

**T.C.
NUH NACİ YAZGAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**AYLIK BUHARLAŞMA MİKTARININ VE İLİŞKİLİ
VERİLERİNİN YZ İLE MODELLENMESİ VE
BUHARLAŞMA KAYIPLARININ AZALTILMASI**

**Hazırlayan
Merve DİNÇALP**

**Danışman
Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ**

**Nisan 2025
KAYSERİ**

**T.C.
NUH NACİ YAZGAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**AYLIK BUHARLAŞMA MİKTARININ VE İLİŞKİLİ
VERİLERİNİN YZ İLE MODELLENMESİ VE
BUHARLAŞMA KAYIPLARININ AZALTILMASI
(Yüksek Lisans Tezi)**

**Hazırlayan
Merve DİNÇALP**

**Danışman
Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ**

**Nisan 2025
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Merve DİNÇALP

İmza

YÖNERGEYE UYGUNLUK ONAYI

Aylık Buharlaşma Miktarının ve İlişkili Verilerinin YZ ile Modellenmesi ve Buharlaşma Kayıplarının Azaltılması adlı Yüksek Lisans tezi, Nuh Naci Yazgan Üniversitesi Lisansüstü Tez Yazım Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Merve DİNÇALP

İmza

Tez Danışmanı

Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ

İmza

KABUL VE ONAY SAYFASI

Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ danışmanlığında Merve DİNÇALP tarafından hazırlanan “Aylık Buharlaşma Miktarının ve İlişkili Verilerinin YZ ile Modellenmesi ve Buharlaşma Kayıplarının Azaltılması” adlı bu çalışma jürimiz tarafından Nuh Naci Yazgan Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalında **yüksek lisans tezi** olarak kabul edilmiştir.

..... / /

JÜRİ:

Danışman : Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ

Üye :

Üye :

ONAY:

Bu tezin kabulü Enstitü Kurulunun tarih vesayılı kararı ile onaylanmıştır.

..... /...../

Enstitü Müdürü

ÖNSÖZ / TEŞEKKÜR

Bana çalışmalarım süresince her türlü yardımı ve fedakârlığı sağlayan, hem bilgisi hem de mentorluğu ile yolumu aydınlatan, desteğini esirgemeyen danışmanım Sayın Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ'a teşekkür ederim. (Kayseri, 29/04/2025).

Merve DİNÇALP

İmza

XXXXXXXXXX

AYLIK BUHARLAŞMA MİKTARININ VE İLİŞKİLİ VERİLERİNİN YZ İLE MODELLENMESİ VE BUHARLAŞMA KAYIPLARININ AZALTILMASI

Merve DİNÇALP

Nuh Naci Yazgan Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Nisan 2025

Danışman: Dr. Öğr. Üyesi Şaban Suat ÖZSARIYILDIZ

ÖZET

Dünyaca kabul edilmiş iklim değişikliği raporlarının gösterdiği üzere su kıtlığı çok yakın zamanlarda kapımızı çalacaktır. Buna ek olarak artan nüfus yoğunluğu, değişen yaşam standartları gibi faktörler su kullanımında artışa sebep olmuştur. Ülkemiz için de geçerli olan bu iki unsur göz önüne alındığında su kaynaklarının en verimli şekilde kullanılması ve gözetilmesi günümüzde mecburi hale gelmiştir.

Bu çalışmada su kaynaklarının korunması kapsamında, su kaybına yol açan buharlaşma ve buharlaşmayı etkileyen faktörler incelenmiştir. Buharlaşma doğası gereği karmaşık, çok fazla parametreye bağlı bir yapı olduğu için tahmini oldukça zordur. Geleneksel buharlaşma hesaplama tahminleri lokasyon, mevsim, veri çeşidi ve sayısı, verilerin ölçüm kalitesi anlamında çoğunlukla eksik kalmaktadır. Son zamanlarda oldukça büyük gelişmeler kaydetmiş olan yapay zeka bu anlamda geleneksel buharlaşma hesaplama yöntemlerine kıyasla daha anlamlı sonuçlara ulaşmakta başarılıdır. Geleneksel buharlaşma yöntemlerinden seçilen formüller ve yapay zeka aracılığı ile oluşturulan modeller ham veri ve işlenmiş verilerle oluşturulmuş referans buharlaşma değerleri ile kıyaslanmıştır. Sonuç olarak yapay zeka ile oluşturulan modeller içinde en anlamlı sonuç ham veri için de işlenmiş veri için de Ensemble modelinde alınmıştır.

Anahtar Kelimeler: Yapay Zeka, Buharlaşma Tahmini, Modelleme, Veri Analizi

MODELING MONTHLY EVAPORATION AMOUNTS AND RELATED DATA USING AI AND REDUCING EVAPORATION LOSSES

Merve DİNÇALP

Nuh Naci Yazgan University, Graduate School of Sciences

Civil Engineering, Master of Science (M.Sc.) Thesis, April 2025

Supervisor: Assist. Prof. Şaban Suat ÖZSARIYILDIZ

ABSTRACT

As highlighted by internationally recognized climate change reports, water scarcity is expected to become an imminent global concern. In addition to this, factors such as increasing population density and changing living standards have led to a significant rise in water consumption. Considering that these two issues are also relevant to our country, the efficient utilization and monitoring of water resources has become an urgent necessity.

Within the scope of this study, factors causing water loss—specifically evaporation—and the parameters influencing it have been examined in the context of protecting water resources. Due to its inherently complex nature and dependence on numerous variables, evaporation is particularly difficult to estimate accurately. Traditional methods of estimating evaporation often fall short in terms of location specificity, seasonal variability, data type and quantity, as well as the quality of measurements. In recent years, artificial intelligence (AI), which has shown considerable advancements, has proven to outperform traditional estimation methods by producing more reliable and meaningful results. In this study, formulas selected from conventional evaporation estimation methods and models developed using AI were compared against reference evaporation values derived from both raw and processed data. Among the AI-based models, the Ensemble model provided the most meaningful results for both raw and processed data.

Keywords: Artificial Intelligence, Evaporation Estimation, Modeling, Data Analysis

İÇİNDEKİLER

AYLIK BUHARLAŞMA MİKTARININ VE İLİŞKİLİ VERİLERİNİN YZ İLE MODELLENMESİ VE BUHARLAŞMA KAYIPLARININ AZALTILMASI

YÖNERGEYE UYGUNLUK	iii
KABUL VE ONAY	iii
ÖNSÖZ / TEŞEKKÜR	v
ÖZET	vi
ABSTRACT.....	vii
İÇİNDEKİLER.....	viii
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ	xi

1.BÖLÜM: GİRİŞ

1.1. Tez konusu ve Önemi	3
--------------------------------	---

2.BÖLÜM: LİTERATÜR ANALİZİ

2.1. Daha Önceden Yapılan Çalışmalar	4
--	---

3.BÖLÜM: PROBLEMİN TANIMI

3.1. Temel Buharlaşma Hesaplama Yöntemleri	18
3.1.1. Tava Buharlaşması.....	18
3.1.2. Su Bütçesi Metodu	18
3.1.3. Enerji Bütçesi Metodu	20
3.1.4. Kütle Transfer Metodu	22
3.1.5 Aerodinamik ve Enerji Dengesi Metotlarının Kombinasyonu.....	22
3.2. Yapay Sinir Ağları.....	23
3.2.1. Avantajları	24
3.2.2. Dezavantajları.....	25

3.2.3. Yapay Sinir Ağı Hücresi	26
3.2.4. Yapay Sinir Ağlarının Sınıflandırılması	27

4.BÖLÜM: YÖNTEM

4.1. Geleneksel Buharlaşma Hesaplama Yöntemleri.....	31
4.2 Buharlaşmayı Önleme Yöntemleri.....	35
4.3 Veri Analizi.....	37
4.3.1. Veri Setine Uygulanan Ön İşlemler	48
4.3.2 Model Sonuçlarının İstatiksel Değerlendirilmesi ve Formülleri.....	55
4.3.3. Ham Veri ile Çalışılan Model Sonuçları	58
4.3.4. Ön İşleme Yapılan Veri ile Çalışılan Model Sonuçları	74

5.BÖLÜM: SONUÇLAR

SONUÇLAR.....	91
KAYNAKÇA	93
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

TABLÖLAR LİSTESİ

Tablo 1. Hava sıcaklığı verisi için aylık istatistiksel analiz.	42
Tablo 2. Özgöl nem verisi için aylık istatistiksel analiz.	43
Tablo 3. Rüzgar hızı verisi için aylık istatistiksel analiz.	44
Tablo 4. Net kısa dalga radyasyonu verisi için aylık istatistiksel analiz.	45
Tablo 5. Açık su yüzeyinden buharlaşma verisi için aylık istatistiksel analiz.	46
Tablo 6. Geleneksel buharlaşma hesaplama yöntemlerinin RMSE değerleri.	56
Tablo 7. Modellerin sonuç değerlerinin karşılaştırılması.	86



ŞEKİLLER LİSTESİ

Şekil 1. Hidrolojik çevrim.	1
Şekil 2. İleri beslemeli ağ yapısı.	7
Şekil 3. Ensemble modelinin oluşturulması.	10
Şekil 4. Kuraklık faktörleri.	12
Şekil 5. Buharlaşmayı etkileyen faktörler.	16
Şekil 6. Yapay sinir ağı hücresi.	27
Şekil 7. Yapay sinir ağlarının sınıflandırılması.	29
Şekil 8. Hava sıcaklığı verisi histogram ve dağılımı.	38
Şekil 9. Spesifik nem verisi histogram ve dağılımı.	39
Şekil 10. Rüzgar hızı verisi histogram ve dağılımı.	39
Şekil 11. Net kısa dalga radyasyonu verisi histogram ve dağılımı.	40
Şekil 12. Buharlaşma verisi histogram ve dağılımı.	41
Şekil 13. Verilerin coğrafi dağılımı.	41
Şekil 14. Değişkenlerin standart sapması.	48
Şekil 15. Hareketli ortalama.	49
Şekil 16. Hareketli standart sapma.	50
Şekil 17. Korelasyon matrisi.	51
Şekil 18. Değişkenlerin trend analizi.	52
Şekil 19. Değişkenlerin Z-Skor değerleri.	53
Şekil 20. Referans veri ile formül çıktılarının karşılaştırılması.	57
Şekil 21. Referans veri ile formül çıktılarının karşılaştırılması.	58
Şekil 22. Referans veri ile formül çıktılarının tekil karşılaştırılması.	58
Şekil 23. Gerçek değerler ile tahmin edilen değerler.	59
Şekil 24. Gerçek değerler ile artık değerler.	60
Şekil 25. Ensemble modelinin sonuçları.	61
Şekil 26. Gerçek değerler ile tahmin edilen değerler.	62
Şekil 28. Gerçek değerler ile artık değerler.	63
Şekil 29. Gaussian Process Regression modelinin sonuçları.	64
Şekil 30. Gerçek değerler ile tahmin edilen değerler.	65
Şekil 31. Gerçek değerler ile artık değerler.	66

Şekil 32. Linear Regression modelinin sonuçları.	67
Şekil 33. Gerçek değerler ile tahmin edilen değerler.....	68
Şekil 34. Gerçek değerler ile artık değerler.	69
Şekil 35. Tree modelinin sonuçları.	70
Şekil 36. Gerçek değerler ile tahmin edilen değerler.....	71
Şekil 37. Gerçek değerler ile artık değerler.	72
Şekil 38. Neural Network modelinin sonuçları.	73
Şekil 39. Ensemble modelinin sonuçları.....	75
Şekil 40. Gerçek değerler ile tahmin edilen değerler.....	76
Şekil 41. Gerçek değerler ile artık değerler.	77
Şekil 42. Linear Regression modelinin sonuçları.	78
Şekil 43. Gerçek değerler ile tahmin edilen değerler.....	79
Şekil 44. Gerçek değerler ile artık değerler.	80
Şekil 45. Tree modelinin sonuçları.	81
Şekil 46. Gerçek değerler ile tahmin edilen değerler.....	82
Şekil 47. Gerçek değerler ile artık değerler.	83
Şekil 48. Neural Network modelinin sonuçları.	84
Şekil 49. Gerçek değerler ile tahmin edilen değerler.....	85
Şekil 50. Gerçek değerler ile artık değerler.	86
Şekil 51. Ham veri modelleri RMSE değerleri.....	89
Şekil 52. İşlenmiş veri modelleri RMSE değerleri.	90

1. BÖLÜM: GİRİŞ

Su, doğada birçok çeşitli alanda farklı formlarda (katı, sıvı, gaz) bulunur ve bu formlar arasında sürekli bir geçiş gerçekleşir. Su atmosferden yeryüzüne yağmur, kar gibi meteorolojik olaylarla transfer edilir. Yeryüzündeki su ise buharlaşma, terleme gibi yollarla yeniden atmosfere döner. Devamlı olarak gerçekleşen bu geçiş olaylarının tümüne hidrolojik çevrim (su döngüsü) adı verilir. Atmosferden düşen yağışın çok büyük bir kısmı buharlaşma, bitkiler tarafından tutulma ve yine bitki yüzeyinden terleme yoluyla kaybedilir. Bu kayıplar iklim koşullarının aleyhte değiştiği günümüzde özellikle kurak iklimlerde oldukça önemlidir.



Şekil 1. Hidrolojik çevrim.

Kaynak: (Web Sayfası: <https://www.mgm.gov.tr/genel/hidrometeoroloji.aspx?s=4>) (Erişim Tarihi: Kasım 2024)

Buharlaşma, açık su yüzeylerinden, bitki örtüsü ile kaplı olmayan toprak yüzeylerden, bitki yüzeylerinden suyun sıvı halden gaz haline geçerek hidrolojik çevrime katılmasıdır. Hidrolojide kullanılan buharlaşma terimi, herhangi bir yüzeyle atmosfer arasında devamlı olarak su molekülü transferi gerçekleştiği için sadece net buharlaşma miktarını ifade etmekte kullanılır. Buharlaşma kayıpları bütün su kaynakları çalışmalarında büyük önem

taşıır. Haznelerin kapasiteleri, baraj işletme çalışmaları, tarımsal sulama ihtiyaçları, su kaynaklarında verim gibi birçok konu buharlaşma kayıplarından oldukça etkilenir.

Dünyanın dörtte üçünün sularla kaplı olmasına karşın, artan nüfus, değişen yaşam koşulları gibi sebeplerle artan su ihtiyacı ve iklim koşullarının kötüleşmesiyle kaybedilen veya kirlenme sebebiyle kullanılamayan su miktarı göz önüne alındığında su kıtlığının oldukça yakın zamanlarda yaşam şartlarımızı etkilemesi beklenmektedir. Bu şartlar altında buharlaşma kayıplarının hesaplanması ve önlenmesi ülkemiz kaynaklarının korunması ve verimli kullanılması açısından büyük önem taşımaktadır.

Buharlaşmanın doğası gereği birçok faktöre bağlı olması, buharlaşmayı karmaşık bir yapı haline getirir. Geçmişten günümüze birçok bilim insanı buharlaşmayı doğru hesaplamak için incelemelerde bulunmuş ve formüller geliştirmiştir. Geliştirilen formüllerin birçoğu oldukça kapsamlı olsa da verilerin elde edilmesinin zorluğu ve veri ölçüm sürecinin hataya çok açık olması, buharlaşmanın değişen iklim koşulları, konum ve mevsimlere göre büyük değişiklikler göstermesi gibi problemler hesaplamalarla elde edilen sonuçların anlamlı olma olasılığını azaltmaktadır. Öte yandan yakın gelecekteki su krizi karşısında hazırlıklı olmak ve ülkemizin doğal kaynaklarını akılcı kullanmak ve korumak için bu alanda çalışmalar yapmak oldukça önem taşımaktadır.

Günümüzde gelişen teknolojiyle özellikle son zamanlarda sıkça konuşulan yapay zeka uygulamalarının hidroloji alanında uygulanabilirliği söz konusu olmuştur. Yapay zeka bu aşamada, buharlaşmanın yapısını inceleme ve anlamada, buharlaşmayı etkileyen faktörlerin ağırlıklarını anlamlandırmakta ve doğru modellemelerle geleceğe dair gerçeğe yakın ve anlamlı tahminler yapmakta oldukça başarılı olduğu kanıtlanmış bir araçtır. Buharlaşmayı etkilen faktörler arasında bulunan nem, sıcaklık, radyasyon, rüzgar gibi verilerin konum ve mevsimden çok fazla etkilendiği bilinmektedir. Bu verilerin eksiksiz ve doğru biçimde kayıt altına alınması ve düzenlenmesi sonuçların anlamlı olması açısından oldukça önemlidir. Bu aşamada yapay zekanın büyük veri setlerindeki verileri bazı işlemlere tabii tutarak uç değerlerden arındırması, verileri daha düzenli hale getirmesi, yanlış ve/veya eksik verilerin çıkarılması veya çeşitli yöntemlerle doldurulması gibi adımlarla buharlaşma alanındaki çalışmalarda büyük fayda sağlaması beklenmektedir.

1.1 Tez konusu ve Önemi

Bu çalışmada bir yapay zeka aracı olan Matlab programı kullanılarak buharlaşma üzerinde etkisi olan veriler incelenecek ve buharlaşma hesabı hem geleneksel yöntemlerle hem de yapay zeka yöntemleriyle yapılacak ayrıca yapay zeka aracılığı ile geleceğe dair anlamlı tahminler yapılmaya çalışılacaktır. Ayrıca giderek önem kazanan ve iklim değişikliği sebebiyle her geçen gün daha kritik hale su seviyelerinin korunması, su seviyesinin değişiminde en büyük etkilerden biri olan buharlaşma kayıplarının bir kısmının önüne geçilebilmesi için açık su yüzeylerinin belirli ölçülerde kapatılması durumunda buharlaşmada oluşacak değişimin teorik olarak incelenmesi amaçlanmaktadır. Ülkemiz sınırları içerisinde bulunan doğal ve yapay göletlerin ve diğer su kaynaklarının değişen iklim koşullarından korunması, su seviyesinin kritik seviye altına düşmemesinin sağlanması açısından bu çalışma önem taşımaktadır. Yapılan teorik gözlem ile su kaynaklarının etkin biçimde kullanılması ve korunması, kaynaklar bakımından oldukça zengin olan ülkemizin etkisini hissettirmeye başlayan iklim değişikliğine karşı savunulması hedeflenmiştir. Önümüzdeki yıllar için beklenen iklim verilerinin ışığında buharlaşma ve dolayısıyla su seviyelerinin tahmin edilebilmesi, açık su yüzeylerinin belirli kısımlarının kapatılması ve kapatılan yüzey alanlarını azaltarak veya artırarak en etkin ve uygulanabilir biçimde buharlaşma kayıplarının hangi oranlarda azaltılabileceği yapay zeka ile matematiksel olarak belirlenmesini sağlayacaktır.

2. BÖLÜM: LİTERATÜR ANALİZİ

2.1. Daha Önceden Yapılan Çalışmalar

Yapılan bir çalışmada Namazgah Barajına ait buharlaşma miktarını tahmin etmek için yapay sinir ağı yöntemini kullanmıştır. Öncelikle eksik veriler İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağı modeliyle tamamlanmış, tamamlanan verilerin %70' eğitim, %15'i onaylama ve %15'i test verisi olarak kullanılmıştır. İkinci aşamada ise minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti, buhar basıncı girdi verisi olarak tanımlanıp çıktı olarak buharlaşma seçilmiştir. Girdi ve çıktı olarak kullanılan veriler arasındaki ilişki doğrusal olmadığı için çok katmanlı bir ağ modeli seçilmiştir. Çok katmanlı ağ için kullanılacak öğrenme algoritmasının seçilmesi aşamasında üç algoritma denenmiş ve en iyi sonucu Levenberg-Marquardt (LM) öğrenme algoritması vermiştir. Alınan sonuçlara dayanarak hidrolojik çevrim problemlerinde LM öğrenme algoritmasının özellikle zaman serisi analizlerinde rahatlıkla kullanılabileceği görülmüştür [1].

