

T.C.
AKDENİZ ÜNİVERSİTESİ



**ANTALYA HAVZASI YERALTI SUYU SEVİYE DEĞİŞİMİNİN YAPAY
ZEKA YÖNTEMLERİYLE İNCELENMESİ**

Erdem ATÇA

FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

MAYIS 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ



**ANTALYA HAVZASI YERALTI SUYU SEVİYE DEĞİŞİMİNİN YAPAY
ZEKA YÖNTEMLERİYLE İNCELENMESİ**

Erdem ATÇA

FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MAYIS 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ANTALYA HAVZASI YERALTI SUYU SEVİYE DEĞİŞİMİNİN YAPAY
ZEKA YÖNTEMLERİYLE İNCELENMESİ**

Erdem ATÇA
İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

MAYIS 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ANTALYA HAVZASI YERALTI SUYU SEVİYE DEĞİŞİMİNİN
YAPAY ZEKA YÖNTEMLERİYLE İNCELENMESİ

Erdem ATÇA
İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 07/05/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Doç. Dr. Halil İbrahim BURGAN (Danışman)

Doç. Dr. Rıfat TÜR

Dr. Öğretim Üyesi Murat KİLİT

ÖZET

ANTALYA HAVZASI YERALTI SUYU SEVİYE DEĞİŞİMİNİN YAPAY ZEKA YÖNTEMLERİYLE İNCELENMESİ

Erdem ATÇA

Yüksek Lisans Tezi, İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Halil İbrahim BURGAN

Mayıs 2025; 73 sayfa

Yeraltısuları, dünya nüfusunun yaklaşık üçte birinin içme suyu ihtiyacını karşılayan ve tarımsal üretimin temelini oluşturan önemli doğal kaynaklardır. İklim değişikliği ve antropojenik faktörlerin etkisiyle, yeraltı su seviyelerinde küresel çapta ciddi düşüşler gözlemlenmektedir. Bu durum, su kaynaklarının sürdürülebilirliği ve gelecekteki su güvenliği açısından endişe verici bir tablo çizmektedir. Antalya havzası da bu küresel eğilimden etkilenmekte olup, bölgedeki yer altı su seviyeleri son yıllarda önemli ölçüde düşüş göstermiştir. Bu çalışma, Antalya havzasındaki gözlem kuyularının su seviyesi değişimlerini, Çita Optimizasyon Algoritması ile optimize edilmiş yapay sinir ağları kullanarak analiz etmektedir. Araştırma, 2008-2023 yılları arasındaki seviye ölçüm verilerini temel alarak, gelecek on yıllık su seviyesi tahminlerini yapmayı amaçlamaktadır. Çita Optimizasyon Algoritması ile elde edilen sonuçların değerlendirilebilmesi için model; Parçacık Sürü Optimizasyonu, Gri Kurt Optimizasyonu ve Simulated Annealing Algoritması ile optimize edilerek çalıştırılmış ve elde edilen değerlendirme ölçütleri karşılaştırılmıştır. Gri Kurt Optimizasyonu ile optimize edilerek çalıştırılan modelin en iyi ölçütlere ulaştığı Çita Optimizasyon Algoritmasının ise rekabetçi sonuçlar ortaya koyduğu belirlenmiştir.

ANAHTAR KELİMELER: Antalya Havzası, Çita Optimizasyon Algoritması, Hidrojeoloji, Yapay Sinir Ağları, Yapay Zeka, Yeraltı Suyu.

JÜRİ: Doç. Dr. Halil İbrahim BURGAN

Doç. Dr. Rıfat TÜR

Dr. Öğretim Üyesi Murat KİLİT

ABSTRACT

EXAMINATION OF ANTALYA BASIN GROUNDWATER LEVEL CHANGE WITH ARTIFICIAL INTELLIGENCE METHODS

Erdem ATÇA

MSc Thesis in Civil Engineering

Supervisor: Assoc. Prof. Dr. Halil İbrahim BURGAN

May 2025; 73 pages

Groundwater is a vital natural resource that supplies drinking water to approximately one-third of the world's population and forms the foundation of agricultural production. Due to the impacts of climate change and anthropogenic factors, significant declines in groundwater levels have been observed globally. This situation presents a concerning outlook for the sustainability of water resources and future water security. The Antalya basin is also affected by this global trend, with groundwater levels in the region showing a marked decrease in recent years. This study analyzes the changes in water levels of observation wells in the Antalya basin using artificial neural networks optimized with the Cheetah Optimization Algorithm. Based on water level measurement data from 2008 to 2023, the research aims to forecast groundwater levels for the next decade. To evaluate the results obtained with the Cheetah Optimization Algorithm, the model was also optimized and run using Particle Swarm Optimization, Grey Wolf Optimization, and the Simulated Annealing Algorithm, and the resulting performance metrics were compared. It was determined that the model optimized with Grey Wolf Optimization achieved the best performance metrics, while the Cheetah Optimization Algorithm produced competitive results.

