 4.22. Eğitim aşamasında ÇDR2-Referans ET saçılım grafiği

Şekil 4.21'de, eğitim kümesinde SR ve TM parametrelerinin kullanıldığı ÇDR2 metodunda yapılan tahminlerin dağılımı gözlemlenmektedir. Şekil 4.22'de ise SR ve TM parametrelerine özgü ÇDR2 metodunda saçılım grafiği sunulmaktadır. Bu iki parametre kullanıldığında, R^2 değeri 0,9413 olarak hesaplanmıştır.




Şekil 4.23. Test aşamasında ÇDR2-Referans ET dağılım grafiği




Şekil 4.24. Test aşamasında ÇDR2-Referans ET saçılım grafiği

Şekil 4.23, SR ve TM parametrelerinin kullanıldığı ÇDR2 metodunda yapılan tahminlerin, test kümesine ait günlük tahmin değerleriyle kısmen uyumlu olduğunu göstermektedir. Şekil 4.24'deki saçılım grafiği ise ÇDR2 metodunda SR ve TM parametrelerine özgü dağılımı gösterir. R^2 değeri 0,9403 olarak hesaplanmıştır. Bu değer, SR ve TM parametrelerini kullanan eğitim kümesine ait sonuçlardan daha düşük olduğu görülmüştür.




Şekil 4.25. Eğitim aşamasında ÇDR3-Referans ET dağılım grafiği




Şekil 4.26. Eğitim aşamasında ÇDR3-Referans ET saçılım grafiği

Şekil 4.25 ve Şekil 4.26'da, eğitim kümesinde SR, TM ve RH parametrelerinin ÇDR3 yöntemiyle tahmin edilen günlük evapotranspirasyon değerlerinin dağılım ve saçılım grafikleri gösterilmiştir. R^2 değeri 0,9775 olarak bulunmuştur, bu da referans ET ile büyük ölçüde örtüşüğünü göstermektedir.