Yapay Sinir Ağları Metotları ile Klasik Hesaplama yöntemlerinin kıyaslandığı bu çalışmada, Klasik yöntemler için referans metot olarak Penman-Monteith metodu seçilmiştir. Seçilen hesaplama sistemlerine girdi olarak ortalama, en yüksek ve en düşük hava sıcaklığı, rüzgar hızı, güneşlenme süresi ve bağıl nem verilmiş çıktı olarak ise buharlaşma değeri seçilmiştir. Diğer klasik hesaplama yöntemleri ile YSA tabanlı hesaplama yöntemleri kıyaslandığında buharlaşma tahmininde YSA tabanlı Çoklu Doğrusal Regresyon, Radyal Tabanlı YSA metotlarının sonuçlarının daha başarılı olduğu sonucuna varmıştır [2].

Penman-Monteith denklemini standart kabul edilip, çalışma alanı olan ABD Teksas'ta bulunan Lewisville gölüne ait 2008-2012 yılları arasındaki verileri kullanarak buharlaşma miktarını ampirik denklemler ve Yapay Sinir Ağları metotları ile tahmin etmiştir. Girdi olarak tanımlanan hava sıcaklığı, rüzgar hızı, güneş ışıınımı, ve bağıl nem verileri ile Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS), M5 Karar Ağacı (M5T), Çoklu Lineer Regresyon (ÇLR) yöntemleri ve Turc ampirik denklemine verilmiş, çıktı değeri olarak buharlaşma verisi tanımlanmıştır. Turc ampirik denkleminin tek başına kullanımında yetersiz olduğu, bulanık mantık ve yapay sinir ağları metotlarının birleşimi olan metotların daha anlamlı olduğu kanısına varılmıştır [3].

Atatürk Barajı'na ait 2016-2018 yılları arası minimum sıcaklık, maksimum sıcaklık, ortalama sıcaklık, güneş radyasyonu, bağıl nem ve rüzgar hızı verilerini girdi olarak kullanmış ve sonuçları gerçek buharlaşma değerleri ile kıyaslanmıştır. Farklı kombinasyonların denenmesi sonucunda performansı en yüksek modelin maksimum ve minimum değerlerin de girdi olarak tanımlandığı model olduğu görülmüş ve buna dayanarak ortalama değerlerden ziyade kurulan sisteme maksimum ve minimum değerlerin de veri olarak girilmesi tavsiye edilmiştir. Ayrıca modellerin kendi aralarında kıyaslanmasıyla buharlaşmayı en çok etkileyen faktörün sıcaklık olduğu belirtilmiştir [4].

Yüzer fotovoltaiik paneller ile su yüzeyinin kapatılması suretiyle buharlaşmanın azaltılması yönünde incelemeler yapılmıştır. Biri açık biri fotovoltaiik panelle bir kısmı kapalı olacak şekilde ayarlanmış iki adet buharlaşma tavaşı otuz gün boyunca incelenmiştir. Fotovoltaiik panelle kapatılmış olan buharlaşma tavasının otuz günlük toplam buharlaşma kaybı 38.7mm iken açık tava buharlaşması toplam 94.9mm olarak ölçülmüştür. Panel yardımıyla buharlaşma önemli ölçüde azaltılmıştır fakat çalışma sonunda su kaliteleri kontrol edildiğinde panelle kısmi olarak kapatılmış tavadaki su kalitesinin tamamen bozulduğu gözlemlenmiştir [5].

Youssef ve Khodzinskaya çalışmasında buharlaşmayı azaltmak için kullanılan teknikleri incelemiştir. Açık su yüzeyinden buharlaşmayı azaltarak su tasarrufu sağlamak için kullanılan yüzen veya asılı örtülerin kullanılması, kimyasal birtakım maddelerin su yüzeyinde film şeklinde bir tabaka oluşturarak su buharı kaybını azaltması, rüzgar kırıcılar, yüzen bitkiler gibi yöntemler buharlaşma hacminde büyük ölçüde fayda sağlayabilmektedir. Buharlaşmayı azaltmada fiziksel yöntemler %70-95 aralığında faydalı olurken kimyasal yöntemler %20-40 aralığında fayda sağlamaktadır. Bu yöntemlerin her biri uygulama açısından bakıldığında farklı avantaj ve dezavantajlara sahiptir [6].

Yapılan bir çalışmada küresel ölçekte toplam 7242 büyük rezervuarın 1985-2016 yılları arasındaki buharlaşmaları tahmin edilmiştir. Tüm rezervuarların yıllık ortalama buharlaşma hacmi 339,8 km^3 olarak hesaplanmıştır. Bu buharlaşma hacminde en büyük paya Amerika Birleşik Devletleri ve Kanada sahiptir. Ayrıca bu hesaplamalar 1985

yılından 2016 yılına kadar buharlaşma hacminde yılda 2 km^3 'lük önemli bir artış olduğunu göstermiştir. Elde edilen sonuçlarla rezervuarların düzenlenmesi ve işletilmesine, küresel su koruma ve yönetimine katkı sağlamak amaçlanmış, artan buharlaşma miktarına dikkat çekilmiştir [7].


ABD'de bulunan İllinois eyaletindeki üç hava istasyonundan elde edilen 2005-2008 yıllarına ait hava sıcaklığı, güneş radyasyonu, rüzgar hızı, bağıl nem, yüzey toprak sıcaklığı ve toplam yağış verileri, buharlaşmanın tahmini için yapay sinir ağları (YSA) ve ANFIS modelleriyle analiz edilmiştir. Tüm parametrelerin giriş verisi olarak kullanıldığı model, incelenen üç istasyonda da en iyi performansı göstermiştir. Güneş radyasyonunun hariç tutulduğu kombinasyon ise ikinci en iyi sonuçları sağlamıştır. Çalışma sonucunda, YSA modellerinin kabul edilebilir doğrulukta tahminler yaptığı, ancak ANFIS modellerinin daha başarılı olduğu tespit edilmiştir [8].

Hindistan'ın Maharashtra eyaletindeki Nathsagar rezervuarı (Jayakwadi Barajı) için buharlaşma tahmini, iklimsel veriler kullanılarak yapay sinir ağları yöntemiyle gerçekleştirilmiştir. Çalışmada, 2000-2006 yılları arasındaki maksimum ve minimum sıcaklık, rüzgar hızı, güneşlenme süresi ve bağıl nem verileri analiz edilerek, her bir değişkenin buharlaşmaya etkisi değerlendirilmiştir. Sonuçlara göre, buharlaşmayı en çok etkileyen parametreler sırasıyla maksimum sıcaklık, bağıl nem, güneşlenme süresi, minimum sıcaklık ve rüzgar hızı olarak belirlenmiştir. Daha sonra, 4 farklı kombinasyon kullanılarak ileri beslemeli geri yayımlı yapay sinir ağı modeliyle buharlaşma tahmini yapılmıştır. Tahmin sonuçlarında en iyi performansı, rüzgar hızının dahil edilmediği kombinasyon göstermiştir. Bununla birlikte, yalnızca maksimum sıcaklık ve bağıl nemin giriş olarak kullanıldığı kombinasyon, çok küçük bir farkla ikinci en iyi sonucu vermiş ve verilerin sınırlı olduğu durumlarda etkili bir alternatif sunabileceği gösterilmiştir [9].

Yeni Delhi'de günlük tava buharlaşma tahmini için maksimum ve minimum hava sıcaklığı, güneşlenme süresi, rüzgar hızı ve bağıl nem parametreleri kullanılarak farklı yöntemlerle buharlaşma değerleri tahmin edilmiştir. Yapay Sinir Ağları (YSA), istatistiksel regresyon ve iklim esaslı modeller (Penman, Priestley-Taylor ve Stephens-Stewart) karşılaştırmalı olarak değerlendirilmiştir. Tahmin süreçlerinde, YSA ve regresyon modellerinin eğitimi için 1096 günlük veri, testi için ise 365 günlük veri

kullanılmıştır. Sonuçlar, YSA ile tahmin edilen tava buharlaşma değerlerinin diğer yöntemlere kıyasla biraz daha başarılı olduğunu göstermiştir [10].

Sapanca Gölü'ne ait günlük buharlaşmayı tahmin etmek amacıyla iki farklı Yapay Sinir Ağı (YSA) yöntemi kullanılmıştır. İleri Beslemeli Geri Yayınımlı (İBGYSA) ve Radyal Temelli Yapay Sinir Ağı (RTYSA) modelleri, klasik Penman-Monteith (PM) modeliyle karşılaştırılmıştır. Girdi parametresi olarak maksimum güneşlenme süresi, gerçek güneşlenme süresi, bağıl nem, rüzgar hızı, minimum ve maksimum sıcaklık verileri değerlendirilmiştir. Çalışmanın sonuçlarına göre, İBGYSA yönteminin diğer yöntemlere kıyasla daha başarılı buharlaşma tahminleri yaptığı görülmüştür [11].



Şekil 2. İleri beslemeli ağ yapısı.

Konya Kapalı Havzası'nda bulunan Karaman meteoroloji istasyonuna ait aylık toplam açık yüzey buharlaşma miktarının tahmini için; 1967-2010 yılları arasındaki aylık toplam yağış, ortalama, maksimum ve minimum sıcaklık, rüzgar hızı, nispi nem, buhar basıncı, atmosferik basınç verileri eşliğinde 4 çeşit YSA algoritması ve 2 çeşit yapay zeka metodu kullanılmıştır. Kullanılan modellerin başarısı giriş kombinasyonlarına göre değişiklik göstermektedir [12].

Küresel olarak rezervuarlardan buharlaşma kayıplarının, rezervuardan toplam tüketimden daha fazla olduğu tahmin edilmektedir. Amerika Birleşik Devletleri'nde 721 rezervuar üzerinde yapılan çalışmada uzun vadeli yıllık ortalama buharlaşma değerinin neredeyse yıllık kamu su arzına eşdeğer olduğu görülmüştür. Yapılan çalışmada hem modelleme teknikleri hem de uzaktan algılama yöntemleri kullanılmıştır. Modelleme de Penman Denklemi kullanılmıştır [13].

Türkiye'deki tatlı su gölleri ve rezervuarların yüzeylerinden buharlaşma ile kaybolan su miktarını tahmin etmek ve bunu Türkiye'nin temin edilen su miktarıyla karşılaştırmak için yapılan bu çalışma kapsamında, 129 göl ve 223 rezervuar buharlaşma tahminlerine tabi tutulmuştur. Göllerin toplam yüzey alanı 3213.97 km², rezervuarların ise 4026.16 km² olarak hesaplanmıştır. Sonuçlara göre, göl ve rezervuar yüzeylerinden yıllık toplam buharlaşma kaybı yaklaşık olarak 6.8×10^9 m³ olup, bu kaybın 2.7×10^9 m³'ü göllerden ve 4.1×10^9 m³'ü rezervuarlardan gerçekleşmektedir. Bu miktar, 1999 yılında Türkiye'nin yeraltı suyu kaynaklarından karşılanan toplam su tüketimini ve içme (5.7×10^9 m³) ve sanayi (4×10^9 m³) su kullanımını aşmaktadır [14].

Hollanda da bulunan 1100 km²'lik bir göl üzerinde yapılan bir çalışmada buharlaşmayı etkileyen faktörlerin etkilerine bakılmıştır. 2019 ve 2020 yıllarının yaz sezonlarında çalışma alanında veriler toplanmış ve incelenmiştir. Sonuçlar, yaz dönemlerinde küresel radyasyonun buharlaşma üzerinde doğrudan bir etkisinin olmadığını, ancak rüzgar hızı ve dikey buhar basıncı gradyanının açık su buharlaşmasının değişkenliğini açıklamada önemli rol oynadığını göstermiştir. Ancak yıllık bir veri seti incelendiğinde radyasyonun belirgin bir etkisinin olduğu görülmüştür. Penman buharlaşma formülü yıllık buharlaşma döngüsünü doğru bir şekilde temsil ederken, günlük ölçekte gözlemlerle uyumsuz olmuştur [15].

Buharlaşmanın doğru tahmini, özellikle meteorolojik istasyonların yerinde ölçümler için uygun şekilde sürdürülemediği ve işletilemediği Irak gibi gelişmekte olan ülkelerde, su kaynakları mühendisliği uygulamaları açısından büyük önem taşımaktadır. Bu çalışmada, Irak'ın kurak ve yarı kurak bölgelerinde yer alan iki farklı meteoroloji istasyonunda buharlaşma tahmini yapılmıştır. Buharlaşma tahmini için CAST, CCNN, GEP ve SVM olmak üzere 4 farklı model geliştirilmiştir ve bu modellerde meteorolojik değişkenlerin

farklı kombinasyonları girdi olarak kullanılmıştır. Sonuçlar, en iyi tahminlerin güneşlenme süresi, rüzgar hızı, bağıl nem, yağış miktarı ile minimum, ortalama ve maksimum sıcaklıkların bir arada kullanılmasıyla elde edildiğini göstermektedir [16].

Bu çalışma moleköl dinamiği simölasyonu ve literatürden elde edilen veri setleri kullanarak yapılmıştır. Veriler; yükseklik, çap, yükseklik-yarıçap oranı, buharlaşma verimliliği ve buharlaşma hızı gibi parametreleri içermektedir. İlk olarak, dört giriş parametresi ile buharlaşma hızı arasındaki ilişki, geleneksel çift değişkenli grafikler ve Pearson korelasyon analizi kullanılarak incelenmiş ve zayıf korelasyonlar gözlemlenmiştir. Daha sonra, yapay sinir ağı ve modelleri kullanılarak buharlaşma hızı tahmin modelleri oluşturulmuş ve iki modelin doğruluk ve genelleme performansları karşılaştırılmıştır. Modeller rastgele veri seçimi yöntemiyle de doğrulanmış ve üstün performans sergilemiştir. Ayrıca, farklı oranlardaki (%10, %20 ve %30) test setlerinin model performansı üzerindeki etkisi araştırılmış ve test setinin %20 olduğu durumlarda model performansının daha iyi olduğu, tüm modellerin bu durumda yakınsadığı görülmüştür. Buharlaşma hızı tahmin modellerinin ortalama mutlak hata ve ortalama kare hata değerleri hesaplanarak performansları değerlendirilmiştir [17].

Three Gorges Rezervuarında su yüzeyinden buharlaşmanın tahmini için Ensemble modelinin kullanılması ve iyileştirilmesi araştırılmıştır. Bu hedefe ulaşmak için öncelikle model girdilerinin en etkili olanlarını belirlemek üzere bir duyarlılık analizi gerçekleştirilmiştir. Sonuçlar, baskın parametrelerin su yüzeyi sıcaklığı, su yüzeyi alanı, bağıl nem, buharın sıcaklık farkı ve rüzgar hızı olduğunu göstermiştir. Aynı zamanda ampirik modeller, istatistiksel modeller ve yapay zeka modelleri de kıyaslanmıştır. Ampirik ve istatistiksel modeller anlamlı sonuçlar üretmiş fakat yapay zeka modellerinde genellikle aşırı öğrenme problemleriyle karşılaşmıştır [18].




Şekil 3. Ensemble modelinin oluşturulması.

Kaynak: (Web Sayfası: <https://ch.mathworks.com/help/stats/framework-for-ensemble-learning.html>)
(Erişim Tarihi: Ocak 2025)

Kuzeybatı Ontario, Kanada'daki iki klimatolojik istasyonda (Rawson Lake ve Atikokan) yapılan bir çalışmada, yedi farklı sıcaklık temelli buharlaşma denklemi karşılaştırılmıştır. Bu denklemler, önce orijinal sabit değerlerle, ardından yeniden kalibre edilmiş sabit değerlerle değerlendirilmiştir. Sonuçlar, orijinal sabit değerler kullanıldığında denklemlerin çoğunun belirgin önyargılara sahip olduğunu göstermiştir. Ancak, sabit değerlerin yeniden kalibre edilmesiyle, denklemlerin altısı her iki istasyonda da daha iyi performans sergilemiştir. Yerel olarak kalibre edilmiş parametrelerle, tüm denklemlerin mevsimsel ortalama buharlaşma değerlerini belirlemede başarılı olduğu görülmüştür. Aylık bazda, değiştirilmiş Blaney-Criddle yöntemi en düşük hata oranını sağlarken, Hargreaves ve Thornthwaite yöntemleri bu yöntemi takip etmiştir. Buna karşılık, Linacre, Kharrufa ve Hamon yöntemleri, özellikle Eylül ayında belirgin bir önyargı sergilemiştir. Bu bağlamda, sıcaklık temelli yöntemler arasında, doğru şekilde belirlenmiş sabit değerlerle Blaney-Criddle, Hargreaves ve Thornthwaite yöntemlerinin buharlaşma tahmini için uygun olduğu sonucuna varılmıştır [19].

Kuraklık, tarım, ekosistem, su kaynakları ve sosyo-ekonomik sistemler üzerinde geniş kapsamlı etkilere sahip, maliyetli bir doğal afettir. Su döngüsü boyunca yayılan kuraklık, farklı türlere dönüşerek hem doğal sistemleri hem de insan toplumlarını etkiler.

Meteorolojik kuraklıktan diğer kuraklık türlerine (örneğin, tarımsal, hidrolojik ve ekolojik kuraklık) geçiş süreci, çeşitli göstergeler, veri kaynakları ve temel bulgular ışığında incelenmiştir. Bu süreçte kuraklık yayılımının tepki süresi ve gecikme zamanı gibi temel özellikleri ile iklim (kuraklık, mevsimsellik, meteorolojik değişkenlerdeki anomaliler), havza özellikleri (eğim, rakım, arazi örtüsü, akifer ve taban akışı) ve insan faaliyetleri (baraj işletimi, su aktarımı, sulama, yeraltı suyu kullanımı) gibi kontrol edici faktörler önemli rol oynamaktadır. Kuraklık yayılımını inceleyen çalışmalarda, kullanılan göstergeler arasındaki farklılıklar, yayılım sürecinin tam olarak karakterize edilememesi ve etkileyen faktörlerin ayrıştırılmasındaki zorluklar temel sorunlar arasında yer almaktadır. Gelecekteki çalışmaların, tek bir gösterge yerine çoklu göstergelere, bireysel faktörler yerine birleşik faktörlere, tek yönlü analizler yerine geri bildirim ilişkilerine ve durağan varsayımlar yerine değişken koşullara odaklanması gerektiği vurgulanmaktadır. Bu bağlamda, kuraklık yayılım süreçlerini anlamaya yönelik kapsamlı incelemeler, küresel ısınmanın etkileri altında farklı bölgelerde kuraklık tahmini ve yönetimi için değerli bilgiler sağlayabilir [20].



Şekil 4. Kuraklık faktörleri.