KEYWORDS: Antalya Basin, Artificial Intelligence, Artificial Neural Networks, Cheetah Optimisation Algorithm, Groundwater, Hydrogeology.

COMMITTEE: Assoc. Prof. Dr. Halil İbrahim BURGAN

Assoc. Prof. Dr. Rıfat TÜR

Asst. Prof. Dr. Murat KİLİT

ÖNSÖZ

Yüksek lisans tez çalışmamda bana yol gösteren, destek veren ve motive eden çok değerli hocam Doç. Dr. Halil İbrahim BURGAN ile değerli katkıları için jüri üyeleri; Doç. Dr. Rıfat TÜR ve Dr. Öğretim Üyesi Murat KİLİT'e sonsuz teşekkürlerimi sunuyorum.



İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
1.1. Çalışmanın Amacı.....	2
1.2. Çalışmanın Kapsamı.....	3
1.3. Konunun Önemi.....	4
1.4. Özgün Değer.....	5
2. KAYNAK TARAMASI.....	7
2.1. Yapay Zeka Tekniklerinin Yeraltı Suyu Seviye Tahmininde Kullanımı.....	7
2.2. Meta – Sezgisel Algoritmalar ve Yeraltı Suyu Seviye Tahmininde Kullanımı....	11
2.3. Çita Algoritması ve Çeşitli Alanlarda Kullanımı.....	13
3. MATERYAL VE METOT.....	14
3.1. Materyal	14
3.1.1. Antalya Havzası	14
3.2. Metot.....	27
3.2.1. Veri Analizi	27
3.2.2. Özellik Seçimi.....	33
3.2.3. Temel Bileşen Analizi	33
3.2.4. Normalizasyon.....	33
3.2.5. Verileri Bölme	34
3.2.6. Yapay Sinir Ağı Modeli Oluşturma.....	35
3.2.7. Optimizasyon.....	37
3.2.8. Modelin Eğitilmesi	40
3.2.9. Tahmin Yapılması	42
3.2.10. Değerlendirme Ölçütleri	42
4. BULGULAR ve TARTIŞMA.....	43
4.1. Bulgular.....	43

4.2. Tartışma.....	44
5. SONUÇ.....	47
6. KAYNAKLAR	49
7. EKLER	57
EK-1. k_3861 kuyusunun test verileri ölçüm ve tahmin değerleri.....	57
EK-2. k_9470 kuyusunun test verileri ölçüm ve tahmin değerleri.....	58
EK-3. k_9479 kuyusunun test verileri ölçüm ve tahmin değerleri.....	59
EK-4. k_25390 kuyusunun test verileri ölçüm ve tahmin değerleri.....	60
EK-5. k_25572A kuyusunun test verileri ölçüm ve tahmin değerleri.....	61
EK-6. k_27106 kuyusunun test verileri ölçüm ve tahmin değerleri.....	62
EK-7. k_41524B kuyusunun test verileri ölçüm ve tahmin değerleri.....	63
EK-8. k_50396 kuyusunun test verileri ölçüm ve tahmin değerleri.....	64
EK-9. k_52276B kuyusunun test verileri ölçüm ve tahmin değerleri.....	65
EK-10. k_52277 kuyusunun test verileri ölçüm ve tahmin değerleri.....	66
EK-11. k_60363 kuyusunun test verileri ölçüm ve tahmin değerleri.....	67
EK-12. k_60364 kuyusunun test verileri ölçüm ve tahmin değerleri.....	68
EK-13. k_60365 kuyusunun test verileri ölçüm ve tahmin değerleri.....	69
EK-14. k_60367 kuyusunun test verileri ölçüm ve tahmin değerleri.....	70
EK-15. k_60368 kuyusunun test verileri ölçüm ve tahmin değerleri.....	71
EK-16. k_60370 kuyusunun test verileri ölçüm ve tahmin değerleri.....	72
EK-17. k_60373 kuyusunun test verileri ölçüm ve tahmin değerleri.....	73
EK-18. k_60378 kuyusunun test verileri ölçüm ve tahmin değerleri.....	74
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Antalya Havzası Yeraltı Suyu Seviye Değişiminin Yapay Zeka Yöntemleriyle İncelenmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