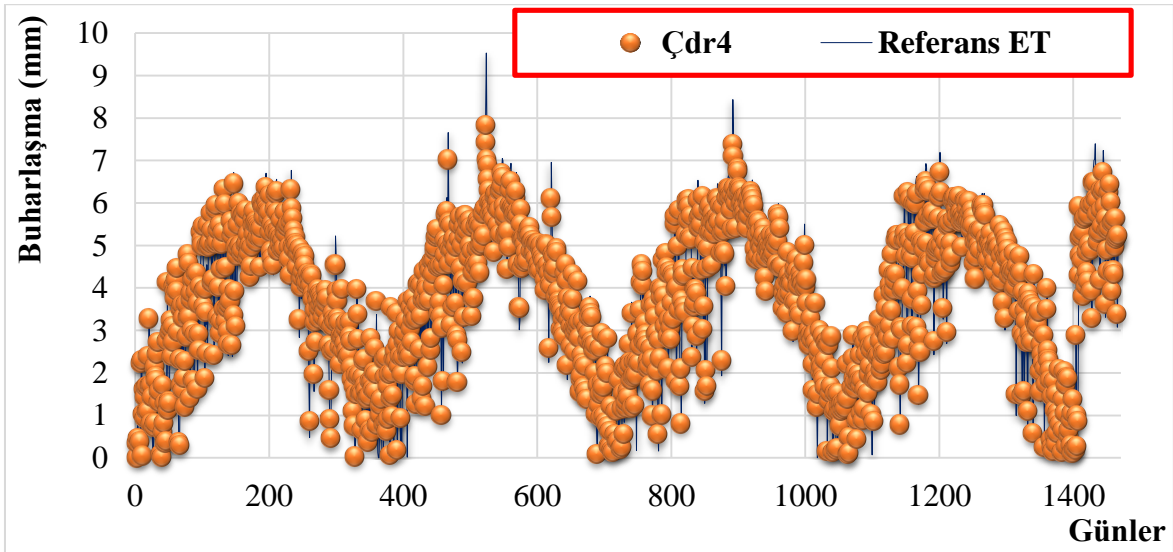


Şekil 4.27. Test aşamasında ÇDR3-Referans ET dağılım grafiği

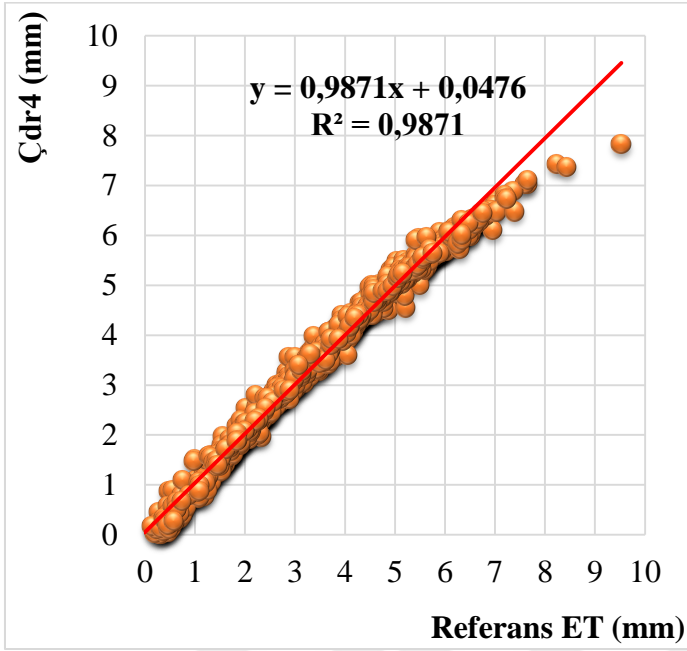


Şekil 4.28. Test aşamasında ÇDR3-Referans ET saçılım grafiği

Şekil 4.27 ve Şekil 4.28'de, test kümesinde SR, TM ve RH parametrelerinin ÇDR3 yöntemiyle kullanılarak elde edilen sonuçların saçılım grafiği görülmektedir. R^2 değeri 0,9824 olarak hesaplanmıştır. Bu sonuç, aynı girdili eğitim kümesine göre daha üstün bir performans elde edildiğini göstermektedir.




Şekil 4.29. Eğitim aşamasında ÇDR4-Referans ET dağılım grafiği




Şekil 4.30. Eğitim aşamasında ÇDR4-Referans ET saçılım grafiği

Şekil 4.29 ve 4.30'da, SR, TM, RH ve U parametrelerinin kombinasyonuyla eğitim kümesinde ÇDR4 yöntemiyle yapılan tahmin sonuçlarının dağılım ve saçılım grafiği gösterilmektedir. Tüm parametrelerin kullanıldığı bu durumda, R^2 değeri 0,9871 olarak elde edilmiştir.



Şekil 4.31. Test aşamasında ÇDR4-Referans ET dağılım grafiği




Şekil 4.32. Test aşamasında ÇDR4-Referans ET saçılım grafiği


Şekil 4.31 ve Şekil 4.32'de, tüm parametreleri girdi olarak kullanan ÇDR4 yöntemi ile test aşamasındaki dağılım ve saçılım grafiği sunulmuştur. Determinasyon katsayısı 0,9872 olarak hesaplanmıştır. Bu sonuç, ÇDR yöntemine ait en yüksek performansı temsil etmektedir. SR, TM, RH ve U parametreleri içeren bu kombinasyon, diğer kombinasyonlara kıyasla en doğru sonucu vermiştir.

4.3. Bulanık SMRGT Model Sonuçları

Günlük evapotranspirasyon tahminleri Bulanık SMRGT yöntemi kullanılarak elde edilmiştir. Bu tahminler için ET_0 referans olarak kabul edilmiştir. Buharlaşma tahmini, SR, TM, RH ve U giriş kombinasyonları kullanılarak Bulanık SMRGT yöntemiyle gerçekleştirilmiştir.