Kaynak: (Zhang, X., Hao, Z., Singh, V.P., Zhang, Y., Feng, S., Xu, Y., Hao, F., 2022, Drought propagation under global warming: Characteristics, approaches, processes, and controlling factors, **Science of The Total Environment** (838,2))

Rezervuarlar ve su kaynaklarının verimli yönetimi için buharlaşma oranlarının belirlenmesi büyük önem taşımaktadır. Özellikle su kıtlığı yaşayan ülkelerde, buharlaşma kaynaklı su kayıpları kritik bir sorun olarak öne çıkmaktadır. Avustralya'daki açık su rezervuarlarının, toplam su depolama kapasitelerinin yaklaşık %40'ını her yıl buharlaşma yoluyla kaybettiği tahmin edilmektedir. Değişen iklim koşulları, bu kayıpların gelecekte nasıl etkileneceğine dair çalışmaların önemini artırmıştır. Güneydoğu Queensland'deki (SEQ) büyük bir su rezervuarında yapılan modelleme çalışmasında, mevcut ve öngörülen iklim koşullarında buharlaşma oranları analiz edilmiştir. Araştırmada, dokuz küresel iklim modelinden elde edilen günlük meteorolojik projeksiyonlar DYRESM modeli

kullanılarak deęerlendirilmiřtir. 2030–2050 ve 2070–2090 yılları arasındaki iki ayrı 20 yıllık dönem için simülasyonlar gerekleřtirilmiřtir. Bu simülasyonlardan elde edilen buharlařma oranları ve su sıcaklıkları, 1990–2010 yılları arasındaki gözlemsel meteorolojik veriler kullanılarak modellenen deęerlerle karřılařtırılmıřtır. Sonular, gelecekte buharlařma oranlarında artış olacaęını göstermiřtir. 2040 yılı civarında yıllık buharlařma oranlarının, mevcut iklimdeki 20 yıllık ortalamaya göre %8 daha yüksek olacaęı öngörölmektedir. 2070–2090 döneminde ise bu artışın %15’e kadar ıkması beklenmektedir. Bu artışın temel nedeni, yüzey hava sıcaklıklarındaki yükseliř olarak belirtilmiřtir. Modellenen verilere göre, yıllık ortalama yüzey hava sıcaklıęı 20.4 °C’den 2030–2050 döneminde 21.5 °C’ye, 2070–2090 döneminde ise 23.2 °C’ye ulařacaktır. Bunun sonucunda, rezervuarın yüzey suyu sıcaklıklarının sırasıyla 0.9 °C ve 1.7 °C artması beklenmektedir. Özellikle ilkbahar ve yaz aylarında bu sıcaklık artışlarının daha belirgin olması, buharlařma oranlarında önemli bir artışa yol açacaktır [21].

3. BÖLÜM: PROBLEMİN TANIMI

Depolama rezervuarları (baraj, gölet vs.) genellikle çok büyük su kütleleridir ve geniş su yüzeylerini buharlaşmaya maruz bırakır dolayısıyla önemli bir su kaynağı kaybına yol açar. Ancak çok yoğun yağış alan bazı bölgelerde de sel sularını geniş taşkın alanlarına yaymak dolayısıyla can ve mal kaybına yol açmak yerine derin depolarda toplayarak doğal buharlaşmayı azaltabilirler.

Büyük su kütlelerinden (baraj, gölet, deniz vs.) buharlaşma devamlı olarak gerçekleşir. Sıvı su molekülleri sürekli olarak hareket ederler ve buna Brownian hareketi denir. Bu hareket sırasında gelen fazladan ısı, su moleküllerini birlikte tutan çekim kuvvetlerini zayıflatır dolayısıyla moleküller daha hızlı hareket eder ve birbirlerinden uzaklaşmaya başlarlar. Yeterli sıcaklıkla yüzeyde sıvı halde bulunan su moleküllerinin kinetik enerjisi yükselir böylece gaz formuna dönüşüp atmosfere katılırlar. Bitki yüzeylerinden gerçekleşen buharlaşma ise açık su yüzeylerinden gerçekleşen buharlaşmaya kıyasla nispeten daha azdır. Dalton Kanunu'na göre buharlaşma, suyun hemen üstündeki doymuş buhar basıncıyla (e_s) daha üstteki havanın gerçek buhar basıncı (e_a) arasındaki fark ile ilişkilidir ($e_s - e_a$). Su sıcaklığı arttığında moleküllerin hareketleri hızlanır, buharlaşma gerilimi azalır ve buharlaşma kolaylaşır. Ancak, buharlaşan suyun su yüzeyinden uzaklaşmaması durumunda, havanın doymun hale gelmesiyle buharlaşma durabilir ($e_s - e_a \leq 0$). Buharlaşmanın devam etmesi için difüzyon ve konveksiyon ile su buharının su yüzeyinden uzaklaşması gerekmektedir. Bu süreçte havanın hareketi ve rüzgar önemli bir rol oynar. Rüzgarlar yatay doğrultuda iletimin yanında düşey doğrultuda türbülanslı difüzyon ile su buharının dağılımını artırdıklarından buharlaşmanın sürekliliğine sebep olmaktadır [22].

Buharlaşma (evaporation) sadece su yüzeyinden gerçekleşen kaybı temsil eden bir terimdir. Buna ek olarak havzalarda bitki örtüsü de bulunduğu için bu bitkilerden terleme gerçekleşir ve su buharı atmosfere geri döner. Bu olaya buharlaşma ve terleme (evaporation) denir. Buharlaşma ve terleme su yüzeyinden gerçekleşen buharlaşmadan farklı olarak bitki büyümesi aracılığı ile gerçekleşir ve bu durum mevsimsel etkenlerden, bitki örtüsü çeşitliliğinden etkilenir. Bitki örtüsü ile kaplı bir alanda yeterli su kaynağı her daim bulunduğu anda gerçekleşen buharlaşma ve terleme işe potansiyel buharlaşma ve terleme (PET/Potential Evaporation) olarak tanımlanır. Bu terim, bitkilere ideal bir su

kaynağı sağlandığını ifade eder. Bitkilere sağlanan su miktarı PET'ten az olduğunda, eksik miktar, mevcut toprak nem deposundan alınır ve bu durum, mevcut kaynağın yaklaşık %50'si kullanıldığında gerçekleşir. Nem eksikliği arttığında, gerçek buharlaşma ve terleme (AET) PET'ten daha az hale gelir ve bu, solma noktasına ulaşana kadar devam eder. Solma noktasına ulaşıldığında, buharlaşma ve terleme tamamen durur [23].

Sıcaklığı çok yüksek veya çok düşük olmayan iklimlerde yıllık yağışın üçte ikisi buharlaşma ve terleme yoluyla kaybedilir. Buharlaşmayı etkileyen birçok faktör bulunmaktadır. Bu faktörler uzun süredir biliniyor olsa da buharlaşma çok kompleks bir yapıya sahip olduğu için tahmini zorlu olan bir alandır. Buharlaşmayı etkileyen faktörlerden bazıları sıcaklık, radyasyon, nem, rüzgâr, su kütlesinin derinliği, suyun kalitesi olarak sayılabilir.

Sıcaklık: Bir ortamın ısısal durumunu ifade eder. Genellikle hava veya su sıcaklığı olarak ölçülür. Hava sıcaklığı ölçümlerinin su yüzeyinden 2 metre yukarıda yapılması tercih edilir. Su yüzeyi sıcaklığı ölçümünde 0.5 derecelik bir hata payı sonucu kabul edilebilir düzeydir. İki sıcaklık verisi için de yüksek sıcaklık, su moleküllerinin kinetik enerjisini artırarak buharlaşmayı hızlandırır. Su yüzeyindeki sıcaklık arttıkça, moleküller daha kolay atmosfere karışır. Örneğin, yaz aylarında sıcaklık yüksek olduğunda buharlaşma oranları artar.



Şekil 5. Buharlaşmayı etkileyen faktörler.

Güneş Radyasyonu: Güneşten gelen elektromanyetik enerji formundaki ışıma radyasyon denir. Kısa dalga radyasyonu ve uzun dalga radyasyonu olarak ikiye ayrılır. Kısa dalga radyasyonu güneşten gelen toplam radyasyondur. Uzun dalga radyasyonu ise güneşten gelen toplam radyasyon ve yüzeyden yansıyan radyasyonun arasındaki farktır. Güneş ışıması, su yüzeyini ısıtarak buharlaşmayı artırır. Direkt güneş ışığı alan bölgelerde, radyasyonun etkisiyle su moleküllerinin enerjisi artar ve buharlaşma hızlanır. Bulutlu günlerde veya gölgeli alanlarda buharlaşma oranı daha düşüktür.

Nem: Havada bulunan su buharı miktarının, belirli bir sıcaklıktaki maksimum su buharı kapasitesine oranına verilen isimdir. Nem oranı yüksek olduğunda buharlaşma yavaşlar, çünkü hava su buharına doymun hale gelir. Düşük nem oranı, hava moleküllerinin daha

fazla su buharını alabilmesini sağlar ve buharlaşmayı hızlandırır. Örneğin, kuru çöl bölgelerinde nem düşük olduğu için buharlaşma oranı yüksektir.

Rüzgar: Atmosferde çeşitli şekillerde gerçekleşen hava hareketine denir. Rüzgar, su yüzeyinden buharlaşan molekülleri taşıyarak ortamda doymuş hale gelmiş hava tabakasını uzaklaştırır ve yeni moleküllerin atmosfere karışmasını sağlar. Şiddetli rüzgarlar, buharlaşmayı artırırken durgun hava koşullarında buharlaşma daha yavaş gerçekleşir. Çoğu dolaylı buharlaşma hesaplama yönteminde rüzgar hızı su yüzeyinden 2 metre yukarıda ölçülmüş veri gerektirir.

Su Kütlesinin Derinliği: Su birikintisinin (göl, baraj vs.) veya bir su kaynağının yüzeyinden tabanına kadar olan derinliktir. Derin su kütleleri, yüzey sıcaklık değişikliklerinden daha az etkilenir, bu nedenle buharlaşma oranı sığ su kütlelerine göre daha düşük olabilir. Sığ sularda, su daha hızlı ısınır ve buharlaşma daha fazla olur.

Suyun Kalitesi: Su içinde çözülmüş durumda bulunan tuz, mineral ve diğer birçok madde suyun kalitesini etkiler. Tuzluluk gibi faktörler buharlaşmayı etkileyebilir. Tuzlu suda, su moleküllerinin buharlaşması saf suya göre daha yavaş gerçekleşir. Çünkü çözülmüş tuzlar, su moleküllerinin serbestçe hareket etmesini zorlaştırır.

Buharlaşma yukarıda açıklanan faktörler ve daha birçok farklı durumdan etkilenir. Bu faktörlerin her birinin buharlaşmaya etkisi farklıdır, örneğin yüksek sıcaklık-düşük nem-şiddetli rüzgar kombinasyonu buharlaşmayı maksimum seviyeye taşıırken düşük sıcaklık-yüksek nem-durgun hava koşulları kombinasyonu buharlaşmayı minimum seviyede tutar. Buharlaşmanın karmaşık bir yapı olmasından kaynaklı olarak su yönetimi, su kaynaklarının korunması, sulama planlaması gibi alanlarda ancak tahmin edilerek kullanılır. Türkiye’de yıllık toplam yağış miktarının yaklaşık %55’i buharlaşma yoluyla atmosfere geri dönmektedir. Bu oran su döngüsünde buharlaşmanın ne kadar önemli bir yer tuttuğunun kanıtı niteliğindedir. Buharlaşma terimi sadece su kütlelerinden gerçekleşen buharlaşmayı içermez. Buharlaşma aynı zamanda tarımsal (sulama sistemleri, bitki transpirasyonu), kentleşme ve altyapı (yapay göller), endüstriyel(soğutma sistemleri, üretim süreçlerinde kullanılan su) olarak da gerçekleşir.

Türkiye, su kaynakları açısından “su stresi” yaşayan bir ülke olarak sınıflandırılmaktadır. Mevcut su potansiyeli ve artan nüfus göz önüne alındığında, su talebinin gelecekte önemli

ölçüde artması beklenmektedir. Nüfus artışı, kentleşme ve ekonomik gelişme gibi faktörler, su talebinin artmasına neden olacaktır. 2030 yılına gelindiğinde, kişi başına düşen kullanılabilir su miktarının yıllık 1.100 metreküp civarına düşeceği öngörülmektedir [24]. Bu durum, Türkiye’yi su sıkıntısı çeken bir ülke konumuna getirebilir. 2050 yılına kadar ise, nüfus artışının %60 daha fazla gıda gerektireceği ve dolayısıyla tarımsal su kullanımında %19’luk bir artış olacağı tahmin edilmektedir [25]. İklim değişikliği, su kaynakları üzerinde uzun vadeli etkiler yaratacaktır. Su Verimliliği Strateji Belgesi ve Eylem Planı (2023-2033) raporuna göre, havzalardaki su varlığının iklim değişikliğine bağlı olarak gelecekte nasıl etkileneceğine ilişkin projeksiyonlar, su kaynaklarının önümüzdeki yüzyıl içinde önemli değişikliklere uğrayacağını göstermektedir [26].

3.1. Temel Buharlaşma Hesaplama Yöntemleri

Buharlaşmayı ölçmek için geçmişten günümüze birçok metot geliştirilmiş ve kullanılmıştır. Bunlar doğrudan ve dolaylı metotlar olarak ikiye ayrılabilir. Tava buharlaşması yöntemi doğrudan metotlardan biridir. Dolaylı metotlar ise bütçe metotları, kombinasyon metotlar ve ampirik formülleri içerir.

3.1.1. Tava Buharlaşması:

Serbest yüzey su kütlelerinden buharlaşmanın tahmin edilebilmesi için küçük bir yüzey üzerinde gerçekleşen buharlaşmanın kayıt altına alınması yoludur. Aynı zamanda kabın alabileceği yağış da dikkate alınmalıdır. Bu şekilde yapılan ölçümleri geniş su yüzeylerinden gerçekleşen buharlaşmayı tahmin etmede kullanırken uygun bir katsayı ile çarpmak gerekir.

3.1.2. Su Bütçesi Metodu:

Temel formülü

$$E=I-O-\Delta S \quad (1)$$

olan yöntem süreklilik eşitliğine dayanır. Burada E buharlaşma değerini, I gelen akış değerini, O giden akış değerini, ΔS ise depodaki değişimi ifade eder. Bu temel ifade, denkleme yüzeyin üzerindeki bileşenleri ifade eden s ve yüzeyin altındaki bileşenleri ifade eden g ekleri ile yeniden düzenlendiğinde aşağıdaki formül elde edilir.

$$E_s = P + R_1 - R_2 - R_g - T_s - F - \Delta S_s \quad (1.2)$$

E_s : rezervuar buharlaşması

P: yağış

R_1 : rezervuarın içine gelen yüzey akışı

R_2 : rezervuardan giden yüzey akışı

R_g : yeraltı suyu akışı

T_s : terleme kaybı

F: sızma

ΔS_s : depolamadaki değişim

Sızıntının net transferi $(R_g - F) = O_s$ ve terleme $T_s = 0$ ise denklem aşağıdaki şekle gelir.

$$E_s = P + R_1 - R_2 + O_s - T_s - \Delta S_s \quad (1.3)$$

Bütün terimler çalışılan zaman periyodu için (bir haftadan az olmamak üzere) hacimsel birimlerdir. Teoride basit olmasına rağmen kullanılan parametrelerin ölçümündeki hatalardan direkt etkilenir. Dolayısıyla hesaplanan buharlaşma değerinde hatanın %5 civarında olması bekleniyorsa bu metodun 1 aydan kısa süre için kullanılması önerilmez.

Bu metotta değerlendirilmesi en zor değer sızma (F) 'dır. Bu bileşen göl yatağının hidrolik iletkenliği ve hidrolik gradyanının bilinmesiyle hesaplanabilir. Ancak yine de bu metod, sızmanın göz ardı edildiği su geçirmez göllerde hesaplanan buharlaşma değerleriyle kıyaslandığında başarılı sonuçlar verir.

ΔS_s 'in değerlendirilmesinin gerektiği göller için kesin bir alan kapasite eğrisi olmalıdır. Bu verilere rağmen depolama bileşeni su bütçesinde bir hataya neden olabilir. Depolama bileşeni ihmal edilirse, su bütçesi metodu yıllık döngüde yararlı olmayacağı gibi bu metod zaman periyodu kısa çalışmalarda da hatalı sonuç verir [27]. Herhangi bir serbest yüzeyden buharlaşmayı tahmin etmek için su bütçesi yöntemini teorik olarak kullanmak mümkün olsa da çeşitli parametrelerin ölçümündeki hataların etkileri nedeniyle bu genellikle pratik değildir. Bu yöntemle tahmin edilen buharlaşma, artık bir değerdir ve

dolayısıyla diğer parametrelere kıyasla küçükse, önemli ölçüde hata içerme olasılığı yüksektir. Özetle, bu yöntem çoğu koşulda zor ve yanıltıcıdır, özellikle kısa ortalama süreler için kullanıldığında. Ölçülmesi en zor parametrelerden bazıları depolamadaki değişim, sızma, yeraltı suyu akışı ve taşınımlı akışlardır [23].

3.1.3. Enerji Bütçesi Metodu:

Enerji bütçesi yöntemi, enerjinin süreklilik denklemini kullanarak yüzeylerden buharlaşmayı hesaplamayı amaçlar. Bu yöntem, genellikle göller ve okyanuslar gibi büyük su kütleleri için tercih edilmektedir. Denklem, sistemdeki enerji dengesini sağlamak için gelen enerji, giden enerji ve depolanan enerji miktarını göz önünde bulundurur. Enerji bütçesi yöntemiyle yapılan buharlaşma hesaplamalarının doğruluğu, ölçüm verilerinin güvenilirliği ve hassasiyetine bağlıdır. Uygun koşullarda, yaz mevsiminde yaklaşık %10, kış mevsiminde ise %20 hata payı görülebilir.

Kimyasal süreçlerin ve biyolojik değişimlerin oluşturduğu ısınma etkisi, enerji bütçesi denklemlerine dahil edilmez. Benzer şekilde, kinetik enerjinin ısı enerjisine dönüşümü de denklemin dışında bırakılmıştır. Ancak, büyük su kütlelerinde bu etkiler genellikle diğer faktörlere kıyasla oldukça küçük olduğundan, bu ihmalin sonuçlara olan etkisi genellikle sınırlıdır.

Enerji bütçesi denklemindeki her terim ya doğrudan ölçümlerle elde edilir ya da bilinen matematiksel ilişkiler yardımıyla hesaplanır. Bu terimlerin değerlendirilmesinde kullanılan yöntemler, detaylı bir şekilde ele alınmaktadır.

$$Q_0 = Q_s - Q_r + Q_a - Q_{ar} - Q_{bs} + Q_v - Q_R - Q_h - Q_w \quad (2)$$

Q_0 = Suyun depoladığı enerjideki artış

Q_s = Su yüzeyine gelen solar radyasyon

Q_r = Yansıtılan solar radyasyon

Q_a = Atmosferden gelen uzun dalga radyasyonu

Q_{ar} = Yansıtılan uzun dalga radyasyonu

Q_{bs} = Sudan yayılan uzun dalga radyasyonu

Q_v =Su kütlesindeki net enerji adveksiyonu-gelen ve giden suyun net enerji içeriği

Q_e =Buharlaşımda kullanılan enerji

Q_h =Hissedilir ısı olarak su kütlesinden iletilen enerji

Q_w =Buharlaşan sudaki enerji adveksiyonu

Bu denklemde Q_s , Q_r , Q_a terimleri ölçülebilir. Yansıyan uzun dalga radyasyonu, su yüzeyi tarafından alınan uzun dalga radyasyonunun %3'ü olarak kabul edilebilir. Su tarafından yayılan uzun dalga radyasyonu (Q_{bs}), Stefan-Boltzman yasasına göre su için 0.970 yayılım faktörüyle hesaplanır.

$$Q_{bs}=0.97\sigma\theta^4 \text{ (} Wm^{-2} \text{)} \quad (2.1)$$

σ = Stefan-Boltzman sabiti ($5.67 \times 10^{-8} K^4$)

θ =°K cinsinden su yüzeyi sıcaklığı

θ değeri ölçümü için rezervuar yüzeyden dibe kadar birçok katmanlara bölünebilir. Her katmandaki su hacmi basamak-hacim ilişkisi ile hesaplanır. Belirli bir katmanda yapılan tüm sıcaklık gözlemlerinin ortalaması, o hacimdeki su için ortalama bir sıcaklık verir. Hacim ve sıcaklık çıktılarının toplamı (taban sıcaklığının 0° olduğu varsayılarak) toplam enerjiyi verir [24].