06/05/2025

Erdem ATÇA



SİMGELER VE KISALTMALAR

Simgeler

m : metre

°C : derece Celsius

Kisaltmalar

COA : Çita Optimizasyon Algoritması

DSİ : Devlet Su İşleri

FFNN : İleri Beslemeli Sinir Ağı

GWO : Gri Kurt Optimizasyon Algoritması

MAE : Ortalama mutlak hata

PSO : Parçacık Sürü Optimizasyon Algoritması

R² : Determinasyon katsayısı

RMSE : Ortalama karekök hata

SA : Simulated Annealing Optimizasyon Algoritması

YSA : Yapay sinir ağları

ŞEKİLLER DİZİNİ

Şekil 3.1. Antalya Havzası'nın Türkiye'deki yeri	14
Şekil 3.2. Havza topografik haritası	15
Şekil 3.3. Antalya Havzasında uzun dönem (1970-2017) yıllık ortalama yağış miktarları (Tongal 2019)	17
Şekil 3.4. Antalya Havzasında uzun dönem (1969-2022) aylık ortalama sıcaklık değerleri (Ercan et al. 2025)	17
Şekil 3.5. Meteoroloji ölçüm istasyonlarının havzaya göre konumları ve havza ağırlık merkezine uzaklıkları	18
Şekil 3.6. 2008-2023 aylık ortalama sıcaklıkları	19
Şekil 3.7. 2008-2023 aylık ortalama yağış miktarları	19
Şekil 3.8. Gözlem kuyularının konumları	21
Şekil 3.9. 2008-2023 aralığında aylık yeraltı suyu seviyelerinin dağılımı	22
Şekil 3.10. Kuyu su seviyelerinin eğilimleri	24
Şekil 3.11. Kuyu su seviyeleri ile iklimsel veriler arası korelasyon değerleri	25
Şekil 3.12. Kuyu su seviyeleri arasındaki korelasyon değerleri	26
Şekil 3.13. Kuyu su seviyeleri arası korelasyon durumu	26
Şekil 3.14. Çalışmanın akış şeması	28
Şekil 3.15. Sıcaklık ile k_3861 kuyusu su seviyesi arasındaki 3 aylık gecikmeli ilişki ...	29
Şekil 3.16. 2008-2010 yılları sıcaklık zaman serisi ve hareketli ortalamalar	30
Şekil 3.17. Ayların Sinüs ve Kosinüs Dönüşümü	31
Şekil 3.18. Ay bazlı one-hot encoding gösterimi	31
Şekil 3.19. Sıcaklık, Yağış ve Etkileşim Terimi (Sıcaklık $\times$ Yağış)	32
Şekil 3.20. Sıcaklık ve yağışın yıllık değişimleri	33
Şekil 3.21. Normalize edilmiş sıcaklık ve yağış verileri	34
Şekil 3.22. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo vd. 2013).....	35
Şekil 3.23. 3 Katmandan oluşmuş tipik İleri Besleme Sinir Ağı Modeli	36

Şekil 3.24. Çitaların avlanma stratejisi a) arama b) oturup bekleme c) hücum
d) yakalama (Akbari et al. 2022).....38

Şekil 4.1. En iyi değerlendirme ölçütlerine göre kuyu sayıları43



ÇİZELGELER DİZİNİ

Çizelge 3.1. Antalya Havzası içerisindeki illerin kapladığı alanlar	14
Çizelge 3.2. Aylık ortalama sıcaklık ve yağış değerlerinin Mann-Kendall eğilim testi sonuçları	20
Çizelge 3.3. Kuyu su seviye değerlerinin Mann-Kendall eğilim testi sonuçları	22
Çizelge 4.1. Değerlendirme ölçütleri	43
Çizelge 4.2. 18 kuyudan elde edilen değerlendirme ölçütlerinin ortalama değerleri	44



1. GİRİŞ

Su, canlılar için vazgeçilmez bir doğal kaynak olup insan kullanımı, ekosistemler, tarım ve enerji üretimi gibi birçok alanda vazgeçilmez öneme sahiptir. Ancak, dünya üzerindeki kullanılabilir tatlı su miktarı yalnızca %3.5 oranında olup son 20 yılda artan nüfus ve su talebi; küresel su krizi yaşanması riskini tetiklemektedir. Kalite ve kullanım açısından ciddi sorunlarla karşı karşıya olan su kaynaklarının akılcı ve sürdürülebilir yönetimi için koruma tedbirleri alınması ve sektörel planlama yapılması gerekmektedir (Aksungur ve Firidin 2008).

Dünyada ve ülkemizde sanayileşme, hızlı nüfus artışı, kentleşme ve yaşam standardının yükselmesi gibi nedenlerle suya duyulan gereksinim hızla artmaktadır. Buna karşılık su kaynaklarının kapasitelerinin sınırlı, yıllara göre rastgele değişim gösteren yağış miktarlarına bağlı olduğu bilinmektedir. Sanayileşme, kentleşme, hızlı nüfus artışı ve temiz alanların bilinçsizce kirlenmesi gibi nedenlerle su kaynaklarının hızla kirlendiği ve miktarlarının giderek azaldığı gözlenmektedir (Akın 2005).