Şekil 4.33. Test aşamasında Bulanık SMRGT-Referans ET dağılım grafiği



Şekil 4.34. Test aşamasında Bulanık SMRGT-Referans ET saçılım grafiği

Şekil 4.33 ve Şekil 4.34'te, tüm parametreleri girdi olarak kullanan Bulanık-SMRGT yöntemi ile test kümesine ait dağılım ve saçılım grafiği sunulmuştur. Determinasyon katsayısı 0,961 olarak hesaplanmıştır. Dağılım grafiği incelendiğinde Bulanık-SMRGT modelinin referans evapotranspirasyon ile uyumlu olduğu görülmüştür.

5.SONUÇ ve ÖNERİLER

Yapay zeka yöntemleri ile buharlaşma tahmini yapmak, geleneksel yöntemlere kıyasla daha doğru ve etkili sonuçlar elde etmeyi mümkün kıldığından su kaynaklarının etkin yönetimi, tarımsal üretim, enerji üretimi ve iklim değişikliği gibi birçok alanda büyük önem taşır. Bu teknoloji, su kaynaklarının sürdürülebilir kullanımı ve gelecek nesillerin de su ihtiyaçlarının karşılanması için önemli bir araçtır. Yapay zeka algoritmaları, büyük miktarda veri ve karmaşık hesaplamalar kullanarak buharlaşma tahminlerini yapar. Bu sayede, meteorolojik koşullara, bölgenin özelliklerine ve diğer etkenlere göre daha yüksek doğruluk ve hassasiyetle tahminler yapabilirler.

Tüm analizlerde göz önüne alınan ölçütler olan determinasyon katsayısı ve hata oranlarına dayanarak, ANFİS modelinin SMRGT ve ÇDR modellerine kıyasla evapotranspirasyon tahminlerinde daha üstün sonuçlar sunduğu gözlemlenmiştir. ANFİS modeli, daha yüksek bir determinasyon katsayısı (0.9988) ve daha düşük hata oranı (MOH: 0.046mm, KKOH: 0.067mm) değerlerine sahip olmasıyla daha iyi bir performans sergilemiştir. Aynı şekilde, ÇDR modelinin daha yüksek determinasyon katsayısı ve daha düşük hata oranı değerlerine sahip olması, ÇDR modelinin SMRGT modeline göre daha uygun sonuçlar verdiğini göstermiştir. Bu durumun nedeni, evapotranspirasyonun sıcaklık, rüzgâr hızı, solar radyasyon ve bağıl nem gibi bağımsız değişkenlerle lineer bir ilişki içinde olmasıdır.

ANFİS yönteminin hidroloji bilimi için klasik yöntemlere alternatif olarak birçok tahmin çalışmasında kullanılabileceği görülmüştür. Doğal olayların karmaşıklığı, klasik yöntemlerin yetersiz kalabileceği belirsiz ve kesin olmayan durumlarda daha uygun ve etkili yöntemlere ihtiyaç duyulduğunu ortaya koymaktadır. ANFİS modeli, probleme kolay uyum sağlama yeteneği ve çıkış değerlerini hızlı bir şekilde elde etme avantajıyla buharlaşma tahminlerinde başarıyla kullanılabilecek bir yöntem olarak öne çıkmaktadır. Modellemenin farklı iklim şartlarına sahip bölgeler için de uyarlanabilir olması, elde edilen sonuçların genelleştirilmesi açısından büyük önem taşımaktadır.