Enerji bütçesi metodundaki terimlerin çoğu doğrudan ölçüm gerektirir. Doğrudan ölçümü yapılamayan terimler matematiksel ilişkiler yoluyla hesaplanır. Bu yaklaşımda ölçümlerin yeterli doğruluğu tüm değişkenler için aynı değildir. Örneğin gelen uzun dalga radyasyonunun ölçümündeki %2 seviyesindeki küçük hatalar aylık buharlaşma tahminlerinde %3-15 aralığında hatalara neden olur. Yansıyan güneş enerjisi ölçümlerindeki %10 hata ise hesaplanan aylık buharlaşma miktarında yalnızca %1-5 aralığında hatalara neden olur [24]. Kış mevsimi esnasında yüzeyin tamamı veya bir kısmı buzla kaplanırsa bu yöntem doğru sonuç vermeyebilir. Aynı şekilde günlük buharlaşma tahmininde kullanımı da tavsiye edilmez çünkü büyük su kütlelerinde depolanan enerjideki değişimi günlük olarak belirlenmesi pek mümkün değildir dolayısıyla daha uzun süreler için kullanıldığında daha doğru sonuçlar elde edilir.

3.1.4. Kütle Transfer Metodu:

Su yüzeyinde bulunan su buharının atmosfere taşınan kısmının kütlelerinin belirlenmesi yoludur. Kütle transferi metodu buharlaşma ve buhar basıncı arasındaki ilişkiyi açıklayan Dalton'un aerodinamik yasasını temel alır. İlk olarak Harbeck ve Meyers tarafından 1970 yılında önerilmiştir.

$$E = k \times (e_s - e_a) \quad (3)$$

E: doğrudan buharlaşma

K: rüzgar hızı, atmosfer basıncı gibi faktörlere bağlı katsayı

e_s : su yüzeyi sıcaklığı

e_a : havanın buhar basıncına karşılık gelen doymuş buhar basıncı

3.1.5 Aerodinamik ve Enerji Dengesi Metotlarının Kombinasyonu:

Bir su kütlelerinin buharlaşmasını meteorolojik faktörler aracılığı ile hesaplamak için kullanılan en yaygın metotlardan biridir.

$$E_i = \frac{R_n \Delta + E_a \gamma}{\Delta + \gamma} \quad (4)$$

$$\Delta = \frac{e_s - e_{sz}}{T_s - T_z} \quad (4.1)$$

E_i : Serbest su yüzeyinden tahmini buharlaşma

Δ : Herhangi bir θ_0 sıcaklığında soygun buhar basıncı eğrisinin eğimi

R_n : Net radyasyon

γ : Islak ve kuru termometre psikrometre denklemindeki sabit

E_a : Aerodinamik buharlaşma

Denklemdaki net radyasyonun (R_n) hesaplanabilmesi için ölçülmüş kısa ve uzun dalga güneş radyasyonu değerlerinin kullanılması tavsiye edilir fakat ölçülmüş değer yok ise

veya uygulanacak metot bu değerin hesabını gerektiriyorsa aşağıdaki bağlantı yardımıyla hesaplanabilir.

$$R_n = \left(0.25 + 0.5 \frac{n}{N}\right) S_0 - (0.9 \frac{n}{N} + 0.1)(0.34 - 0.14\sqrt{e_d})\sigma T^4 \quad (4.2)$$

$\frac{n}{N}$: Gerçek güneş ışığı saatlerinin olası güneş ışığı saatlerine oranı

S_0 : Dünyanın dışındaki radyasyon ($mjm^{-2}day$)

e_d : Havanın mmHg cinsinden gerçek buhar basıncı

σ : Stefan-Boltzmann sabiti (ayrıca $mmday^{-1}$ cinsinden eşdeğer buharlaşma)

T : Kelvin cinsinden ortalama hava sıcaklığı

Bu metot dar zaman aralıkları için hesaplanacaksa derin olmayan su kütleleri ve su kütlesine enerji taşınımının çok az olduğu (göz ardı edilebilir seviyede) durumlarda kullanılmalıdır. Derin su kütlelerinde kullanılması gerekiyorsa giriş-çıkış kaynaklı önemli adveksiyon durumlarında ve enerjinin depolanmasındaki değişiklikler bakımından düzenlenmelidir. Güvenilir haftalık veya aylık göl buharlaşma tahminleri, ancak enerji adveksiyonu ve enerji depolama faktörlerinin dikkatlice değerlendirildiği durumlarda bu yöntemle elde edilebilir. Bu nedenle, yöntemin uygulanabilirliği, gölün fiziksel özellikleri ve kullanılan verilerin doğruluğu ile doğrudan ilişkilidir.

3.2. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin geleneksel bilgisayarlardan farklı bir şekilde çalıştığı fikrinden yola çıkılarak geliştirilmiştir. Beyin, doğrusal olmayan, oldukça karmaşık ve paralel çalışan bir yapı olarak düşünülebilir. En temel anlamıyla yapay sinir ağı, beyin belirli bir görevi veya işlevi nasıl yerine getirdiğini modellemek üzere tasarlanmış bir sistemdir.

YSA'lar, birbirine ağırlıklandırılmış bağlantılarla bağlanmış, nöron olarak adlandırılan işlem birimlerinden oluşur. Bu işlem birimleri, diğer nöronlardan gelen sinyalleri alır, bu sinyalleri birleştirir ve matematiksel bir dönüşümden geçirerek sayısal bir çıktı üretir.

Nöronlar, biyolojik nöronların işlevlerine benzer şekilde, bir ağ içerisinde birbirlerine bağlanır ve bu bağlar aracılığıyla sinir ağı yapısını oluşturur.

Yapay sinir ağları, sahip oldukları özellikler sayesinde geniş bir yelpazede işlevler gerçekleştirebilmektedir. Bu ağlar, sınıflandırma, örüntü tanıma, doğrusal olmayan sistem modelleme, optimizasyon, zeki ve doğrusal olmayan kontrol, sinyal süzme, veri sıkıştırma ve doğrusal olmayan sinyal işleme gibi çeşitli fonksiyonlar için etkin bir şekilde kullanılabilir. Özellikle karmaşık ve doğrusal olmayan problemlerde etkili çözümler sunma yetenekleri, yapay sinir ağlarını farklı alanlarda vazgeçilmez hale getirmektedir.

Bu fonksiyonel çeşitlilik, yapay sinir ağlarının birçok sektörde uygulama bulmasını sağlamaktadır. Tıp, mühendislik, havacılık, güvenlik sistemleri, pazarlama, robotik, otomotiv ve savunma gibi alanlar, yapay sinir ağlarının sıklıkla kullanıldığı sektörler arasında yer almaktadır. Örneğin, tıp alanında hastalık tanıma ve tedavi planlaması; mühendislikte sistem modelleme ve kontrol, robotikte hareket ve nesne tanıma; pazarlamada ise müşteri davranışlarının analiz edilmesi gibi birçok alanda yapay sinir ağlarının sunduğu çözümlerden yararlanılmaktadır. Bu uygulamalar, yapay sinir ağlarının esneklik, uyarlanabilirlik ve öğrenme yeteneklerinden en iyi şekilde faydalanılmasını sağlamaktadır.

3.2.1. Avantajları

1.Paralel Veri İşleme:

Yapay sinir ağları, geleneksel bilgisayarların çoğundan farklı olarak paralel işlem yapma kapasitesine sahiptir. Bu özellik hem işlem hızını artırır hem de ağın bir kısmında sorun oluşsa bile sistemin genel performansını büyük ölçüde korumasını sağlar. Nöronlardan birinin devre dışı kalması durumunda, diğer nöronlar çalışmaya devam eder ve istenen sonuca yaklaştırmaya devam eder.

2. Doğrusal Olmama:

YSA'ların doğrusal olmayan yapısı, lineer olmayan sistemlerin çözümünde yüksek başarı sağlar. Bu özellik, karmaşık ve eğrisel sistemler üzerinde etkili sonuçlar üretmelerine olanak tanır.

3. Yerel Bilgi İşleme:

Yapay sinir ağları, bir problemin çözümünde yalnızca ilgili birimler ile ilgilenir. Bu görev paylaşımı, karmaşık problemleri dahi daha hızlı ve kolay bir şekilde çözebilmelerine yardımcı olur.

4. Genelleme Yeteneği:

Eğitim sürecinden geçen YSA'lar, öğrendikleri bilgileri genelleyerek benzer problemleri çözebilir. Eğitim sırasında analiz edilen verilere dayalı olarak test aşamasında doğru sonuçlar üretebilirler.

5. Uyarlanabilir Olma:

YSA'lar, belirli bir ortamda eğitilmiş olsa bile, ortam koşullarındaki değişikliklere kolayca uyum sağlayabilir ve yeniden eğitilebilir. Bu özellik, otomatik kontrol, hedef tanıma ve sistem modelleme gibi alanlarda kullanılmalarını sağlar.

6. Öğrenme Yeteneği:

YSA'lar, geleneksel algoritmalardan farklı olarak, bir problemin çözümünü örnekler üzerinden öğrenir. Hücreler arası bağlantılar ve ağırlıklar uygun şekilde düzenlenerek ağın istenen davranışı göstermesi sağlanır. Öğrenme süreci, giriş ve çıkış verilerinden ağırlıkların ilişkilendirilmesiyle gerçekleşir.

7. Hata Toleransı:

Paralel çalışmanın bir sonucu olarak, ağ içindeki bir nöronun işlev kaybı, sistemin genel performansını önemli ölçüde etkilemez. Bu özellik, ağın güvenilir ve dayanıklı bir şekilde çalışmasına olanak tanır.

3.2.2. Dezavantajları:

1.Paralel veri işleme yeteneklerinden tam verim alabilmek için, paralel çalışan donanımlar gereklidir.

2.Uygun ağ yapısının belirlenmesi için genel bir kural bulunmamaktadır.

3.Ağ parametrelerinin ayarlanması için kesin bir yöntem yoktur ve bu her problem için farklılık gösterebilir.


4.Problemler, nümerik bilgilere dönüştürülmeden YSA'lar tarafından çözülemez.

5.Ağın eğitiminin ne zaman tamamlanacağına dair kesin bir yöntem yoktur.

6.Ağın bir problemi nasıl çözdüğü hakkında bilgi edinmek mümkün değildir, bu da ağ davranışının açıklanmasını zorlaştırır.

3.2.3. Yapay Sinir Ağı Hücresi

Yapay sinir ağları; girdi katmanı, ara katman ve çıktı katmanı olarak sıralanabilecek 3 temel katmandan oluşur. Girdi katmanı kullanıcıdan alınan bilgileri herhangi bir işlem yapmadan doğrudan ara katmana iletir. Ara katman ise girdi katmanından gelen verileri işler ve çıktı katmanına aktarır. Yapay sinir ağları ile çözülmek istenen problemler genellikle karmaşık yapılar oldukları için birden fazla ara katmana sahip olmaları muhtemeldir. Çıktı katmanı ise ara katmanın aktardığı işlenmiş veriyi kullanarak bir çıktı üretir ve bunu kullanıcı ile paylaşır.



Şekil 6. Yapay sinir ağı hücresi.

3.2.4. Yapay Sinir Ağlarının Sınıflandırılması

Ağ Mimarisine Göre Sınıflandırma

İleri Beslemeli Sinir Ağları (Feedforward Neural Networks- FNNs) : Bu ağ yapısında girdiler tek yönlüdür ve giriş katmanından çıkış katmanına doğru hareket ederler. Dolayısıyla döngü oluşturup geri besleme yapmazlar. Görüntü sınıflandırma, zaman serisi analizi regresyon gibi problemlerde yaygın şekilde kullanılırlar. Mimarileri daha basit olduğu için kullanmak ve anlamak daha kolaydır. Fakat zaman bağımlı veriler üzerindeki sonuçlarını iyi değerlendirmek gerekmektedir.

Geri Beslemeli Sinir Ağları (Recurrent Neural Networks- RNNs) : İleri beslemeli sinir ağlarından farklı olarak döngüler sayesinde çıktı katmanı veya ara katmandaki çıktılar bir sonraki girdiyi besler ve böylece geçmiş bilgiler kullanılarak daha iyi tahminler

yapabilmektedir. Zaman serisi analizlerinde ve metin işleme gibi uygulamalarda kullanılır.

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks- CNNs) : Sinyal işleme, görüntü analizi gibi alanlarda kullanılan matematiksel bir işlem olan konvolüsyon katmanları ile çalışır. Yüz tanıma, nesne tespiti, medikal görüntülerin analizinde kullanılmaktadır.

Radyal Tabanlı Ağlar (Radial Basis Function Networks- RBFNs) : Aktivasyon fonksiyonu olarak radyal baz fonksiyonlarını kullanan bir ağ yapısıdır. Genellikle gizli katman ve çıktı katmanlarından oluşur. Hızlı öğrenebilen bir yapıdır ve sınıflandırma regresyon gibi alanlarda iyi performans göstermektedir fakat yüksek boyutlu veriler kullanılırsa bu performans düşebilmektedir.


Öğrenme Türüne Göre Sınıflandırma

Bir ağın öğrenmesi ağa verilen veriler için doğru ağırlık değerlerine ulaşarak verilere dair anlamlı tahminler yapabilmesidir. Bu ağırlık değerleri başlangıçta rastgele atanır daha sonra ağa verilen girdi çıktı örneklerine dayanarak, optimize edilir ve daha anlamlı sonuçlar elde edilmesini sağlar.

Denetimli Öğrenme (Supervised Learning) : Bu öğrenme modelinde ağa girdi değerlerine ek olarak çıktı değerleri de verilir. Bu sayede ağa verilen çıktı ile gerçek çıktı karşılaştırılabilir. Verilen girdi ve çıktı etiketli örneklerin sayısı arttıkça ağ bu iki veri arasındaki bağlantıyı daha iyi öğreneceği için doğruluk yüzdesi yükselir. Genellikle sınıflandırma ve regresyon problemlerinde kullanılır.

Denetimsiz Öğrenme (Unsupervised Learning) : Denetimli öğrenme yönteminin aksine bu yöntemde ağa sadece girdi katmanı sağlanır. Ağdan bu girdi katmanlarındaki ilişkiyi örneğin kümeler oluşturarak öğrenmesi ve çıktı katmanı üretmesi beklenir. Fakat bu öğrenme sisteminden oluşan çıktıları yorumlamak bazı veri setlerinde zorlayıcı olabilir.

Pekiştirmeli Öğrenme (Reinforcement Learning) : Bu yöntemde eğitim süreci karmaşıktır dolayısıyla uzun sürebilmektedir. Pekiştirme işleminin yapılabilmesi için ağa çıktı verisi sağlanmaz, giriş verileri ile kendisinin çıktı sağlaması beklenir. Ağ tarafından üretilen çıktı katmanının ne kadar anlamlı olduğu ağa bilgi olarak iletilir ve kendisini bu yöntemle geliştirmesi sağlanır.



Şekil 7. Yapay sinir ağlarının sınıflandırılması.

4. BÖLÜM: YÖNTEM

Türkiye’de yıllık ortalama yağış 574 mm olup, yılda ortalama 450 milyar m^3 , suya tekabül etmektedir. Çeşitli maksatlarla tüketilebilecek yerüstü suyu potansiyeli yılda ortalama 94 milyar m^3 ,’tür, 18 milyar m^3 , olarak belirlenen yeraltı suyu potansiyeli ile yılda ortalama toplam 112 milyar m^3 , tüketilebilir su potansiyeli bulunmaktadır. Ülkemizde kişi başına düşen kullanılabilir su potansiyeline bakıldığında, Türkiye su baskısı yaşayan ülkeler arasında yer almaktadır. [28] IPCC 2023 İklim Değişikliği raporuna göre birçok ülke gibi Türkiye’de de daha sık ve şiddetli sıcak hava dalgaları ve kuraklıklar yaşanıyor. Bu raporda belirlenen ana sorunlardan biri azalan yağışlar ve artan buharlaşma oranları nedeniyle su kıtlığı riskinin giderek yükselmesidir. Türkiye için hem kısa hem uzun vadede önemli sıcaklık artışları beklenmektedir. 21. yüzyılın ortalarına kadar (2041-2060) küresel sıcaklık artışlarının $1,5^{\circ}\text{C}$ ile $2,4^{\circ}\text{C}$ arasında olacağı tahmin edilmektedir. 21. yüzyılın sonuna kadar (2081-2100) ise bu artışın daha da belirginleşerek 2°C ile 4°C arasında olması öngörülmüyor. Önümüzdeki 20 yıl içinde, mevcut emisyon senaryolarına bakıldığında, Türkiye’deki sıcaklık artışının $1,5^{\circ}\text{C}$ seviyesini geçmesi beklenmektedir. En kötü senaryoda ise sıcaklık artışının 2050 yılına kadar 2 katına çıkabileceği ve 2100 yılına kadar bu artışın da 2 katına çıkabileceği belirtilmektedir. [29] IPCC raporu göz önüne alındığında Türkiye’nin iklim değişikliğinden ciddi oranda etkileneceği görülmektedir. Bu etkiyi minimuma indirebilmek için gelen yağışların verimli şekilde tutulması, buharlaşmayı önleme alanında daha etkili uygulama ve çalışmalar yapılması ve tabii ki su tüketiminde oldukça dikkatli olunması büyük önem arz etmektedir.

Buharlaşma sürekli olarak devam eden ve birçok parametreye bağlı karmaşık bir yapıdır. Bu yapıyı hesaplamak ve günümüz şartlarında iklim değişikliğine karşı savaşabilmek için tahmin etmek geleneksel yöntemlerle oldukça zordur. İlgili bölümlerde açıklanan birçok metotta görüldüğü üzere birden fazla veri ihtiyacı vardır ve bu verilerin ölçümelerini yapmak bazı bölgelerde çok zorlu bazı durumlarda ise neredeyse imkansız hale gelebilir, oldukça da pahalı cihazlar gerektirebilir. Ölçüm esnasında oluşabilecek ölçümü yapan kişi kaynaklı hata veya cihaz kaynaklı hataların getireceği yanlış hesaplamaları da göz önünde bulundurmak gereklidir. Ampirik formüllerle hesaplanan çıktıları doğruya yaklaştırmak için bölgesel olarak katsayı hesabı yapmak da gerekebilir.