Mevcut su kaynakları, birçok bölgede kentsel, endüstriyel, tarımsal ve çevresel ihtiyaçları karşılamada yetersizdir. 2050'ye kadar yaklaşık 3 milyar artacak küresel nüfus ve su kalitesindeki bozulma, su kıtlığını artıracaktır. Özellikle kurak ve yarı kurak bölgelerde, nüfus artışıyla birlikte yüzey suyu kullanılabilirliği, yağışın zamanlaması ve miktarına bağlı olarak daha kritik hale gelecektir (Jury ve Vaux 2005).

Tüketim fazlalığı ve kirlilik; yüzeysel suların miktar olarak yetersiz kalmasına neden olmakta ve bu durum, yer altı suyunun kullanımını zorunlu hale getirmektedir. Bu nedenle, gitgide önemi artan yeraltı suyunun, optimum şekilde kullanılabilmesi için zamansal ve konumsal davranışının bilinmesi, yeraltı suyu kaynaklarının iyi yönetilmesi açısından önem kazanmaktadır (Hökelekli ve İçağa 2010).

Antalya, coğrafi özellikleri ve iklim koşulları sayesinde turizm ve tarım sektörlerinde öne çıkarak ülke ekonomisine en çok katkı sağlayan havzalardan biridir. Son dönemde sanayi ve inşaat faaliyetlerindeki gelişmelerle ivme kazanan bölge, iklimi, doğası, kültürel ve tarihi mirası ile deniz, kum, güneş turizminin yanı sıra kültür, spor, sağlık, kış, kongre, yayla, mağara, kamp ve inanç turizmi gibi alternatif turizm seçenekleri sunmaktadır.

Antalya Havzası, Türkiye'nin %2.56'sını kaplayan 2.235.036 hektarlık yüzölçümüyle, Akdeniz'in kuzeyinde, 36°30'–38°28' kuzey enlemleri ve 30°10'–32°22' doğu boylamları arasında yer almaktadır. Havza, turizm ve tarımın ön planda olduğu ekonomik yapısıyla ülke ekonomisine önemli katkı sağlamakta ve iklim koşulları ve doğal zenginlikleri sayesinde deniz, kum, güneş turizminin yanı sıra kültür, spor, sağlık ve yayla turizmi gibi alternatifler sunmaktadır. Artan sıcaklıklar enerji talebini, su kıtlığını ve sağlık sorunlarını artırmakta, antropojenik faaliyetler ve doğal süreçlerden kaynaklanan aşırı hava olayları fiziksel ve insani sistemler üzerinde baskı oluşturmakta, uyum ve hafifletme stratejilerini gerektirmektedir (Işınkaralar vd. 2024).

Yağış sıklığı ve aşırı yağış endekslerindeki değişikliklerin, havzadaki su kaynakları yönetimi üzerinde ciddi baskılar oluşturma ve ardışık ıslak günlerin azalması da toprak nemi, yüzey ve yeraltı suyu sistemlerinin beslenmesini kısıtlama olasılığını

getirmekte olup, bunların havza için etkin su kullanımı stratejileri geliştirilmesi açısından politika geliştiriciler tarafından değerlendirilmesi gerekmektedir (Tongal 2019).

Antalya Havzası gerek Akdeniz Bölgesi genelinde gerekse Antalya ili özelinde, su ihtiyaçları sürekli artış gösteren yerleşimleri kapsamaktadır. Küresel ısınmaya bağlı iklim değişikliğinin olumsuz etkileri ve sürekli artan su talebinin karşılandığı havzada, yeraltı suyu seviyelerinin düşüşüne bağlı olarak kaynak yönetiminde önemli zorluklarla karşı karşıya kalınmaktadır. Bu durum gerek tarımsal sulama gerekse içme ve kullanma suyu kaynaklarının sürdürülebilirliği açısından kritik bir öneme sahiptir. Veriler, özellikle kurak sezonda, yeraltı suyu seviyesinde meydana gelen dalgalanmaların daha belirgin hale geldiğini göstermektedir, bu da etkin kaynak yönetimi stratejilerinin geliştirilmesinin önemini ortaya koymaktadır. Bu çalışma, yapay zeka yöntemleri kullanılarak söz konusu havzada yeraltı suyu seviyesindeki dalgalanmaların belirlenmesi ve tahmin edilmesi üzerine odaklanmaktadır. Çalışmanın Antalya Havzasındaki su yönetimi politikalarının geliştirilmesine ve yeraltı sularının sürdürülebilir kullanımı adına kararların alınmasına katkı sağlaması beklenmektedir.

1.1. Çalışmanın Amacı

Suya olan talep miktarının sürekli artışı, uzun yıllar ortalaması değişmeyen mevcut su kaynaklarının, kalite ve miktarının korunmasını dikkate alan, bütüncül, etkin ve verimli bir şekilde yönetilmesini zorunlu kılmaktadır. Dünyada canlılığın devamı için su kaynaklarının havza ölçeğinde yönetilmesi ve sürdürülebilir bir yaklaşımla kullanılması ve korunması çok büyük önem arz etmektedir (Kımençe 2023).