KAYNAKLAR

- Arslan H., Tasar B., Unes F., Demirci M., Yılmaz A. Keban Baraj Gölü seviye değişiminin anfis ve destek vektör makineleri ile tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2020; 3(2): 71-77.
- Arunkumar, R., Jothiprakash, V., & Sharma, K. (2017). Artificial Intelligence Techniques For Predicting And Mapping Daily Pan Evaporation. *Journal Of The Institution Of Engineers (India): Series A*, 98(3), 219-231.
- Al-Jamimi, H. A., & Saleh, T. A. (2019). Transparent Predictive Modelling Of Catalytic Hydrodesulfurization Using An Interval Type-2 Fuzzy Logic. *Journal Of Cleaner Production*, 231, 1079-1088.
- Amani, S., & Shafizadeh-Moghadam, H. (2023). A review of machine learning models and influential factors for estimating evapotranspiration using remote sensing and ground-based data. *Agricultural Water Management*, 284, 108324.
- Ataseven, B. (2013). *Yapay Sinir Ağları İle Öngörü Modellemesi*
- Aydın, Y. (2019). Yarı Kurak İklim Koşullarında A Sınıfı Kap'tan Olan Buharlaşmanın Penman Ve Kohler-Nordenson-Fox (KNF) Modelleri İle Tahmini. *Turk J Agric Res*, 6(3), 319-327.
- Bai, Peng (2023). Comparison of remote sensing evapotranspiration models: Consistency, merits, and pitfalls. *Journal of Hydrology*, 617, 128856.
- Bayram, S., & Çıtakoğlu, H. (2023). Modeling monthly reference evapotranspiration process in Turkey: application of machine learning methods. *Environmental Monitoring and Assessment*, 195(1), 67.
- Bjarke, N., Barsugli, J., & Livneh, B. (2023). Ensemble of CMIP6 derived reference and potential evapotranspiration with radiative and advective components. *Scientific Data*, 10(1), 417.
- Chen D. Daily reference evapotranspiration estimation based on least squares support vector machines. *IFIP Advances in Information and Communication Technology* 2012; 369: 54-63.
- Chen Z., Zhu Z., Jiang H., Sun S., Estimating daily reference evapotranspiration based on limited meteorological data using deep learning and classical machine learning methods. *Journal of Hydrology* 2020; 591: 125286.
- Çodur, (2008). *Y. Sinirsel Bulanık Sistemler İle Trafik Gürültüsünün Tahmini*.

- Demirci M., Unes F., Kaya YZ., Tasar B., Varcin H. Modeling of dam reservoir volüme using adaptive neuro fuzzymethod. aerul si apa. Componente ale Mediului 2018; 145-152.
- Demirci M. Destek vektör makineleri ve m5 karar ağacı yöntemleri kullanılarak yağış akış ilişkisinin tahmini. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi 2019; 10(3): 1113-1124.
- Demirci, M., Unes, F., Kaya, Y. Z., Tasar, B., Varcin, H. (2018). Modeling Of Dam Reservoir Volume Using Adaptive Neuro Fuzzy Method. Aerul Si Apa. Componente Ale Mediului, 145-152.
- Demirel, S. , Kaya, Y. Z. , Taşar, B. , Üneş, F. & Demirci, M. (2023). Adana İli Referans Evapotranspirasyon Miktarının Bulanık Smrgt, Anfis ve Çoklu Doğrusal Regresyon Kullanılarak Tahmini . Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi , 6 (1) , 106-120.
- Di Nunno, F., & Granata, F. (2023). Future trends of reference evapotranspiration in Sicily based on CORDEX data and Machine Learning algorithms. Agricultural Water Management, 280, 108232.
- Doğan E., Sabahattin I., Sandalcı M. Günlük buharlaşmanın yapay sinir ağları kullanarak tahmin edilmesi. Teknik Dergi 2007; 18(87): 4119-4131.
- Doğan, E., Işık, S., & Sandalcı, M. (2007). Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi. İMO Teknik Dergi, 4119(4131), 271.
- Doğan, O. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (ANFİS) Talep Tahmini İçin Kullanımı Ve Bir Uygulama. Dokuz Eylül Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi 2016; 31(1).
- Gavili S., Sanikhani H., Kisi O., Mahmoudi MH. Evaluation of several soft computing methods in monthly evapotranspiration modelling. Meteorol. Appl. 2018; 25: 128-138.
- Gocić M., Motamedi S., Shamshirband S., Petković D., Ch S., Hashim R., Arif M. Soft computing approaches for forecasting reference evapotranspiration. Computers and Electronics in Agriculture 2015; 113: 164-173.
- Gumus V., Simsek O., Soydan NG., Akoz M. S., Yenigun K. Adana istasyonunda buharlaşmanın farklı yapay zeka yöntemleri ile tahmini. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi 2016; 7(2):309-318.
- Gümüş V., Yesiltas Y., Simsek O. Yapay zekâ yöntemleri ile Adıyaman ve Diyarbakır İstasyonlarının aylık tava buharlaşmalarının tahmin edilmesi. Türk Doğa ve Fen Dergisi 2021; 10(2): 112-122.
- Hofmann, G. S., Silva, R. C., Weber, E. J., Barbosa, A. A., Oliveira, L. F. B., Alves, R. J. V., & Cardoso, M. F. (2023). Changes in atmospheric circulation and