Yapay sinir ağıları ise buharlaşma gibi karmaşık yapıları anlama konusunda oldukça gelişmiştir. Günümüzde sağlık, mühendislik, pazarlama, üretim, lojistik gibi temel alanlarda ve bunların haricinde de birçok alanda etkili olan yapay zeka hidroloji alanında da yenilik ve kolaylık sağlamaktadır. Yapay zeka tabanlı birçok program aracılığı ile elde edilen veriler toplanabilir, saklanabilir, analizleri yapılarak uç noktalarda bulunan veriler normalleştirilebilir ve dolayısıyla daha doğru sonuçlar elde edilebilir. Elde edilen sonuçlar gerçeğe yaklaştıkça iklim değişikliğinin boyutu daha net görülecek ve elbette alınması mecbur olan önlemler gözler önüne serilecektir.

4.1. Geleneksel Buharlaşma Hesaplama Yöntemleri

Su kaynaklarının yönetimi ve hidrolojik süreçlerin anlaşılması, sürdürülebilir çevre politikalarının geliştirilmesi için büyük önem taşımaktadır. Bu bağlamda, buharlaşma hesabı, hidrolojik döngünün kritik bir bileşenini oluşturmaktadır. Buharlaşmanın doğru bir şekilde tahmin edilmesi, su bütçesi analizleri ve iklim etkilerinin değerlendirilmesi gibi uygulamalarda hayati bir rol oynamaktadır. Literatürde buharlaşma tahmini için kullanılan yöntemler arasında Meyer ve Penman-Monteith denklemi, meteorolojik parametrelerin ayrıntılı bir şekilde değerlendirildiği ve uluslararası düzeyde standart kabul edilen bir yaklaşım olarak öne çıkmaktadır. Romanenko yöntemi, sıcaklık temelli basit yapısıyla dikkat çekerken, Hargreaves-Samani yöntemi ise sınırlı meteorolojik veriyle buharlaşma hesabını mümkün kılan pratik bir yöntem olarak kullanılmaktadır. Bu çalışma, farklı buharlaşma tahmin yöntemlerinin dayandığı temel prensipleri açıklamak ve hidrolojik uygulamalardaki önemini değerlendirmek amacıyla gerçekleştirilmiştir.

Penman Denklemi (1948)

Bu teoride buharlaşmanın devam edebilmesi, buharlaşma latent ısısı için gerekli enerjinin sağlanması ve buharı uzaklaştıran bir mekanizmanın var olması temellerine dayanır.

$$E = \left(\frac{\Delta}{\Delta + \gamma} \right) (R_n - A_h) + \left(\frac{\gamma}{\Delta + \gamma} \right) \frac{1}{\lambda} (6.43(1 + 0.536u_2)(e_s + e_a)) \quad (5)$$

E: buharlaşma (mm/gün)

Δ : doymuş buhar basınç eğrisi eğimi (kPa/°C)

γ : psikometrik sabit (kPa/°C)

R_n : net radyasyon (W/m²)

A_h : su kütlesine yatay enerji transferi (W/m^2)

λ : latent ısı ($^\circ C$)

u_2 : 2 m yükseklikteki günlük ortalama rüzgâr hızı (m/sn)

e_s : doymuş buhar basıncı (kPa/ $^\circ C$)

e_a : gerçek buhar basıncı (kPa/ $^\circ C$)

$e_s - e_a$: buhar basınç farkı (kPa/ $^\circ C$)

$$\Delta = 4090 \frac{e_s}{(237.3 + T_a)^2} \quad (5.1)$$

$$\gamma = 0.00163 P_a / \lambda \quad (5.2)$$

$$\lambda = 2.501 - 0.002361 T_s \quad (5.3)$$

T_a : günlük ortalama hava sıcaklığı ($^\circ C$),

P_a : günlük ortalama atmosfer basıncı (kPa)

T_s : günlük ortalama su sıcaklığı ($^\circ C$)

Meyer Denklemi (1915)

Aşağıda bulunan 6 numaralı denklem Meyer tarafından 1915 yılında bulunmuştur. Bu denklem rüzgâr hızına, buhar basınç farklarına ve su kütlesinin büyüklüğüne bağlıdır.

$$E = A(e_s - e_a) \left(1 + \frac{w}{16}\right) \quad (6)$$

E: aylık buharlaşma miktarı(mm)

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

e_a : Su yüzeyindeki buhar basıncı(mmHg)

W: su yüzeyinden 8m yükseklikte km/saat cinsinden ölçülen rüzgâr hızı

*A büyük su kütlelerinde 11, küçük su kütlelerinde 15 olarak alınan bir katsayıdır.

RH: rölatif nem olmak üzere e_a ve e_s değerlerinin hesaplanması;

$$RH = \frac{e_a}{e_s} \quad (6.1)$$

$$e_s = 6.11 \exp \left[\frac{17.3T}{237.3+T} \right] \quad (6.2)$$

T: hava sıcaklığı(°C)

e_s : doymuş buhar basıncı(mmbar)

Ritchie Ampirik Denklemi (1990)

Bu ampirik denklemin kullanılabilmesi için gerekli parametreler günlük solar radyasyon, maksimum ve minimum hava sıcaklıklarıdır.

$$ET = \alpha_1 [3.87 \times 10^{-3} SR (0.6 T_{max} + 0.4 T_{min} + 29)] \quad (7)$$

$$5 < T_{max} \leq 35^\circ C \quad \alpha_1 = 1.1 \quad (7.1)$$

$$T_{max} > 35^\circ C \quad \alpha_1 = 1.1 + 0.05(T_{max} - 35) \quad (7.2)$$

$$T_{max} < 5^\circ C \quad \alpha_1 = 0.01 \cdot \exp. [0.18(T_{max} + 20)] \quad (7.3)$$

Romanenko Denklemi (1961)

Romanenko denklemi aylık buharlaşma değerini bulabilmek için ortalama hava sıcaklığını ve rölatif nemi kullanır.

$$E = 0.0018(25 + T_a)^2(100 - RH) \quad (8)$$

E: aylık buharlaşma miktarı(mm/ay)

T_a : ortalama hava sıcaklığı(°C)

RH: rölatif nem (%)

FAO Penman-Monteith Denklemi

1948 de Penman tarafından geliştirilen formülün 1965 de Monteith tarafından değiştirilmesiyle oluşmuştur. Bitki su ihtiyacını hesaplamak ve su yönetimini optimize etmek için sıklıkla kullanılan yöntemler arasındadır.

$$\lambda E = \frac{\Delta(R_n - N) + \frac{86400 \rho_a c_p (e_s - e_a) d}{r_a}}{\Delta + \gamma d} \quad (9)$$

R_n : net radyasyon ($\text{MJ m}^{-2} \text{gün}^{-1}$)

c_p : 0.001013 özgül ısı ($\text{MJ kg}^{-1} \text{°C}^{-1}$)

ρ_a : 1 (kgm^{-3}) hava yoğunluğu

Monteith değişkeni olarak tanımlanan **d**, uzun dalga net radyasyonun bileşenini hesaplarken yüzeydeki sıcaklığı kullanmak yerine, havanın sıcaklığının kullanılmasını sağlamak için eklenmiştir.

1990 yılının mayıs ayında Uluslararası Sulama ve Drenaj komisyonu (International Commission for Irrigation and Drainage) ve Dünya Meteoroloji Örgütü (World Meteorological Organization) ‘nın gerçekleştirdiği toplantıda bu yöntem referans buharlaşma ve terleme için standart olarak önerildi. Çeşitli parametrelerin hesaplanması için ayrıca geliştirilen prosedürlerle FAO Penman-Monteith yöntemi standart yöntem olarak kabul edildi ve günümüze kadar birçok araştırmacının çalışmalarında kullanıldı. FAO Penman-Monteith denklemi orijinal Penman-Monteith denkleminin aerodinamik denklemleri ve yüzey direnci denklemleri kullanılarak üretilmiştir. Bu yöntemde, iklim verileri olarak radyasyon, hava sıcaklığı, nem ve rüzgar kullanılır. Yöntem oldukça başarılı sonuçlar verse de hiçbir yöntem tüm iklim koşulları ve yöntemin kullanıldığı tüm konumlar için buharlaşmayı tamamen doğru tahmin edemez. Çoğu denklem kullanılabilir olması için belirli basitleştirmeler ve ön kabuller içerir bu sebeptendir ki sonuçların doğruluğu için konumlara göre kalibrasyon katsayıları da gerekmektedir. Bununla birlikte bu yöntemin güçlü temellere dayandığı ve yaygın olarak kullanıldığı da unutulmamalıdır.[30]

$$E = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (9.1)$$

Hargreaves-Samani Denklemi

Aşağıda Hargreaves-Samani denklemi verilmiştir.

$$ET = 0.0135 \frac{SR}{\lambda} (T + 17.8) \quad (10)$$

λ : potansiyel buharlaşma ısısı

4.2 Buharlaşmayı Önleme Yöntemleri

Buharlaşmayı önlemek için kullanılan yöntemler fiziksel ve kimyasal olarak ikiye ayrılır. Buharlaşma kayıplarını önlemek büyük bir avantaj sağlayacak olsa da kullanılabilecek her yöntemin kendi içinde avantaj ve dezavantajları da bulunmaktadır. Kullanılacağı alana uygun ve sürdürülebilir seçimler yapmak bu noktada oldukça önemlidir. Buharlaşma açık su yüzeylerinden gerçekleştiği gibi bitki ve toprak yüzeylerinden de gerçekleşir. Fakat buharlaşma önemli bir kayıp olduğu için özellikle açık su yüzeylerinden gerçekleşen buharlaşma kaybını önlemek veya azaltmak su tasarrufu sağlamak için oldukça önemli bir adımdır.

Bu bağlamda buharlaşmayı önlemek birincil öncelik olsa da aşağıda iki başlık halinde açıklanan fiziksel ve kimyasal yöntemlerin çeşitli negatif sonuçları da olabilmektedir. Su yüzeyinin hava ile temasını kesen bazı yöntemler özellikle durağan su kütlelerinde oksijen transferini azalttığını, su sıcaklığını artırdığı, organik atıkların birikmesine olanak tanıdığı için bir takım zararlı mikroorganizmaların üremeleri ve çoğalmaları için ideal ortamı sağlamış olurlar. Bu negatif etki filtrasyon, klorlama, ozonlama, UV arıtma, ters osmoz gibi arıtma yöntemleriyle ortadan kaldırılabilir. Bu arıtma yöntemlerinin etkileri ve maliyetleri farklı olduğu gibi devamlı bir ihtiyaç söz konusu olacağı için hem kurulum hem de işletme açısından sürekli maliyet yaratacaklardır.

Fiziksel Yöntemler

Bu başlık altındaki yöntemler, doğrudan su yüzeyinde fiziksel bir bariyer oluşturarak buharlaşmayı önlemeye yönelik çözümleri kapsamaktadır. Bu yöntemler genellikle uzun vadeli ve etkili olmakla birlikte kurulum ve bakım maliyetleri değişkendir.

Su Yüzeyinin Örtülmesi: Bu yöntemde su yüzeyinin tamamı polietilen, PVC veya diğer sentetik malzemelerden üretilen su geçirmez kaplamalarla kapatılır. Su yüzeyinin fotovoltaiik panellerle kaplanması da bu başlık altına dahil edilebilir. Fotovoltaiik paneller hem buharlaşmayı önleyerek hem de güneşten gelen ışınlarla elektrik üretimi yaparak çift kazanım sağlarlar. Kullanılan bu örtüler suyun doğrudan güneş ışınlarına ve rüzgarın buharlaşmayı artırıcı etkisine maruz kalmasını engelleyerek su kaybını önemli ölçüde azaltırlar. Oldukça etkili bir yöntemdir fakat büyük su yüzeylerinde uygulanması zor ve maliyetlidir.

Modüler Örtüler: Su yüzeyinde altıgen veya dairesel şekillerde birbirine geçmeli plastik malzemelerin yerleştirilmesiyle uygulanır. Bu plastik malzemeler hafif olmalarından kaynaklı su yüzeyinde kalır ve buharlaşmayı azaltırlar. Uygulama açısından oldukça kolaydır ve taşınabilir olduklarından su seviyesine göre ayarlanabilirler. Ancak büyük su yüzeylerine uygulanması zordur ve hareket kabiliyetleri sebebiyle rüzgar ve dalgalardan etkilenecek bozulma-açılmalar olabileceği için düzenli bakım gerektirirler.

Gölgeleme Brandası: Su yüzeyinin üstüne gergin bir şekilde yüksek kaliteli bir branda kumaşı veya plastik örtü serilmesi yoluyla güneş ışınlarının su yüzeyine ulaşması, suyun ısınması engellenerek dolayısıyla buharlaşmanın engellenmesi veya azaltılması amaçlanır. Kullanılan örtü su yüzeyine temas etmediği için su kalitesini etkilemez. Fakat kurulum maliyeti oldukça yüksektir.

Özel Tasarımlar: Buharlaşmayı önlemek için yerel ihtiyaçlara ve çevresel koşullara bağlı olarak özel tasarımlar geliştirilir. Rüzgar kırıcı bariyerlerle rüzgarın buharlaşmayı artırıcı etkisinin azaltılması, tamamen kapalı su rezervuarlarının inşa edilmesi, ağaçlar ile doğal gölgelik alanlar oluşturulması bu yönetime dahil edilebilir.

Biyolojik Örtüler: Bu yöntemde su yüzeyi, su yüzeyinde yetiştirilmeye uygun bazı su bitkileri ile doğal yollarla kaplanır. Diğer uygulamalara kıyasla maliyeti düşüktür ve aynı zamanda ekolojik dengeyi korur. Fakat uygulama kontrollü yapılmaz veya bakımlar aksatılırsa bitkiler su kalitesini olumsuz etkileyebilir.

Kimyasal Yöntemler

Kimyasal yöntemler su yüzeyine kimyasal bileşiklerin uygulanması yoluyla buharlaşmayı azaltmayı hedefler. Bu bileşenler genellikle alkol ve yağ bazlı bileşiklerdir ve su yüzeyinde ince bir tabaka oluşturarak su moleküllerinin buharlaşıp atmosfere geçişlerinin engellerler.

Kimyasal Örtüler: Su yüzeyinde özel kimyasal bileşiklerden oluşan çok ince bir film tabaka oluşturulmasıyla suyun doğrudan atmosferle temasının azalması sağlanır ve bu şekilde buharlaşma azaltılır. Bu yöntemin uygulanması kolay ve maliyeti düşüktür ancak rüzgar, yağmur, suda oluşacak dalgalanmalar nedeniyle etkinliği azalır ve düzenli olarak yineleme gerektirir. Biyolojik olarak parçalanabilir biyobozunur filmler çevreye ve su ekosistemine zarar vermeyen bir diğer seçenektir.

Polimer Kaplamalar: Hidrojeller veya su tutucu polimerler tarım arazilerinde suyun daha uzun süre toprakta kalmasını sağlayarak buharlaşmayı azaltabilirler.

Tuz ve Mineral Kullanımı: Bazı tuz ve mineraller suyun yüzey gerilimini değiştirerek buharlaşma hızını azaltabilmektedirler. Ancak bu yöntemin uygulanmasında seçilen alan önemlidir çünkü bazı su kaynakları için tuzluluk sorunu oluşturabilmektedir.


4.3 Veri Analizi

Bu çalışmada 2000-2023 yılları arasındaki buharlaşma değerleri hem geleneksel yöntemlerle hem de yapay zeka aracılığı ile hesaplanacak ve karşılaştırılacaktır. Çalışmanın yapay zeka ile model oluşturma kısmında önce ham veriler kullanılacak daha sonra veri seti gerekli işlemlere tabii tutularak işlenecek ve oluşturulan modeller karşılaştırılacaktır. Çalışmada kullanılacak veriler aylık ortalamaları analiz etmek ve mekânsal-zamansal varyasyonlarını incelemek için doğrudan NASA GES DISC platformundan indirilmiştir. NASA Goddard Yer Bilimleri Veri ve Bilgi Hizmetleri Merkezi (GES DISC) tarafından sağlanan GLDAS Noah Land Surface Model L4 Aylık 0.25 x 0.25 Derece V2.1 veri seti kullanılmıştır. GLDAS-2.1 simülasyonu, Ocak 1, 2000 tarihinde başlatılmış ve GLDAS-2.0 simülasyon koşulları temel alınmıştır. Model, çeşitli atmosferik ve yüzeysel verilerle desteklenmiştir. GLDAS-2.1 veri üretimi, National Oceanic and Atmospheric Administration (NOAA) Global Data Assimilation System (GDAS) atmosferik analiz alanları [31] Global Precipitation Climatology Project (GPCP) V1.3 Günlük Analiz yağış alanları [32,33] ve Air Force Weather Agency (AFWA) tarafından sağlanan AGRicultural METeorological Model (AGRMET) radyasyon verileri kullanılarak gerçekleştirilmiştir.

The Global Land Data Assimilation System (GLDAS), Dünya genelinde kara yüzeyindeki nem, buharlaşma ve duyulur ısı akısı gibi durum ve akış bileşenlerini modellemek amacıyla kullanılan dört kara yüzey modeli (CLM, Mosaic, Noah ve VIC) tarafından üretilen veri setlerini sunmaktadır. Bu veriler, NASA Goddard Yer Bilimleri Veri ve Bilgi Hizmetleri Merkezi'nin (GES DISC) bir bileşeni olan Hidroloji Veri ve Bilgi Hizmetleri Merkezi (HDISC) aracılığıyla erişilebilir durumdadır. GLDAS'ın mevcut veri arşivi, 1979'dan günümüze kadar olan dönemi kapsayan, 1.0 derecelik çözünürlükte dört modelden elde edilen veri ürünlerini ve 2000 yılından günümüze kadar


olan dönemi kapsayan, 0.25 derecelik çözünürlükte Noah modeli ürünlerini içermektedir [34].

Veri seti 2000-2023 yılları arasında Türkiye sınırları için hava sıcaklığı, nem, rüzgar, radyasyon ve buharlaşma miktarını içermektedir. Verilere ait histogramlar ve verilerin coğrafik dağılımları aşağıda verilmiştir.




Şekil 8. Hava sıcaklığı verisi histogram ve dağılımı.

Hava sıcaklığı verisi ölçümleri Kelvin cinsindedir ve aylık periyotlara sahiptir. Buharlaşmanın yapısında önemli bir yere sahiptir. Hava sıcaklığındaki artışın buharlaşma değerinde artışa sebep olması beklenir. Geleneksel buharlaşma yöntemlerinde yaygın olarak Celcius cinsinde kullanılır.




Şekil 9. Spesifik nem verisi histogram ve dağılımı.

Spesifik nem (özgül nem) değişkeninin dağılımı şekil 10 da verilmiştir. Nem, buharlaşma üzerinde belirli bir seviyeye kadar artış sağlar fakat su yüzeyinde hava hareketinin yokluğu durumunda hava nem açısından doymun hale geleceği için buharlaşma durur.




Şekil 10. Rüzgar hızı verisi histogram ve dağılımı.

Rüzgar hızı verisi su yüzeyinden 10 metre yukarıda ölçülmüştür. Uygun düzenleme yöntemleri ile gerekli görüldüğü zaman yüzeyden 2 metre yüksekteki rüzgar hızına dönüşümü sağlanabilir. Rüzgar hızı, su yüzeyindeki doygun havanın taşınımını yaparak buharlaşmanın devamlılığını sağlayan bir etkidir.




Şekil 11. Net kısa dalga radyasyonu verisi histogram ve dağılımı.

Şekil 11’de dağılımı verilen net kısa dalga radyasyonu mevsimsel döngülere ve konuma göre değişiklik gösterir. Yeryüzüne ulaşan radyasyondaki artış buharlaşmada artışa sebep olur.