Sinir ağı, biyolojik sinir sistemleri üzerine yapılan çalışmalardan esinlenilerek, birbirine bağlı elemanlardan oluşturulmuş, biyolojik nöronlar gibi davranan bileşenler kullanılarak insan beynine benzer şekilde çalışması sağlanmış makinelerdir. Sinir ağının işlevi, kendisine sunulan bir giriş modeline karşılık bir çıkış modeli üretmektir. Örneğin, sinir ağı kendine verilen bir deseni; bir desen grubuna ya da desen gruplarına ayırabilmektedir (Picton 1994).

Makine öğreniminde kullanılan çoğu model, öğrenme sürecinin veriye uyumunu etkileyen bir dizi ayar hiperparametresine sahiptir. Bu hiperparametreler, problemi çözmek için otomatik olarak ayarlanan dahili parametrelerden (ağırlıklar, kural olasılıkları vb.) farklıdır. Sinir ağlarında hiperparametreler; katman sayısı, türü, düğüm sayısı ve türü gibi genellikle ağın yapısını belirleyen etkenleri tanımlamaktadır. Ayrıca, modelin kendisi de meta düzeyde bir hiperparametre olarak görülebilir ve her biri kendi hiperparametrelerine sahip olan bu farklı modellerin, belirli bir problem için optimize edilmesi gerekmektedir. Hiperparametre optimizasyonunun amacı, bir doğrulama setinde ölçülen en iyi performansı sağlayacak olan hiperparametreleri bulmaktır (Andonie 2019).

Karar verme süreci, çeşitli alternatifler arasından seçim yapmayı içerir ve bu seçim, en iyi kararı verme isteği tarafından yönlendirilir. Her bir alternatifin getireceği iyileştirme derecesi, bir hedef fonksiyonu veya performans endeksi ile tanımlanır. Optimizasyon teorisi ve yöntemleri, verilen hedef fonksiyonu bağlamında en iyi alternatifi seçmeye odaklanır. Bu bağlamda, optimizasyon; mühendislik veya ekonomi alanlarında, karar verme süreçlerini içeren her türlü problemde merkezi bir rol oynamaktadır (Edwin vd. 2013).

Çalışmada; en temel ve yaygın kullanılan YSA modellerinden biri olan FFNN modeli kullanılmıştır. Bu model, giriş katmanından başlayarak gizli katmanlar üzerinden çıkış katmanına doğru ilerleyen tek yönlü bilgi akışına sahip bir mimariye dayanmakta olup her katmandaki nöronlar, bir önceki katmandaki nöronlardan gelen ağırlıklı girdileri topladıktan sonra bir aktivasyon fonksiyonu aracılığıyla işleyerek sonraki katmana iletmektedir. FFNN, basit yapısı ve esnekliğinin getirdiği avantajlar doğrultusunda; sınıflandırma, regresyon ve patern tanıma gibi problemlerde bir çözüm aracı olarak yaygın biçimde kullanılmaktadır.

Bu çalışmanın amacı, Antalya Havzasındaki yeraltı suyu seviyelerinin geçmişten günümüze değişimlerini analiz ederek, gelecekteki su seviyelerini tahmin edilmesi için yapay zeka yöntemlerinden yararlanılmasının araştırılmasıdır. Bu doğrultuda, havzadaki gözlem kuyularından elde edilen 2008-2023 yılları arasındaki 16 yıl içerisinde alınan aylık ölçüm verileri kullanılarak, YSA modeli geliştirilmiştir. Modelin performansını artırmak ve daha doğru tahminler elde etmek amacıyla, COA kullanılarak YSA modelinin hiperparametreleri optimize edilmiştir. Çalışmada, aylık ortalama sıcaklık ve ortalama yağış miktarı parametreleri de değerlendirilmiş ve bu veriler ışığında analiz gerçekleştirilmiştir.

Araştırma, yeraltı su kaynaklarının sürdürülebilir yönetimi için bilimsel bir temel oluşturmayı ve iklim değişikliği bağlamında yeraltı su seviyelerindeki değişimlere dair öngörüler sunmayı hedeflemektedir. Bu doğrultuda FFNA modelinin COA ile optimizasyonu sonucunda elde edilen su seviyesi tahmin verileri; PSO, GWO ve SA ile yapılan optimizasyon sonucunda elde edilen su seviyesi tahmin verileriyle karşılaştırılmıştır.

1.2. Çalışmanın Kapsamı

Bu çalışmada, yeraltı suyu seviye değişimlerinin analiz edilmesi için Antalya Havzası örneği seçilmiştir. Antalya Havzası; doğuda Gazipaşa ilçesi ve Konya il sınırı, Kuzeyde Afyonkarahisar il sınırı ve güneyde Akdeniz ile sınırlanmaktadır. Antalya havzasındaki yeraltı suyu seviyelerinin değişimini analiz etmek ve gelecekteki su seviyelerini tahmin etmek amacıyla; 2008-2023 yılları arasında havzadaki gözlem kuyularından elde edilen yeraltı suyu seviye verileri kullanılmıştır. Bu veriler, aylık ortalama sıcaklık ve toplam yağış miktarı değişkenleri gibi iklimsel parametrelerle birleştirilerek analiz edilmiştir. Yapılan analizlerde; ortalama sıcaklığın artış, ortalama yağışın ve su seviyelerinin de azalma eğiliminde olduğu belirlenmiştir.