evapotranspiration are reducing rainfall in the Brazilian Cerrado. *Scientific Reports*, 13(1), 11236.

Güzel, H., Üneş, F., Erginer, M., Kaya, Y. Z., Taşar, B., Erginer, İ., & Demirci, M. (2023). A comparative study on daily evapotranspiration estimation by using various artificial intelligence techniques and traditional regression calculations. *Mathematical Biosciences and Engineering*, 20(6), 11328-11352.

Hou, P. S., Fadzil, L. M., Manickam, S., & Al-Shareeda, M. A. (2023). Vector Autoregression Model-Based Forecasting of Reference Evapotranspiration in Malaysia. *Sustainability*, 15(4), 3675.

İnternet: USGS. URL <https://www.usgs.gov/> Son Erişim Tarihi:19.05.2022

İnternet: MGM. URL <https://www.mgm.gov/> Son Erişim Tarihi:11.08.2023

Jang JS. ANFİS: Adaptive-network-based fuzzyinference system. *IEEE Transactions on Systems, Man, and Cybernetics* 1993; 23(3): 665-685.

Jensen ME., Burman RD., Allen RG. *Evapotranspiration and Irrigation Water Requirements*, American Society of Civil Engineers New York 1990.

Juttner, A., Szabó, I., ve Szentesi, A. (2003). On Bandwidth Efficiency Of The Hose Resource Management Model In Virtual Private Networks. *Twenty-Second Annual Joint Conference Of The IEEE Computer And Communications Societies*, 1, 386-395.

Kaya YZ., Mamak M., Unes F. Evapotranspiration prediction using M5T data mining method. *International Journal of Advanced Engineering Research and Science (IJAERS)* 2016; 12(3): 225-229.

Kaya YZ., Unes F., Mamak M. Estimating evapotranspiration using adaptive neuro fuzzy inference system and HargreavesSamani method. In: *Book of abstracts of the International Conference on Engineering* 2016.

Kaya YZ., Zelenakova, M., Üneş, F., Demirci, M., Hlavata, H., & Mesaros, P. (2021). Estimation of daily evapotranspiration in Košice City (Slovakia) using several soft computing techniques. *Theoretical and Applied Climatology*, 144, 287-298.

Kılınc I., İstanbul'daki baraj haznelerinin işletilmesinde yapay sinir ağları kullanılması. İstanbul Technical University, Institute of Science and Technology (Doctoral dissertation, Fen Bilimleri Enstitüsü) 2004.

Kumar M., Raghuwanshi NS., Singh R., Wallender WW., Pruitt WO. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering* 2002; 128(4): 224–233.