Şekil 12. Buharlaşma verisi histogram ve dağılımı

Şekil 12’de buharlaşma verisine ait dağılım görülmektedir. Buharlaşma verisi birçok parametreye bağlıdır fakat bu çalışmada sıcaklık, radyasyon, nem, rüzgar hızı değişkenleri altında incelenecektir.



Şekil 13. Verilerin coğrafi dağılımı.

Şekil 13’te enlem ve boylamlara göre verilerin bulunduğu noktalar işaretlenmiştir. Büyük çoğunlukla verilerin coğrafik noktalarının dağılımı dengeli görülmektedir. Bu dengeli dağılım geniş alanda bir çalışma yapılacağı için önem taşımaktadır.

Modellemeden önce verilerin aylık dağılımını daha iyi anlayabilmek için aylık bazda 2000-2023 yılları arası tüm verilerin aylık ortalamaları, medyanlar ve standart sapmaları kontrol edilmiştir.

Tablo 1. Hava sıcaklığı verisi için aylık istatistiksel analiz.

Ay	Ortalama	Medyan	Standart Sapma
1	284.619382	284.589462	9.552710
2	284.618823	284.621520	9.575131
3	284.634367	284.667510	9.560878
4	284.619304	284.784439	9.559903
5	284.636197	284.810058	9.562390
6	284.620306	284.683166	9.547206
7	284.624486	284.675704	9.572513
8	284.627442	284.701126	9.560231
9	284.618311	284.643051	9.569669
10	284.631819	284.697494	9.565052

11	284.612801	284.703048	9.556558
12	284.624605	284.645858	9.570213

Tablo 1’de değerleri verilen, hava sıcaklığı (Kelvin) verisine yapılan istatistiksel analiz sonucunda ortalamalar incelendiğinde neredeyse sabit bir sıcaklık değeri olduğu görülmektedir. Yıllık döngüde önemli bir değişiklik olmadığı söylenebilir. Ortalama ve medyan değerleri birbirine oldukça yakındır ve bu sonuç sıcaklık dağılımının simetrik olduğunu ifade etmektedir. Standart sapma 9.55 civarındadır yani hava sıcaklığı verileri yıllık döngülerde benzer bir varyansa sahiptir.

Tablo 2. Özgül nem verisi için aylık istatistiksel analiz.

Ay	Ortalama	Medyan	Standart Sapma
1	0.005832	0.005483	0.002191
2	0.005829	0.005481	0.002190
3	0.005829	0.005499	0.002175
4	0.005828	0.005502	0.002187
5	0.005829	0.005503	0.002192
6	0.005834	0.005502	0.002203
7	0.005831	0.005505	0.002197
8	0.005832	0.005518	0.002182

9	0.005827	0.005501	0.002179
10	0.005825	0.005509	0.002176
11	0.005828	0.005489	0.002195
12	0.005829	0.005474	0.002199

Tablo 2’de sonuçları verilen istatistiksel analize bakıldığında aylık nem ortalamalarının oldukça düşük olduğu ve çok büyük bir değişiklik göstermediği anlaşılmaktadır. Medyan ve standart sapma değerlerinde de aylık değişikliklerin çok küçük olduğu görülmektedir.

Tablo 3. Rüzgar hızı verisi için aylık istatistiksel analiz.

Ay	Ortalama	Medyan	Standart Sapma
1	2.946078	2.824699	0.852992
2	2.946107	2.822023	0.852299
3	2.947987	2.828845	0.856486
4	2.944627	2.820602	0.854510
5	2.946719	2.816988	0.856644
6	2.945030	2.818580	0.853715
7	2.945906	2.819010	0.854066

8	2.945532	2.818997	0.857294
9	2.943459	2.820559	0.857519
10	2.946948	2.820671	0.860389
11	2.944650	2.817191	0.857117
12	2.946717	2.822486	0.856924

Rüzgar hızı verisinin yukarıdaki tabloda verilen aylık istatistiksel sonuçları incelendiğinde büyük değişiklikler göstermediği görülmektedir. Standart sapma değeri ortalama olarak 0.85 civarındadır yani rüzgar hızında bazı zamanlarda doğal dalgalanmalar olduğu fakat büyük sapmalar olmadığı anlaşılmıştır.

Tablo 4. Net kısa dalga radyasyonu verisi için aylık istatistiksel analiz.

Ay	Ortalama	Medyan	Standart Sapma
1	153.287773	151.195686	76.378435
2	153.362547	152.185585	76.439291
3	153.525657	152.244659	76.321797
4	153.320130	152.493797	76.442316
5	153.333357	151.639015	76.602241
6	153.239606	151.134712	76.406544

7	153.337051	151.539474	76.497242
8	153.360735	151.038444	76.305637
9	153.388214	150.697296	76.401995
10	153.519705	151.884010	76.555383
11	153.260931	151.845123	76.555189
12	153.337904	150.931190	76.648037

Net kısa dalga radyasyonu verisinin istatistiksel analizi incelendiğinde diğer değişkenlere kıyasla daha fazla dalgalanma gerçekleştiği görülmektedir. Medyan ve ortalama değerlerinin birbirine yakın olması bu verinin normal bir dağılıma yakın olduğunu ifade etmektedir.

Tablo 5. Açık su yüzeyinden buharlaşma verisi için aylık istatistiksel analiz.

Ay	Ortalama	Medyan	Standart Sapma
1	4.819823	3.095684	5.294084
2	4.859834	3.141330	5.346941
3	4.838383	3.095285	5.368889
4	4.829270	3.096457	5.318404
5	4.829310	3.097721	5.317140

6	4.803709	3.105493	5.256635
7	4.846119	3.096840	5.355501
8	4.819533	3.083487	5.342814
9	4.855620	3.114455	5.370986
10	4.855274	3.096004	5.406413
11	4.830518	3.107388	5.284892
12	4.819823	3.095684	5.294084

Aylık bazda buharlaşmanın medyan değeri aylık ortalamalardan düşük çıkmıştır ki bu bazı yüksek buharlaşma değerlerinin genel ortalamayı yükselttiği anlamına gelmektedir. Standart sapması incelendiğinde ise buharlaşma verilerinde diğer değişkenlere nispeten daha geniş bir yayılım olduğu görülmektedir. Medyan değeri ise ortalama dan düşük olarak sonuçlanmıştır. Bu sonuç buharlaşma verisi değişkeninde pozitif bir çarpıklık olduğunu ifade etmektedir.

Yukarıdaki tablolar incelendiğinde hava sıcaklığı, rüzgar ve nem verilerinin aylık olarak çok fazla değişiklik göstermediği görülmektedir. Buna karşın net kısa dalga boyu ve buharlaşma değişkenlerinde aylık bazda standart sapma değerleri daha yüksektir. Net kısa dalga boyu ve açık su yüzeyinden buharlaşmayı ifade eden değişkenlerin mevsimsel etkilerden ve konumdan en çok etkilenen veriler olduğu göz önünde bulundurulmalıdır.

4.3.1. Veri Setine Uygulanan Ön İşlemler

Varyasyon ve Standart Sapma:


Varyasyon bir veri setindeki değerlerin ortalamasının etrafında nasıl dağıldığını gösteren bir istatistiksel kavramdır. Standart sapma Denklemi buraya yazın. ise varyasyonun karekökü olarak açıklanabilir.

$$varyasyon = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \quad (11)$$

her iki formülde de x_i tekil veri noktalarını, $\bar{x}$ ise verilerin ortalamasını ve n veri sayısını ifade eder.

$$standart\ sapma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (12)$$

Bu iki formülde akış, sıcaklık gibi hidrolojik verilerde değişkenliği anlamak için kullanılır. Özellikle ekstrem olayları ve bu olayların sıklıklarını anlamak için faydalıdır.



Şekil 14. Değişkenlerin standart sapması.

Hareketli Ortalama ve Hareketli Standart Sapma:


Hareketli ortalama belirli bir zaman aralığındaki verilerin ortalamasını alarak zaman serisinin trendini gözlemlemeye yarayan bir yöntemdir. Hareketli standart sapma ise hareketli ortalama yöntemiyle belirlenen zaman aralıklarındaki verilerin standart sapmasının hesaplanmasıdır.

$$hareketli\ ortalama = \frac{\sum_{i=t-k+1}^t x_i}{k} \quad (13)$$


Burada k, hareketli ortalama için seçilen zaman aralığını belirtir.

$$hareketli\ standart\ sapma = \sqrt{\frac{\sum_{i=t-k+1}^t (x_i - H.Ortalama_t)^2}{k}} \quad (14)$$

Hidrolojik verilerde aşırı değişkenlik gösteren dönemleri tespit etmekte fayda sağlayan uygulamalardır.




Şekil 15. Hareketli ortalama.



Şekil 16. Hareketli standart sapma.

Korelasyon Analizi:

İki değişken arasındaki ilişkinin gücünü ve yönünü açıklayan bir matrisin oluşturulmasıdır. İki hidrolojik parametre arasındaki doğrusal gücün anlaşılmasını sağlar.




Şekil 17. Korelasyon matrisi.

Yapılan korelasyon analizi sonucunda, hedef değişken olan buharlaşma en yüksek doğrusal ilişkiyi nem ile göstermiştir. Bu durum atmosferik nem oranının buharlaşma süreçlerini doğrudan etkilediğini göstermektedir. Benzer şekilde radyasyon ile buharlaşma arasında orta düzeyde pozitif bir ilişki ($r = 0.3596$) tespit edilmiştir; bu da güneşten gelen net kısa dalga radyasyon miktarının artmasıyla buharlaşmanın arttığını ortaya koymaktadır. Hava sıcaklığı değişkeni ile buharlaşma arasında daha zayıf bir ilişki ($r = 0.1942$) bulunmuş, bu da sıcaklığın tek başına buharlaşma üzerinde sınırlı bir etkisi olduğunu düşündürmektedir. Rüzgar değişkeni ile buharlaşma arasında ise çok zayıf ve negatif bir korelasyon ($r = -0.0588$) gözlenmiş olup, bu veri seti özelinde rüzgarın buharlaşmaya olan etkisinin ihmal edilebilir düzeyde olduğunu göstermektedir. Öte yandan, değişkenler arası güçlü korelasyonlar da dikkat çekicidir; özellikle hava sıcaklığı ile radyasyon ($r = 0.8322$) ve hava sıcaklığı ile nem ($r = 0.7591$) arasındaki yüksek ilişki, modelleme sürecinde çoklu doğrusal bağlantı sorununa yol açabilmektedir.

Trend Analizi:

Bir zaman serisindeki uzun vadeli eğilimlerin tespit edilmesini sağlar. Hidrolojik verilerin mevsim değişikliği etkileri altında olan ve iklim değişikliğine bağlı olan veriler olmasından kaynaklı olarak eğilimlerinin trend analizi ile tespit edilmesi önem taşımaktadır. Bu yöntem aynı zamanda su yönetimi planlamasına katkı da sağlayabilir.



Şekil 18. Değişkenlerin trend analizi


2000–2023 yılları arasındaki GLDAS verileri kullanılarak seçili meteorolojik değişkenler için doğrusal trend analizi gerçekleştirilmiştir. Şekil 18’de görülebileceği üzere her bir değişkenin zaman içerisindeki genel eğilimi, MATLAB ortamında lineer regresyon yöntemiyle belirlenmiş ve sonuçlar görsel olarak sunulmuştur. Analiz sonuçlarına göre; hava sıcaklığı (Tair), nem (Qair) ve net kısa dalga radyasyon (SWnet) gibi değişkenlerde hafif artış eğilimi gözlemlenmiştir. Bu eğilimler, iklim değişikliğinin bölgesel yansımaları açısından önemli bulgular sunmakta olup, uzun dönemli hidrolojik ve atmosferik modeller açısından da temel girdi olarak değerlendirilebilir.

Z-Skor:

Bir veri noktasının ortalamadan kaç standart sapma uzakta olduğunu gösteren bir ölçüdür. Bu standardizasyon yöntemi değişkenlerin farklı ölçeklerde olduğu durumlarda veriyi

normalize eder. Özellikle doğrusal regresyon gibi ölçek farkına duyarlı makine öğrenmesi modellerinde kullanılacak veri setleri için tercih edilir. Her veri noktası için z-score hesaplama işlemi aşağıdaki denklemle yapılır.

$$Z = \frac{\chi - \mu}{\sigma} \quad (15)$$



Şekil 19. Değişkenlerin Z-Skor değerleri.

Zaman serilerinin karşılaştırılabilirliğini artırmak ve olası anomalileri belirlemek amacıyla, her bir değişkenin Z-skor normalizasyonu yapılmıştır. Bu yöntemle, her veri noktası kendi ortalamasına ve standart sapmasına göre yeniden ölçeklendirilmiştir. Z-skorları kullanılarak elde edilen grafiklerde; sıcaklık (Tair), nem (Qair), net kısa dalga radyasyon (SWnet) ve buharlaşma (ECanop) değişkenlerinin mevsimsel döngüleri belirgin bir şekilde görülmekte olup, bu döngülerin bazı yıllarda daha şiddetli sapmalar içerdiği dikkat çekmektedir. Özellikle rüzgâr hızı (Wind) değişkeni, diğerlerinden farklı olarak daha düzensiz ve geniş bir dağılım sergilemekte, bu da değişkenin yüksek volatilitesine işaret etmektedir. Z-skor grafiklerinde görülen ani yükseliş veya düşüşler, veri kümesindeki potansiyel anomali dönemlerini tespit etmek için önemli ipuçları sunmaktadır. Bu analiz, uzun dönemli gözlemlerde iklimsel değişkenliklerin ve uç değerlerin daha net ortaya konmasına olanak sağlamıştır.

IQR (Interquartile Range):

Veri setindeki merkezi dağılımı ölçmek için kullanılan bir yayılım ölçüsüdür. Verinin birinci çeyreği ile üçüncü çeyreği arasındaki farkı ifade eder.

$$IQR = Q_3 - Q_1 \quad (16)$$

Aşırı uçları belirlemek için alt ve üst sınır değerleri hesaplanır.

$$alt\ sınır = Q_1 - k \times IQR \quad (16.1)$$

$$üst\ sınır = Q_3 + k \times IQR \quad (16.2)$$

Burada k katsayısı, veri setinde çok fazla uç değer yoksa veya daha az uç değer temizlenmesi gerekiyorsa genellikle 3 olarak , uç değerlerden daha fazla arındırılması gerekiyorsa genellikle 1.5 olarak seçilir.

Winsoring:

Bu işlem uç değerleri tamamen kaldırmak yerine belirli bir yüzdelik dilimle sınırlandırmak için kullanılır. Verinin belirlenen yüzdelik diliminin dışındaki uç noktalar sınırlandırılır ve böylece belirli bir bölgede dağılım yoğunlaştırılmış olur. Bu yöntemle uç değerler tamamen silinerek veri kaybına uğrama probleminin önüne geçilmiş ve gerçeğe daha yakın bir dağılımla çalışma olanağı sağlanmış olur.

Sin-Cos Dönüşümü:

Ay, gün, saat gibi zaman verileri döngüsel değişkenlerdir. Dolayısıyla veri seti içinde bu değişken periyodik olarak kendisini tekrar eder. Zamana dair verilere sin-cos dönüşümü uygulamak verinin matematiksel sürekliliğini koruyarak modelin öğrenmesini kolaylaştırır. Bir periyodik değişkeni sinüs ve cosinüs bileşenlerine ayırırken aşağıdaki formüller kullanılır.

$$\sin = \sin(2\pi \times \frac{x}{T}) \quad (17)$$

$$\cos = \cos(2\pi \times \frac{x}{T}) \quad (18)$$

Gaussian Smoothing:

Bu işlemle veri setindeki gürültünün azaltılır, trendler daha belirgin hale gelir ve küçük dalgalanmalar düzeltildiği için model iyileştirilmiş olur. Bu yöntemin temeli Gauss fonksiyonu ile yapılan ağırlıklı ortalamaya dayanır.

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} \quad (19)$$

Lag Features:

Zaman serisi analizlerinde yaygın olarak kullanılır. Bir değişkenin önceki bir zamandaki değerini yeni değişken olarak kullanıp gelecekteki tahminleri iyileştirmeyi amaçlar. Bu tür geçmiş değerlere lag (gecikme) değişkeni adı verilir. Çalışılan alan, veri seti, modelleme detayları gibi faktörler dikkate alınarak lag1, lag9 gibi değişkenler eklenerek kullanılır. Burada 1 ve 9 gibi seçilen değerler kaç zaman birimi önceki değerin kullanılacağını belirler. Bu değişkeni kullanmak zaman serilerindeki dönerselliği yakalamak açısından önem taşır. Kullanılan veri setinde, örneğin bu çalışmada olduğu gibi, mevsimsel değişkenler varsa ve veriler periyodikse uygun lag değerlerini seçmek ve modele eklemek modelin doğruluğunu artırabilir. Fakat çok fazla lag değişkeni eklemek modeli oldukça karmaşık hale getirebilir. Bu seçimi yaparken verinin bağlı olduğu zaman değişkeni ve veri setinin uzunluğu dikkate alınmalıdır.

4.3.2 Model Sonuçlarının İstatistiksel Değerlendirilmesi ve Formülleri

İstatistik biliminde ve makine öğrenmesi ile oluşturulan modellerin performansını değerlendirmede kullanılan birçok yöntem vardır. Bu yöntemler geliştirilen çeşitli modellerin arasından performansı en yüksek olanı seçmede, geliştirilen modelleri kıyaslamada, modeldeki hataları analiz etmede, modelin parametrelerini iyileştirerek modeli optimize etmede kullanılan oldukça faydalı araçlardır. Bunlardan en yaygın olarak kullanılanları aşağıda açıklanmıştır.

R-Squared (R^2): R^2 değeri, ikili değerler arasındaki doğrusal bağıntıyı ölçerek modelin açıklayıcılık gücünü ifade eder. Sonuç 0 ile 1 arasındaki bir değerle verilir ve bu değer 1'e yaklaştıkça modelin veri setini daha iyi açıkladığı kabul edilir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (20)$$

Root Mean Square Error (RMSE): Oluşturulan modelin çıktıları ile referans olarak verilen gerçek değerler arasındaki farkların karelerinin ortalamasının karekökünün alınmasıyla hesaplanır. Model çıktısının hatalarının büyüklüğüne daha duyarlıdır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

Mean Absolute Error (MAE): Model çıktısının yani tahmin edilen değerlerle referans olarak verilen gerçek değerler arasındaki farkı dikkate almadan hataların ortalama büyüklüğüne odaklanır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (22)$$

Mean Squared Error (MSE): Hesaplanan hataların karelerinin ortalaması ile ifade edilir. RMSE değerinin karesine eşittir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (23)$$

Mean Absolute Percentage Error (MAPE): Tahmin edilen değerlerle gerçek değerlerin arasındaki farkı mutlak hata büyüklüğünü hesaplayarak yüzde cinsinden ifade eder.


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (24)$$

Yukarıdaki açıklamaların ışığında bu çalışmada yapay zeka ile oluşturulan modeller ile geleneksel buharlaşma hesaplama yöntemlerinin sonuçları aşağıda değerlendirilmiştir.


Tablo 6. Geleneksel buharlaşma hesaplama yöntemlerinin RMSE değerleri.

Method	RMSE
Penman-Monteith	19.389637
Romanenko	279.730224
Hargreaves-Samani	30.047260


Ritchie	29.946821
Meyer	13.949930
Penman	7.167252



Şekil 20. Referans veri ile formül çıktılarının karşılaştırılması.



Şekil 21. Referans veri ile formül çıktılarının karşılaştırılması.