Tahmin modeli olarak yapay sinir ağları kullanılmış ve modelin performansını artırmak için Çita Optimizasyon Algoritması ile hiperparametre optimizasyonu gerçekleştirilmiştir. COA uygulamasının değerlendirmesini yapabilmek için; PSO, GWO ve SA algoritmaları kullanılarak analizler yapılmış ve her bir optimizasyon sonrası elde edilen ölçütler karşılaştırılmıştır. Modelde kullanılan veriler; Antalya havzasının yeraltı suyu seviyesi ve iklim değerleri olduğundan, model havzaya özgü sonuç üretmektedir.

1.3. Konunun Önemi

İklim değişikliği, doğal sistemlerin işleyişini bozarak oksijen, temiz su ve gıda gibi hayati kaynakları tehdit ederken, bir yandan da ekosistemler üzerinde olumsuz etkiler oluşturmaktadır. İklim değişikliği etkisiyle okyanusların verimsizleşmesi, tarımsal üretimdeki azalma ve ekosistem çöküşleri gerçekleşirken bunlara ek olarak çevre kirliliği, arazi dönüşümü ve habitat kaybı gibi diğer çevresel baskıların etkileri, bu sorunları daha da ağırlaştırmaktadır. Bu doğrultuda öncelikli olarak, artarak devam eden etkileri dikkate alınıp, iklim değişikliğine yönelik gerçekçi ve bütüncül çözümler geliştirilmelidir (McNutt 2013).

Atmosferde artan sera gazları; hidrolojik döngüyü değiştirmekte ve su talebi ile arz dengesini tehdit etmektedir. İklim değişikliği, yağış dağılımını ve zamanlamasını değiştirerek sel ve kuraklık gibi ekstrem olayları artırma, özellikle kurak ve yarı kurak bölgelerde yeraltı suyu beslenimini olumsuz etkileme potansiyeline sahiptir. Sıcaklık artışıyla evapotranspirasyonun artması, su kaynaklarını daha da baskı altına almaktadır. Yeraltı suyu beslenimini; iklim değişikliğine daha duyarlıdır ve deniz seviyesinin yükselmesiyle kıyı akiferlerinde tuzlu su girişi riski artmaktadır. Su yönetimi için dinamik stratejiler, entegre havza yönetimi ve risk temelli yaklaşımlar getirilerek kurak bölgelerde yeraltı suyu yönetimi için belirsizliklerin dikkate alınması gerekmektedir (Şen 2009).

Su kaynaklarının kirlenmesi ve kontrolsüz kullanımı, yanlış tarımsal sulama uygulamaları, iklim değişikliği, hızlı nüfus artışı ve endüstriyel üretim artışına bağlı olarak su tüketiminin artması; günümüzde birçok ülkede tatlı suya ulaşma problemi yaratmaktadır. Küresel ısınma nedeniyle tarihte yaşanan en sıcak yaz mevsimleri son 10 yılda yaşanmıştır. Bu duruma bağlı olarak tatlı su kaynaklarına olan ihtiyaç günden güne artış göstermektedir. Ülkemizin; hakim olan yarı kurak iklimi, su kullanım alışkanlıkları, nüfus artış hızı ve mevcut su rezervi göz önüne alındığında gelecek yıllarda su fakiri ülkeler arasında yer alması büyük bir olasılıktır (Üstün vd. 2020).

Yeraltı suyu ekosistemler için hayati öneme sahip, yenilenebilir ancak sınırlı ve hassas bir kaynak olup tüm yaşam formlarının varlığını sürdürebilmesi ve insan uygarlığının gelişimi için büyük öneme sahiptir. İçme suyu ve evsel ihtiyaçların karşılanması yanı sıra, tarımsal sulama ve sanayi sektörlerinde de yoğun olarak kullanılmaktadır. Bu nedenle azalması ve kirlenmesi halk sağlığı açısından büyük tehdit oluşturmaktadır (Simlandy 2015).

Yeraltı suyu hareketi yüzey ve atmosferik su sistemlerine kıyasla oldukça yavaş gerçekleşmekte olduğundan yeraltı suyunun izlediği süreçlerdeki değişimleri niceliksel olarak belirlemek ve sistemler arası etkileşimleri yakalamak için uzun vadeli veri kayıtlarına ihtiyaç bulunmaktadır. Uzun süreli ve sürekli veri toplama, iklim değişikliğiyle birlikte su kaynaklarındaki değişimleri izlemek ve modelleri doğrulamak açısından büyük önem taşımaktadır. Bu nedenle uzun vadeli ve kapsamlı veri toplama çabalarının desteklenmesi gerekmektedir (Singha ve Navarre-Sitchler 2022).