- Mostafa, R. R., Kisi, O., Adnan, R. M., Sadeghifar, T., & Kuriqi, A. (2023). Modeling potential evapotranspiration by improved machine learning methods using limited climatic data. *Water*, 15(3), 486.
- Özel, A., Büyükyıldız, M. (2019). Aylık buharlaşma tahmininde yapay zeka yöntemlerinin kullanılabilirliği. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 2019; 8(1): 244- 254.
- Shang, K., Yao, Y., Di, Z., Jia, K., Zhang, X., Fisher, J. B., ... & Zhang, L. (2023). Coupling physical constraints with machine learning for satellite-derived evapotranspiration of the Tibetan Plateau. *Remote Sensing of Environment*, 289, 113519.
- Shiri J., Kisi O. Comparison of genetic programming with neuro-fuzzy systems for predicting short- term water table depth fluctuations, *Computers & Geosciences* 2011; 37(10): 1692-1701.
- Sudheer, K. P., Gosain, A. K., Mohana Rangan, D., & Saheb, S. M. (2002). Modelling evaporation using an artificial neural network algorithm. *Hydrological Processes*, 16(16), 3189-3202.
- Rajput, J., Singh, M., Lal, K., Khanna, M., Sarangi, A., Mukherjee, J., & Singh, S. (2023). Performance evaluation of soft computing techniques for forecasting Daily reference evapotranspiration. *Journal of Water and Climate Change*, 14(1),350-368.
- Traore S., Wang YM., Kerh T. Artificial neural network for modeling reference evapotranspiration complex process in Sudano Sahelian zone. *Agricultural Water Management* 2010; 97: 707 714.
- Tasar B., Unes F., Demirci M., Kaya YZ. Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *DÜMF Mühendislik Dergisi* 2018; 9(1): 543-551.
- Toprak ZF. Flow discharge modeling in open canals using a new fuzzy modeling echnique (SMRGT). *CLEAN – Soil, Air, Water* 2009; 37(9): 742-752.
- Turhan E., Cagatay HO. Eksik akım verilerinin tahmin modelinin oluşturulmasında yapay sinir ağlarının kullanımı: Asi Nehri-Demirköprü akım gözlem istasyonu örneği. *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 2016; 31(1): 93-106.
- Turhan E. A comparative evaluation of the use of artificial neural networks for modeling the rainfall- runoff relationship in water resources management. *Journal of Ecological Engineering* 2021; 22(5): 166-178.
- Unes, F. Prediction Of Dam Reservoir Volume Fluctuations Using Adaptive Neuro Fuzzy Approach. *EJENS*, 2017,2(1), 144-148.

- Unes F., Demirci M., Tasar B., Kaya YZ., Varcin H. Estimating dam reservoir level fluctuations using data-driven techniques. *Polish Journal of Environmental Studies* 2019; 28(5): 3451-3462.
- Unes, F., Demirci M., Zelenakova M., Calisici M., Tasar B., Vranay F., Kaya YZ. River flow estimation using artificial intelligence and fuzzy techniques. *Water* 2020; 12(9): 2427.
- Yihdego Y., Webb JA. Comparison of evaporation rate on open water bodies: energy balance estimate versus measured pan. *Journal of Water and Climate Change* 2018; 9(1): 101-111.
- Yildirim, D., Cemek, B., & Küçüktopçu, E.(2019) Bulanık Yapay Sinir Ağları Ve Çok Katmanlı Yapay Sinir Ağları İle Günlük Buharlaştırma Tahmini. *Toprak Su Dergisi*, 24-31.
- Yildirim, D., Küçüktopcu, E., Cemek, B., & Simsek, H. (2023). Comparison of machine learning techniques and spatial distribution of daily reference evapotranspiration in Türkiye. *Applied Water Science*, 13(4), 107.
- Zadeh, LA. Fuzzy sets. *Information and Control* 1965; 8(3): 338-353.
- Zadeh, LA. Outline Of A New Approach To The Analysis Of Complex Systems And Decision Processes. *IEEE Transactions On Systems, Man, And Cybernetics* 1965; (1), 28-44.
- Zadeh, LA. The Concept Of A Linguistic Variable And Its Application To Approximate Reasoning—I. *Information Sciences* 1975; 8(3), 199-249.
- Zanetti SS., Sousa EF., Oliveira VPS., Almeida FT., Bernardo S. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering* 2007; 133(2): 83-8



TEKNOVERSİTE



teknoversite

İSTE