Şekil 22. Referans veri ile formül çıktılarının tekil karşılaştırılması.


4.3.3. Ham Veri ile Çalışılan Model Sonuçları

Ensemble: Ensemble Learning yöntemlerinden biri olan Bagged Trees modeli doğruluğu artırmak için bootstrap aggregation kullanılır. Yani birçok karar ağacını rastgele seçilmiş veri setlerinde eğiterek birleştirir ve bütün tahminleri bir araya getirerek son tahmini oluşturur. Performansı artıran ve dengeli öğrenme sağlayan bir modeldir. Bu model ile

eđitilen veri setinin sonucunda RMSE deęeri 2.10 , R-Squared deęeri 0.84 , MSE deęeri 4.44 , MAE deęeri 1.31 olarak elde edilmiřtir.




řekil 23. Gerek deęerler ile tahmin edilen deęerler.



Şekil 24. Gerçek değerler ile artık değerler.


Ensemble regresyon modeli, ham veri ile eğitildiğinde genel olarak başarılı bir tahmin performansı sergilemiştir. Gerçek değerler ile tahmin edilen değerlerin karşılaştırıldığı Şekil 23'te veri noktalarının büyük çoğunluğu $y = x$ doğrusu çevresinde konumlanmakta olup, modelin orta düzey buharlaşma değerlerini başarılı şekilde öngörebildiği görülmektedir. Ancak yüksek buharlaşma değerlerinde tahminlerin sistematik olarak düşük kaldığı ve modelin bu uç değerlerde performans kaybı yaşadığı anlaşılmaktadır. Şekil 24'te bu durumu doğrulamakta; yüksek gerçek değerlerde pozitif artıkların yoğunluğu, modelin alt tahmin eğiliminde olduğunu göstermektedir. Bu nedenle modelin uç değerlerdeki başarısını artırmak amacıyla özellik mühendisliğinin kullanılması gerekmektedir.




Şekil 25. Ensemble modelinin sonuçları.

Şekil 25'te gerçek değerler ile tahmin edilen değerler kıyaslanmıştır. Mavi renk gerçek değerleri, sarı renk ise tahmin edilen değerleri temsil etmektedir. Şekilde de görüldüğü üzere gerçek değerler ve tahmin edilen değerler genel olarak birbirine yakındır. Model genel olarak başarılı sonuç vermiştir fakat ekstrem değerlerde veya bazı spesifik durumlarda iyileştirme yapılması gerekmektedir.

Gaussian Process Regression: Verinin temelini oluşturan fonksiyonun bir Gaussian süreci olduğunu varsayarak kovaryans fonksiyonu üzerinden tahmin yapan olasılık tabanlı bir yaklaşımdır. Çok çeşitli veri dağılımlarını ve karmaşık ilişkileri anlamada performansı yüksektir. Bu analiz ile RMSE değeri 2.63 , R-Squared değeri 0.75 , MSE değeri 6.96 , MAE değeri ise 1.78 olarak elde edilmiştir.




Şekil 26. Gerçek değerler ile tahmin edilen değerler.



Şekil 27. Gerçek değerler ile artık değerler.


Gaussian Process algoritması kullanılarak oluşturulan model, özellikle düşük ve orta düzeydeki buharlaşma değerlerinin tahmininde başarılı bir performans sergilemiştir. Model çıktılarında, tahmin edilen değerlerin büyük ölçüde gerçek değerlere yakınsadığı, ancak yüksek buharlaşma değerlerinde tahminlerin sistematik olarak düşük kaldığı gözlenmiştir. Bu durum, modelin uç değerleri öğrenmekte zorlandığını ve genellikle alt tahmin (underestimation) eğiliminde olduğunu göstermektedir. Artık (residual) analizleri de bu sapmaları doğrular niteliktedir; yüksek gerçek değerlerde pozitif artıkların artması, modelin bu değerleri yeterince temsil edemediğini ortaya koymuştur. Bununla birlikte, bazı tahminlerin negatif olması, fiziksel anlamda kabul edilemez sonuçlar doğurabileceğinden, model çıktılarının sınırlandırılması ya da ön işleme tabi tutulması önerilmektedir. Gaussian Process modeli, belirsizliklerin modellenmesi açısından avantajlı olmakla birlikte, veri setinin uç noktalarında performans artışı için iyileştirmeler yapılması faydalı olabilir.




Şekil 28. Gaussian Process Regression modelinin sonuçları.

Gaussian Process Regression modelinde tahminler gerçek değerlere makul oranda yaklaşıktır. Ancak R-Squared değerinin 0.75 olmasından da anlaşılacağı üzere geliştirmelere ihtiyaç duymaktadır.

Linear Regression: Doğrusal regresyon modeli bağımsız değişkenler arasındaki etkileşimler dahil ederek çalıştırılmıştır. Değişkenlerin özniteliklerinin etkisini doğrudan yorumlamayı sağlar. Bu model bağımsız değişkenler ile hedef değişkenlerin arasındaki ilişkinin doğrusal olduğunu varsaydığı için doğrusal olmayan karmaşık ilişkiler barındıran verilerde anlamlı sonuçlar vermeyebilir. Çalıştırılan model sonucunda RMSE değeri 3.79 , R-Squared değeri 0.49 , MSE değeri 14.41 , MAE değeri 2.67 olarak elde edilmiştir.




Şekil 29. Gerçek değerler ile tahmin edilen değerler.



Şekil 30. Gerçek değerler ile artık değerler.


Doğrusal regresyon modeli buharlaşma tahmini amacıyla oluşturulan modeller arasında en zayıf performansa sahip yöntem olarak öne çıkmıştır. Tahmin edilen değerlerin büyük oranda 0–20 aralığında yoğunlaşması, gerçek buharlaşma değerlerinin ise 45'e kadar çıkabilmesi, modelin özellikle yüksek değerleri temsil edemediğini göstermektedir. Bu durum, doğrusal modellerin veri setinde var olan karmaşık ve doğrusal olmayan ilişkileri açıklamada yetersiz kaldığını ortaya koymuştur. Artık analizleri de bu durumu desteklemekte, yüksek değerlerde sistematik sapmaların arttığı, yani modelin özellikle uç değerleri sürekli olarak düşük tahmin ettiği görülmektedir. Ayrıca bazı tahminlerin negatif çıkması, modelin fiziksel anlamda geçersiz sonuçlar üretebileceğini göstermektedir. Bu nedenle doğrusal regresyon modelinin bu tür çevresel tahminlerde tek başına yeterli olmadığı, daha karmaşık ve öğrenme kapasitesi yüksek algoritmaların tercih edilmesi gerektiği sonucuna varılmıştır.




Şekil 31. Linear Regression modelinin sonuçları.

Bu modelin sonucunda hata oranı yüksek çıkmıştır. Buharlaşıma doğrusal olmayan ilişkiler barındırdığı için model veriyi anlamlı olarak temsil edememiştir. Şekil 32’de görüldüğü üzere tahmin edilen değerler (sarı), gerçek değerlerin (mavi) altında kalmıştır.

Tree: Decision Tree modeline göre daha basit bir sistemle çalışır. Veri setini daha az bölmelere ayırıp daha büyük gruplar halinde inceler. Bu sebeple aşırı öğrenme riskini azaltan bir yapıdır. Doğrusal olmayan ilişkileri öğrenmekte performansı yüksektir.




Şekil 32. Gerçek değerler ile tahmin edilen değerler.



Şekil 33. Gerçek değerler ile artık değerler.


Bu model ise buharlaşma tahmininde düşük ve orta düzeyli değerlerde yüksek doğruluk sergilemiştir. Gerçek ve tahmin edilen değerlerin karşılaştırıldığı Şekil 32’de özellikle 0–25 aralığındaki gözlemlerin doğruluk çizgisine yakınsadığı, ancak 30 birim üzerindeki gerçek değerlerde modelin tahminlerinin sistematik olarak düşük kaldığı gözlemlenmiştir. Bu durum, yüksek buharlaşma değerlerinde modelin genelleme başarısının düştüğünü ve alt tahmin eğiliminde olduğunu ortaya koymaktadır. Şekil 33 bu gözlemi desteklemekte, gerçek değer arttıkça artıkların pozitif yönde sapma gösterdiği görülmektedir.




Şekil 34. Tree modelinin sonuçları.

Bu modelde RMSE değeri 2.44 , R-Squared değeri 0.79 , MSE değeri 5.96 , MAE değeri 1.54 olarak bulunmuştur. Hata oranının düşük olması modelin gerçek buharlaşma değerlerini anlamlı seviyede tahmin ettiğini gösteriyor. MSE değerinin RMSE ile uyumlu bir şekilde düşük olması da tahmin seviyesinin iyi olduğunu ifade etmektedir. Model 2.7 hidrolojik verilerde iyi bir performans göstermiştir fakat değerler incelendiğinde daha hassas bir modele ihtiyaç olduğu anlaşılmıştır.

Neural Network: Katmanlar halinde düzenlenmiş nöronlar üzerinden doğrusal olmayan fonksiyonları öğrenir. Bir veya birden fazla girdi katmanı kullanılabilir ve genellikle girdi katmanında daha fazla nöron bulunur bu da modelin karmaşık ilişkileri daha iyi öğrenmesini sağlar. Ancak derin katmanları olan modellere kıyasla genelleme yeteneği daha düşüktür. Daha fazla veriyle daha iyi çalıştığı için modelde az sayıda veri kullanılırsa aşırı öğrenme durumu gerçekleşebilir.




Şekil 35. Gerçek değerler ile tahmin edilen değerler.



Şekil 36. Gerçek değerler ile artık değerler.

Şekil 35 incelendiğinde modelin düşük ve orta buharlaşma düzeylerinde oldukça başarılı olduğu, ancak yüksek değerlere çıkıldıkça tahminlerin giderek azaldığı görülmektedir. Bu durum, modelin yüksek buharlaşma değerlerini öğrenmede yetersiz kaldığını ve sistematik bir alt tahmin eğiliminde olduğunu göstermektedir. Şekil 36'nın analizi de bu gözlemi doğrulamakta, düşük değerlerde negatif, yüksek değerlerde pozitif artan sapmalar gözlenmektedir. Bu tür bir dağılım, modelin gerçek değerler karşısında öngörülerini orta değerlere doğru çekme eğiliminde olduğunu ortaya koymaktadır.



Şekil 37. Neural Network modelinin sonuçları.

Neural Network modelinde RMSE 2.47 yani model iyi bir performans sergilemiştir. R-Squared değerinin 0.78 olması modelin tahminlerinde kayda değer bir başarı gösterdiğini ifade etmektedir. MSE değeri 6.13'tür ve bu değeri RMSE değeri ile birlikte değerlendirmek daha doğrudur. Bu bağlamda bu iki değer birbiriyle uyumlu şekilde düşük bulunmuştur. MAE değeri 1.64 olması ortalama mutlak hatanın oldukça düşük olduğu anlamına gelir ve tahminler anlamlıdır.


Bu bölümde kullanılan gerçek değerler ile tahmin edilen değerlerin oluşturduğu görsellerde yatay eksen gerçek değerleri, dikey eksen ise modelin tahmin ettiği değerleri ifade etmektedir. İdeal bir modelde tüm noktalar 45°lik doğru üzerinde ve/veya yakınında yer almalıdır. Bu ideal görüntü tahmin edilen değerlerin gerçek değerlerle aynı veya çok yakın olduğu anlamına gelir. Çalıştırılan modellerde tahminlerin dağılımı büyük ölçüde beklenen gibi fakat ekstrem değerlerde dağılımlar gözlenmektedir. Bir diğer görsel olan gerçek değerler ve artık değerlerin grafiklerinde ise yatay eksen gerçek değerler, dikey eksen tahmin edilen değerler yer almaktadır. Artık değer, tahmin edilen değer ile gerçek değer arasındaki farka verilen isimdir. Birebir tahmin yaptığı varsayılan

mükemmel bir modelde bu artık değerler simetrik bir şekilde sıfır çizgisine yakın dağılmalıdır. Çalıştırılan modellerde ise artık değerlerin genellikle sıfırın üzerinde ve altında dengeli bir dağılım gösterdiği anlaşıyor. Bu durum modelin hatalarının sistematik değil rastgele olduğu anlamına gelmektedir. Ancak ekstrem değerlerdeki artıklarda bir yayılma da gözlenmektedir, bu da modelin yüksek değerlerdeki tahminlerde daha az anlamlı sonuçlar ürettiği anlamına gelmektedir.

4.3.4. Ön İşleme Yapılan Veri ile Çalışılan Model Sonuçları


Veri seti yukarıdaki bölümlerde açıklanan ön işlemlere tabii tutularak veri özelliklerinin artırılması yoluyla model performansları tekrar değerlendirmeye alınmıştır. Yapay zeka aracılığı ile oluşturulan modellerde verilerin oluşturulacak modellere göre düzenlenmesi, modele problemi daha iyi anlaması için gerekli ek özelliklerin sağlanması model performansında büyük bir etkiye sahiptir.

Ensemble: Ön işlemler sonrası oluşturulan modeller arasında en iyi sonucun alındığı model ensemble olmuştur. Ensemble modelinde RMSE değeri 0.056, R-Squared değeri 0.93, MSE değeri 0.003, MAE değeri ise 0.035 olmuştur.




Şekil 38. Ensemble modelinin sonuçları.

Şekil 38’de yer alan “Response Plot for Predictions” grafiğinde Ensemble modelinin tahmin sonuçları (sarı noktalar) ile gerçek değerler (mavi noktalar) karşılaştırmalı olarak verilmiştir. Yatay ekseninde kayıt numaraları, dikey ekseninde ise tahmin edilen ve gerçek ECanop değerleri yer almaktadır. Grafikte sarı ve mavi noktaların büyük ölçüde üst üste binmesi, modelin gerçek değerlere oldukça yakın tahminler yaptığını göstermektedir. Bu durum, modelin genel olarak başarılı bir öğrenme süreci geçirdiğini ve veri içindeki yapıyı iyi temsil ettiğini ortaya koymaktadır. Ayrıca, tahminlerde sistematik bir sapma gözlemlenmemesi, modelin yüksek doğrulukta ve dengeli tahminler sunduğunu desteklemektedir. Grafikselsel olarak da modelin güvenilir ve genellenebilir bir yapıya sahip olduğu söylenebilir.




Şekil 39. Gerçek değerler ile tahmin edilen değerler.



Şekil 40. Gerçek değerler ile artık değerler.


İşlenmiş veri seti ve yeni özelliklerin (features) eklenmesiyle oluşturulan ensemble modeli, tahmin başarısı açısından önceki modellere kıyasla belirgin bir iyileşme göstermiştir. Modelin tahminleri, gerçek buharlaşma değerleriyle büyük ölçüde örtüşmekte, özellikle orta değer aralığında son derece yüksek doğruluk sunmaktadır. Artık analizinde görülen simetrik ve sıfır merkezli dağılım, modelin sistematik bir sapma içermediğini ve genelleme gücünün yüksek olduğunu ortaya koymaktadır. Özellikle düşük varyansla elde edilen tahminler, modelin stabilitesini ve doğruluğunu desteklemektedir. Bu bağlamda, işlenmiş veri ve feature mühendisliği süreçleri, ensemble algoritmasının performansını belirgin biçimde artırmış ve buharlaşma tahmininde güçlü bir araç olarak öne çıkmasını sağlamıştır.

Linear Regression: Linear regression modelleri arasında en iyi sonucu interactions linear vermiştir. Bu modelde RMSE değeri 0.093, R-Squared değeri 0.82, MSE değeri 0.0086, MAE değeri ise 0.064 ile sonuçlanmıştır.




Şekil 41. Linear Regression modelinin sonuçları.

Modelin R^2 değerinin yüksek olması, bağımsız değişkenlerin bağımlı değişken üzerindeki açıklayıcılığının oldukça iyi olduğunu göstermektedir. Bununla birlikte, modelin tahmin sonuçlarını içeren görsel incelendiğinde, tahmin edilen ECanop değerlerinin bazı durumlarda -0.2 seviyelerine kadar sapma gösterdiği görülmektedir. Bu durum, özellikle negatif tahminlerin fiziksel anlam taşımaması sebebiyle modelin bazı veri noktaları için güvenilirliğini zayıflatabileceğini işaret etmektedir. Yine de genel performans göz önünde bulundurulduğunda, bu modelin doğrusal regresyon teknikleri içinde güçlü bir alternatif sunduğu ve veri setindeki ilişkileri büyük oranda doğru yansıttığı söylenebilir.




Şekil 42. Gerçek değerler ile tahmin edilen değerler.



Şekil 43. Gerçek değerler ile artık değerler.


İşlenmiş veri seti ve zenginleştirilmiş değişkenler ile oluşturulan doğrusal regresyon modeli, ham veriyle oluşturulan modele kıyasla daha yüksek doğruluk ve daha dar hata aralığı sunmuştur. Gerçek değerlerle tahminlerin büyük oranda uyumlu olduğu görülmekle birlikte, yüksek buharlaşma değerlerinde modelin sistematik olarak alt tahmin yaptığı gözlenmiştir. Artık değerler bu sapmaları desteklemekte, modelin özellikle veri dağılımının uç noktalarında yeterince genelleme yapamadığını ortaya koymaktadır. Bu durum, doğrusal yapının karmaşık çevresel süreçleri temsil etmede sınırlı kalabildiğini göstermekte olup, daha gelişmiş regresyon tekniklerinin değerlendirilmesini gerekli kılmaktadır.

Tree: Medium tree ile oluşturulan modelde RMSE değeri 0.075, R-Squared değeri 0.88, MSE değeri 0.0056 ve MAE değeri 0.045 olmuştur.




Şekil 44. Tree modelinin sonuçları.

Medium Tree algoritması kullanılarak oluşturulan model, buharlaşma tahmininde yüksek başarı göstermiştir. Modelin çıktısının hata metrikleri değerlendirildiğinde, model veri setindeki varyansın büyük bir kısmını açıklamakta ve düşük hata payı ile tahmin yapabilmektedir. Grafiksel inceleme de bu durumu desteklemekte; modelin gerçek verilerle büyük ölçüde örtüştüğü, dönemsel dalgalanmaları etkili biçimde yakalayabildiği görülmektedir. Özellikle mavi (gerçek değer) ve sarı (tahmin edilen) noktaların üst üste gelmesi, tahmin başarısının yüksekliğini açıkça ortaya koymaktadır. Bu bağlamda Medium Tree algoritması, lineer olmayan ilişkileri ve karmaşık desenleri öğrenme kapasitesi sayesinde, buharlaşma tahmini için uygun ve güçlü bir yöntem olarak değerlendirilmiştir.




Şekil 45. Gerçek değerler ile tahmin edilen değerler



Şekil 46. Gerçek değerler ile artık değerler.


İşlenmiş veri setiyle eğitilmiş olan tree modeli özellikle orta aralıktaki buharlaşma değerlerinde yüksek tahmin doğruluğu sunmuş, ancak uç değerlerde sistematik hatalar sergilemiştir. Gerçek ve tahmin edilen değerler büyük ölçüde örtüşmekle birlikte, uç değerler söz konusu olduğunda modelin tahminleri düşmeye başlamış ve bu durum artık analizinde pozitif sapmalar olarak kendini göstermiştir. Modelin düşük değerlerde ise zaman zaman aşırı tahmin yaptığı gözlenmiştir. Bu bulgular, modelin tahmin kabiliyetinin belirli aralıklarda güçlü olduğunu ancak genelleme kabiliyetinin uç değerlerde sınırlı kaldığını göstermektedir.