Yeraltı suları, dünya genelinde içme suyu ihtiyacının büyük bir kısmını karşılayan, tarımsal üretimin temelini oluşturan ve ekosistemlerin devamlılığı için kritik bir öneme sahip olan doğal kaynaklardır. Ancak, küresel ısınma ve iklim değişikliği gibi

çevresel sorunlar, yeraltı su kaynaklarının sürdürülebilirliğini ciddi şekilde tehdit etmektedir. İklim değişikliğine bağlı olarak yağış rejimlerinde meydana gelen bozulmalar, kuraklık dönemlerinin uzaması ve yağışların düzensizleşmesi, yeraltı su seviyelerinde önemli düşüşlere yol açmaktadır. Bunun yanı sıra, hızlı nüfus artışı ve tarımsal üretimdeki artışa bağlı olarak içme, kullanma ve sulama suyu ihtiyaçlarının yükselmesi, yeraltı su kaynakları üzerindeki baskıyı daha da artırmaktadır. Bu durum, su kaynaklarının sürdürülebilir yönetimi ve gelecekteki su güvenliği açısından büyük bir risk oluşturmaktadır.

Yeraltı sularının sürdürülebilirliği hem insan yaşamı hem de ekonomik faaliyetler için hayati bir öneme sahiptir. Özellikle tarımsal üretimin yoğun olduğu bölgelerde, yeraltı su seviyelerindeki değişimlerin doğru bir şekilde tahmin edilmesi, su rezervlerinin korunması ve etkin bir şekilde yönetilmesi için kritik bir gerekliliktir. Yeraltı su seviyelerinin gelecekteki eğilimlerini öngörebilmek, su kaynaklarının kullanım planlarının oluşturulmasına, rezervlerin korunmasına ve suyun daha verimli bir şekilde dağıtılmasına olanak tanır. Bu tür öngörüler, aynı zamanda kuraklık gibi olası kriz durumlarına karşı önlem alınmasını ve su yönetimi politikalarının daha sağlam bir temele oturtulmasını sağlar.

Antalya havzası, tarımsal faaliyetlerin yoğun olduğu ve su kaynaklarının stratejik bir öneme sahip olduğu bir bölge olarak, bu sorunlardan doğrudan etkilenmektedir. Havzada yılda toplam 562 hm³ yer altı suyu kullanılmaktadır. Bu miktar, 452 hm³ olan güvenli işletme rezervinin üzerindedir. Dolayısıyla, yer altı suyu çekimi, beslenmeden daha fazla gerçekleşmekte ve bu da havzadaki yer altı suyu kaynaklarının aşırı şekilde kullanılmasına yol açmaktadır (Su Yönetimi Genel Müdürlüğü 2018).

Bu çalışmanın önemi, yeraltı su seviyelerindeki değişimlerin yapay zeka yöntemleriyle analiz edilmesi ve gelecekteki eğilimlerin öngörülmesiyle, su yönetimi politikalarına ve sürdürülebilir su kaynakları planlamasına katkı sağlamasını amaçlamasından kaynaklanmaktadır. Ayrıca, Çita Optimizasyon Algoritması ile optimize edilmiş yapay sinir ağları kullanılarak, tahmin modellerinin doğruluğunun artırılması, bu alandaki literatüre yenilikçi bir yaklaşım sunmakta ve yeraltı su kaynaklarının korunması için önemli bir bilimsel temel oluşturmaktadır.

1.4. Özgün Değer

Bu çalışma, yeraltı suyu seviyelerinin tahmin edilmesinde Çita Optimizasyon Algoritması (COA) ile optimize edilmiş yapay sinir ağları (YSA) modelini kullanarak literatüre yenilikçi bir katkı sunmaktadır. COA, doğadan esinlenen modern bir meta-sezgisel algoritma olarak, yapay sinir ağlarının hiperparametrelerini optimize etmek için kullanılmış ve bu sayede modelin tahmin doğruluğu önemli ölçüde artırılmıştır. Geleneksel yöntemlerin aksine, bu yaklaşım, yeraltı su seviyelerindeki değişimlerin daha hassas bir şekilde öngörülmesini sağlamaktadır. Çalışmada, yıllık ortalama sıcaklık ve toplam yağış miktarı gibi iklimsel parametreler kullanılarak kapsamlı bir analiz gerçekleştirilmiş ve bu parametrelerin yeraltı su seviyeleri üzerindeki etkileri incelenmiştir. Literatürde, yeraltı suyu seviyelerinin tahmini ile ilgili çalışmalarda, GWO, PSO gibi meta-sezgisel optimizasyon algoritmaları sık olarak kullanılmış olup bu alanda COA ile yapılmış herhangi bir çalışmaya rastlanmamıştır. Bu yönüyle çalışma hem kullanılan yöntem hem de ele alınan veri seti açısından özgün bir nitelik taşımaktadır.