Neural Network: Neural Network modelleri arasından Wide Neural Network en iyi sonucu vermiştir. Bu modelde RMSE değeri 0.084, R-Squared 0.85, MSE değeri 0.0071, MAE değeri 0.058 olmuştur.




Şekil 47. Neural Network modelinin sonuçları.

Şekil 47 modelin veri setindeki karmaşık ve doğrusal olmayan ilişkileri başarılı bir şekilde öğrenebildiğini ve genel tahmin performansının oldukça yüksek olduğunu göstermektedir. Grafikselsel olarak da model tahminleri ile gerçek değerler büyük ölçüde örtüşmekte, özellikle mevsimsel desenlerin takibi açısından tatmin edici bir performans sergilemektedir. Ancak tahminlerdeki yayılımın bazı düşük değerlerde arttığı gözlenmiş, bu da modelin özellikle düşük buharlaşma aralıklarında daha dikkatli kalibre edilmesi gerektiğini ortaya koymuştur. Bu kapsamda Wide Neural Network, karmaşık ilişkilerin öğrenilmesinde etkili bir yöntem olsa da model hassasiyetinin daha da artırılması için hiperparametre optimizasyonu gerekebilir.



Şekil 48. Gerçek değerler ile tahmin edilen değerler.



Şekil 49. Gerçek değerler ile artık değerler.

Neural Network modeli doğrusal olmayan yapıları öğrenmede yüksek bir performans sergilemiştir. Tahminlerin büyük kısmı gerçek değerlere yakınsadığı gibi, artık dağılımı da genellikle sıfır merkezli ve dengelidir. Bununla birlikte, modelin yüksek buharlaşma değerlerini hafife alma eğiliminde olduğu ve bu bölgelerde artıkların pozitif yönde sapma gösterdiği görülmektedir. Bu durum, sinir ağlarının uç değerlerde zaman zaman genelleme zorluğu yaşadığını ve tahminlerin ortalamaya doğru çekildiğini göstermektedir.


Tablo 7. Modellerin sonuç değerlerinin karşılaştırılması.

Model	Ham Veri RMSE	Ham Veri R-Squared	İşlenmiş Veri RMSE	İşlenmiş Veri R-Squared
Linear Regression (Linear)	4.46	0.29	0.13	0.60
Linear Regression (Interactions Linear)	3.79	0.49	0.093	0.82

Linear Regression (Robust Linear)	5.20	0.04	0.093	0.51
Stepwise Linear Regression	4.10	0.40	-	-
Tree (Fine Tree)	2.59	0.76	0.076	0.88
Tree (Medium Tree)	2.44	0.78	0.075	0.88
Tree (Coarse Tree)	2.44	0.79	0.080	0.86
SVM (Linear SVM)	26.76	-24.20	0.14	0.57
SVM (Quadratic SVM)	26.71	-24.10	0.095	0.81
SVM (Cubic SVM)	19.05	-11.77	0.085	0.85
SVM (Fine Gaussian SVM)	29.43	-29.48	0.085	0.85
SVM (Medium Gaussian SVM)	29.49	-29.59	0.075	0.88
SVM (Coarse Gaussian SVM)	31.59	-34.11	0.099	0.79
Efficient Linear (Least Squares)	4.97	0.12	0.13	0.60
Efficient Linear (SVM)	5.14	0.07	0.14	0.57
Ensemble (Boosted Trees)	2.86	0.71	0.11	0.74
Ensemble (Bagged Trees)	2.10	0.84	0.056	0.93
Gaussian Process Regression (Squared Exponential)	2.63	0.75	-	-
Gaussian Process Regression (Matern 5/2)	2.95	0.69	-	-
Gaussian Process Regression (Exponential)	3.75	0.50	-	-
Gaussian Process Regression (Rational Quadratic)	2.96	0.68	-	-

Neural Network (Narrow)	2.74	0.73	0.099	0.79
Neural Network (Medium)	2.61	0.75	0.091	0.82
Neural Network (Wide)	2.47	0.78	0.084	0.85
Neural Network (Bilayered)	2.64	0.75	0.093	0.81
Neural Network (Trilayered)	2.60	0.76	0.092	0.82
Kernel (SVM)	2.80	0.72	-	-
Kernel (Least Squares Regression)	2.73	0.73	-	-

Yukarıdaki tabloda bu çalışmada oluşturulan tüm modellerin hata metrikleri verilmiştir. Yürütülen çalışma kapsamında farklı makine öğrenmesi algoritmaları hem ham veriyle hem de ön işleme tabi tutulmuş verilerle eğitilerek model performansları karşılaştırılmıştır. Ham veri kullanılarak elde edilen sonuçlarla karşılaştırıldığında, ön işleme aşamasının model başarısını önemli ölçüde artırdığı görülmektedir. Özellikle Ensemble (Bagged Trees) modeli, işlenmiş veriyle çalıştırıldığında en düşük RMSE (0.056) ve en yüksek R-Squared (0.93) değerlerine ulaşarak, tüm modeller arasında en başarılı sonuçları vermiştir. Bu durum, bu modelin hedef değişkeni değerlerini yüksek doğrulukla tahmin edebildiğini göstermektedir.




Şekil 50. Ham veri modelleri RMSE değerleri.

Lineer regresyon tabanlı modeller incelendiğinde, en iyi performansın Interactions Linear modeli ile elde edildiği gözlemlenmiştir. Ancak bu modelin bazı değerler için negatif tahminler ürettiği gözlemlenmiş, bu durum fiziksel gerçeklik açısından modelin sınırlı güvenilirlikte olduğuna işaret etmektedir.

Ağaç temelli modellerden Medium ve Coarse Tree modelleri başarılı sonuçlar sunmuş, GPR modelleri ise veri setinin işlendikten sonra çok büyük olmasından kaynaklı olarak oluşacak olan sayısal tutarsızlık nedeniyle yalnızca ham verilerle test edilmiş, en iyi sonucu Squared Exponential kernel ile elde etmiştir.

Destek Vektör Regresyonu (SVR) tabanlı modellerin ham veriyle elde edilen sonuçlarının büyük oranda başarısız olduğu, hatta negatif R-Squared değerleri ürettiği görülmüştür.

Ancak işlenmiş verilerle özellikle Medium Gaussian SVM modelinin RMSE değeri 0.075, R^2 değeri ise 0.88'e ulaşarak etkili bir performans sergilediği dikkat çekmektedir. Benzer şekilde, geniş yapılı yapay sinir ağı (Wide Neural Network) modeli de düşük RMSE (0.084) ve yüksek R-Squared (0.85) değerleriyle başarılı tahminler gerçekleştirmiştir.



Şekil 51. İşlenmiş veri modelleri RMSE değerleri.

Sonuç olarak, ön işleme adımları sayesinde model doğruluğu büyük ölçüde artırılmış, özellikle Ensemble (Bagged Trees) modelinin ön plana çıktığı tespit edilmiştir. Bu bulgular, farklı model türlerinin karşılaştırmalı performans analizlerinin veri madenciliği uygulamalarında ne denli önemli olduğunu ortaya koymaktadır.

5.BÖLÜM: SONUÇLAR

Bu çalışmada geleneksel buharlaşma hesaplama yöntemleri ile yapay zeka ile geliştirilen modeller NASA GES DISC platformundan elde edilen veriler aracılığı ile karşılaştırılmıştır. Veri seti 2000-2023 yılları arasında aylık bazda hava sıcaklığı, nem, rüzgar hızı, radyasyon ve buharlaşma (referans) değişkenlerini içermektedir. Geleneksel buharlaşma hesaplama yöntemlerinden standart olarak kabul edilen FAO Penman-Monteith, Penman, Meyer, Romanenko, Hargreaves-Samani ve Ritchie formülleri kullanılmıştır. Geleneksel hesaplama yöntemleri çoğunlukla yerel kalibrasyon için katsayı belirlenmesi ihtiyacı yaratmaktadır fakat bu çalışmada katsayı eklenmemiştir. Çalışmanın bu aşamasında en iyi performansı Penman buharlaşma formülü sergilemiştir. Penman buharlaşma formülünü takiben sırasıyla Meyer, Penman-Monteith ve Ritchie Formülleri gelmektedir. En kötü sonuç ise Romanenko formülünden alınmıştır.

Yapay zeka ile model geliştirmek için Matlab Programı kullanılmıştır. Matlab programında bulunan birçok modelleme seçeneği çalıştırılmıştır ancak burada Linear Regression, Tree, Gaussian Process Regression, Neural Network ve Ensemble modellerinden söz edilmiştir.

Ham veriler üzerinde yapılan analiz ve yine ham veriler ile yapılan modelleme sonucunda en düşük hata Ensemble (Bagged Trees) modelinde RMSE değeri 2.10 olarak bulunmuştur. Bu model anlamlı sonuçlar tahmin etmede diğer modellere kıyasla daha yüksek bir performans sergilemiştir. Ensemble modelini takiben Coarse Tree ve Wide Neural Network 2.44 ve 2.47 ile anlamlı sonuçlar vermiştir. Gaussian Process modelinde doğrusal olmayan ilişkileri yakalayabilmiş olsa da diğer modellere kıyasla etkisi düşük kalmıştır. Linear Regression modeli en zayıf model olarak bulunmuştur. Ham veri ile yapılan çalışmalar neticesinde iyi düzeyde modellemeler elde edilmiş olsa da veriler üzerinde çalışmalar gerçekleştirerek modellerin iyileştirilmesi gerektiği düşünülmüştür. Fakat yapay zekanın günümüzde geldiği nokta, karmaşık veriler üzerindeki yüksek performansı ve anlamlı modeller oluşturması ile bir kez daha kanıtlanmıştır.

Model performanslarının kıyaslanabilmesi ve verilerin ön işlemlerden geçirilerek modele daha fazla özellik eklenmesinin performans üzerindeki etkisini anlayabilmek için, veriler ilgili bölümde açıklanan ön işlemlere tabi tutulmuştur. İşlenmiş veriler üzerinde gerçekleştirilen modelleme çalışmalarında, ham veriye kıyasla hata oranlarında önemli

ölçüde düşüş sağlandığı ve modellerin doğruluk seviyelerinde anlamlı bir artış gözlemlenmiştir. Özellikle Ensemble (Bagged Trees) modeli, RMSE değeri 0.056 ve R-Squared değeri 0.93 ile tüm modeller arasında en yüksek başarıyı göstermiştir. Bu modelin ardından sırasıyla Medium Gaussian SVM ve Medium Tree modelleri 0.075 RMSE değeri ve 0.88 R-Squared değeri ile başarılı tahminler gerçekleştirmiştir. Neural Network (Wide) modeli de benzer şekilde düşük hata ve yüksek doğruluk sunarak etkili bir performans sergilemiştir. İşlenmiş verilerle birlikte Linear Regression (Interactions Linear) modelinin performansı da dikkate değer düzeyde bir artış gözlenmiştir.

Bu sonuçlar, veri ön işleme sürecinin model başarısını doğrudan etkilediğini ve veri madenciliğinde kritik bir adım olduğunu ortaya koymuştur. Elde edilen bulgular, makine öğrenmesi yöntemlerinin doğru veri hazırlığı ile birleştğinde karmaşık yapıları çözümleyebildiğini ve yüksek doğrulukla tahminler gerçekleştirebildiğini bir kez daha kanıtlamaktadır.

Buharlaşma atmosfer ve su yüzeyi arasında gerçekleşen birçok faktörün hem doğrudan etkisiyle hem de değişkenlerin birbiri üzerinde bulunan etkisi ve etkileşimiyle karmaşık bir süreçtir. Bu sebeple buharlaşmayı modellemek için seçilecek yöntemler bu karmaşık, çok faktörlü yapıyı doğru ve yeterli şekilde temsil edebilmelidir.

KAYNAKÇA

1. Doğan,A., 2019. Namazgâh Barajına Ait Buharlaşma Miktarının Yapay Sinir Ağı İle Tahmin Edilmesi. Kocaeli Üniversitesi, Fen Bilimler Enstitüsü, Yüksek Lisans Tezi, Kocaeli
2. Doğan, S., 2020. Günlük Buharlaşma Miktarının Yapay Sinir Ağları Metotları ve Klasik Yöntemlerle Tahmini. İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İskenderun
3. Özdülkar,K., 2021. Günlük Referans Buharlaşma Miktarının Yapay Zeka Yöntemleri ve Ampirik Denklemler ile Tahmini. İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İskenderun
4. Tütüncü,Ö.,2022. Yapay Sinir Ağları (YSA) Modeli ile Su Yüzeyinden Buharlaşmanın Tahmini: Atatürk Barajı Örneği. Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Bilecik
5. Korkmaz,M.S.,2015. Buharlaşma Kayıplarının Yüzer Fotovoltaik Paneller ile Azaltılması. İstanbul Teknik Üniversitesi, Meteoroloji Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul
6. Youssef, Y. W., Khodzinskaya, A., 2019. A review of evaporation reduction methods from water surfaces. In E3S web of conferences (Vol. 97, p. 05044). EDP Sciences.
7. Tian, W., Liu, X., Wang, K., Bai, P., Liu, C., Liang, X., 2022. Estimation of global reservoir evaporation losses. **Journal of Hydrology**, (Vol. 607, 127524).
8. Shiri, J., Dierickx, W., Pour-Ali Baba, A., Neamati, S., Ghorbani, M. A., 2011. Estimating daily pan evaporation from climatic data of the State of Illinois, USA using adaptive neuro-fuzzy inference system (ANFIS) and artificial neural network (ANN). **Hydrology Research**, **42**(6), 491-502.
9. Pallavi, K., Rajeev, S., 2016. Predicting reservoir evaporation using artificial neural network. **International Journal of Innovative Research in Science, Engineering and Technology**,(An ISO 3297: 2007 Certified Organization) Vol, 5.

10. Shirsath, P. B., Singh, A. K., 2010. A comparative study of daily pan evaporation estimation using ANN, regression and climate based models. **Water Resources Management**, 24, 1571-1581.
11. Doğan, E., Işık, S., Sandalcı, M., 2007. Günlük buharlaşmanın yapay sinir ağları kullanarak tahmin edilmesi. **Teknik Dergi**, 18(87), 4119-4131.
12. Özel, A., Büyükyıldız, M., 2019. Aylık buharlaşma tahmininde yapay zeka yöntemlerinin kullanılabilirliği. **Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, 8(1), 244-254.
13. Zhao, G., Gao, H., 2019. Estimating reservoir evaporation losses for the United States: Fusing remote sensing and modeling approaches. **Remote Sensing of Environment**, 226, 109-124.
14. Gökbülak, F., Özhan, S., 2006. Water loss through evaporation from water surfaces of lakes and reservoirs in Turkey. **Official Publication of the European Water Association, EWA**. 1-6.
15. Jansen, F. A., Uijlenhoet, R., Jacobs, C. M., Teuling, A. J., 2021. Evaporation from a large lowland reservoir—observed dynamics during a warm summer. **Hydrol. Earth Syst. Sci. Discuss.**[preprint], 1-28.
16. Yaseen, Z. M., Al-Juboori, A. M., Beyaztas, U., Al-Ansari, N., Chau, K. W., Qi, C., ... Shahid, S., 2020. Prediction of evaporation in arid and semi-arid regions: A comparative study using different machine learning models. **Engineering applications of computational fluid mechanics**, 14(1), 70-89.
17. Qiao, D., Yang, M., Gao, Y., Hou, J., Zhang, X., Zhang, H. 2024. The optimization of evaporation rate in graphene-water system by machine learning algorithm. **Journal of Applied Physics**, 135(13), 135302.
18. Peng, Y., Zhang, D., Wang, W., Xu, G. 2024. An analysis of ensemble models for the water surface evaporation simulation in the Three Gorges Reservoir. **Theoretical and Applied Climatology**, 1-16.

19. Xu, C.-Y., Singh, V.P. 2001, Evaluation and generalization of temperature-based methods for calculating evaporation, **Hydrological Processes** (15,2): 305-319
20. Zhang, X., Hao, Z., Singh, V.P., Zhang, Y., Feng, S., Xu, Y., Hao, F., 2022, Drought propagation under global warming: Characteristics, approaches, processes, and controlling factors, **Science of The Total Environment** (838,2)
21. Helfer, F., Lemckert, C., Zhang, H., 2012, Impacts of climate change on temperature and evaporation from a large reservoir in Australia, **Journal of Hydrology** (475): 365-378
22. Bayazıt, M., 2013. Hidroloji, 978-975-511-364-9, İstanbul, 36-48.
23. Guide to Hydrological Practices volume1 hydrology-from measurement to hydrological information Sixth edition 2008 WMO-No. 168
24. T.C. Kalkınma Bakanlığı, Su kaynakları yönetimi ve güvenliği, On birinci kalkınma planı, 2018. (Web Sayfası: https://www.sbb.gov.tr/wp-content/uploads/2020/04/SuKaynaklariYonetimi_ve_GuvenligiOzellhtisaskomisyonuRaporu.pdf), (Erişim Tarihi: Ağustos 2024).
25. T.G.D.F., 2022. Türk gıda ve içecek sektöründe su riskleri ve sürdürülebilirliği için politika önerileri, (Web Sayfası: <https://www.tgdf.org.tr/wp-content/uploads/2022/01/TGDF-su-surdurulebilirligi-raporu.pdf>), (Erişim Tarihi: Eylül 2024).
26. T.C. Tarım ve Orman Bakanlığı, 2023. Değişen iklime uyum çerçevesinde su verimliliği strateji belgesi ve eylem planı (2023-2033), (Web Sayfası: https://suverimliliği.gov.tr/wp-content/uploads/2023/09/SU-VERIMLILIGI-STRATEJI-BELGESI-ve-EYLEM-PLANI_dikey_260923.pdf), (Erişim Tarihi: Eylül 2024).
27. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Boş yüzeylerden buharlaşma, (Web Sayfası: <https://www.mgm.gov.tr/genel/buharlasma.aspx?s=2>), (Erişim Tarihi: Aralık 2024).

28. DSİ., Toprak su kaynakları, (Web Sayfası: <https://dsi.gov.tr/sayfa/detay/754>), (Erişim Tarihi: Kasım 2024).
29. IPCC., 2023. Climate change synthesis report, (Web Sayfası: https://www.ipcc.ch/report/ar6/syr/downloads/report/IPCC_AR6_SYR_SP_M.pdf), (Erişim Tarihi: Kasım 2024).
30. FAO., (Web Sayfası: <https://www.fao.org/4/x0490e/x0490e06.htm#equation>), (Erişim Tarihi: Haziran 2024).
31. Derber, J. C., Parrish, D. F., Lord, S. J., 1991. The new global operational analysis system at the National Meteorological Center. **Weather and forecasting**, 6(4), 538-547.
32. Adler, R. F., Huffman, G. J., Chang, A., Ferraro, R., Xie, P. P., Janowiak, J., ... Nelkin, E., 2003. The version-2 global precipitation climatology project (GPCP) monthly precipitation analysis (1979–present). **Journal of hydrometeorology**, 4(6), 1147-1167.
33. Huffman, G. J., Adler, R. F., Morrissey, M. M., Bolvin, D. T., Curtis, S., Joyce, R., ... Susskind, J., 2001. Global precipitation at one-degree daily resolution from multisatellite observations. **Journal of hydrometeorology**, 2(1), 36-50.
34. Fang, H., Beaudoin, H. K., Teng, W. L., Vollmer, B. E., 2009. **Global Land data assimilation system (GLDAS) products, services and application from NASA hydrology data and information services center (HDISC)**. In ASPRS 2009 January Annual Conference.