Ayrıca, bu çalışma, Antalya havzası özelinde yeraltı suyu seviyelerinin gelecekteki eğilimlerinin doğru tahmin edilmesini sağlanmasına yönelik yapay zeka yöntemlerini değerlendirerek, bölgesel su yönetimi konusundaki karar vericilere katkı sağlamayı hedeflemektedir. Çalışmanın sonuçları, yeraltı su rezervlerinin korunması, sürdürülebilir kullanım planlarının oluşturulması ve su kaynaklarının daha verimli yönetilmesi için bilimsel bir temel sunmaktadır. COA ile optimize edilmiş YSA modelinin, geleneksel yöntemlere kıyasla daha yüksek performans sergilemesi, bu yöntemin yeraltı suyu tahmin modellerinde uygulanabilirliğini göstermektedir. Bu bağlamda, çalışma hem yeraltı su kaynaklarının sürdürülebilir kullanımına yönelik planlamalara veri sağlanması açısından önemli bir özgün değer taşımaktadır.



2. KAYNAK TARAMASI

2.1. Yapay Zeka Tekniklerinin Yeraltı Suyu Seviye Tahmininde Kullanımı

Yeraltı suyu seviyesi değişimlerinin oluşturduğu olumsuz etkiler, su kalitesindeki değişimler ve rezervuarlarda biriktirilen suların uzun vadede çevreye etkileri modelleme çalışmalarıyla değerlendirilmelidir. Yeraltı suları; sürekli olarak izleme programları ile takip edilmeli ve model sonuçları değerlendirilmelidir. Bu değişimlere bağlı olarak da akiferlerden emniyetli su çekme miktarları güncellenmelidir (Demiroğlu 2017).

Bahadırılı, Amerika Birleşik Devletleri'nin Minnesota şehrinde Prairie Adası yakınlarındaki PI98-14 numaralı gözlem kuyusu istasyonu verilerini kullanmış; bağımlı değişken yeraltı suyu seviyesi ve bağımsız değişkenler olarak da yağış, sıcaklık ve önceki günkü yeraltı suyu seviyesinin kullanıldığı bir model ortaya koymuştur. Bu veriler, Yapay Sinir Ağları, Çoklu Doğrusal Regresyon ve M5 Karar Ağacı modellerine girilmiş, yeni yeraltı suyu seviye değerleri tahmin edilmiştir. Her üç model de değerlendirilerek, tahmin sonuçları Determinasyon Katsayısı, Ortalama Mutlak Hata ve Kök Ortalama Kare Hata kriterlerine göre karşılaştırılmıştır. Kullanılan modellerin yakın sonuçlara ulaştığı ve yeraltı suyu seviye tahmininde başarılı olduğu ortaya konmuştur (Bahadırılı 2021).

İspir (2017) tarafından; Hatay ilinin, Amik Ovası, Kumlu bölgesinde bulunan DSI gözlem kuyusuna ait 2000-2015 yılları arasındaki su seviyesi aylık ölçümleriyle, bölgenin aylık toplam yağış ve ortalama sıcaklık değerleri kullanılarak su seviyesinin tahminine yönelik çalışılmıştır. Çalışmada; Çoklu Lineer Regresyon (MLR), Otoregresif Model (AR) ve Yapay Sinir Ağları (YSA) modelleri kullanılmış ve bunlarla yapılan su seviyesi tahmininin performansı değerlendirilmiştir. Su seviyesinin tahmininde; YSA modelinin MLR ve AR modellerine göre daha iyi sonuçlar ortaya koyduğu tespit edilmiştir.

Sahoo ve Jha (2013) tarafından, bir yeraltı suyu havzasındaki yeraltı suyu seviyelerinin; Çoklu Lineer Regresyon ve Yapay Sinir Ağları teknikleriyle tahmin edilen sonuçlarını karşılaştırmak üzere bir çalışma yapılarak sonucunda; Japonya'daki 17 bölgede; sıcaklık, nehir akımı, mevsimsel değişkenler, yağış, yeraltı suyu seviyesi verileri kullanılarak modellenmiş, modellerin performansı; istatistiki ve grafiksel göstergelerle değerlendirilmiş, değerlendirme sonuçlarında; Yapay Sinir Ağları modelinin, Çoklu Lineer Regresyona göre, ölçülmüş yeraltı suyu seviye verileriyle daha uyumlu sonuçlar verdiği ortaya konmuştur.

Yurtcu vd. (2006) tarafından, Akarçay havzasındaki yeraltı suyu akımı ile diğer meteorolojik değişkenler arasındaki ilişkinin; bulanık mantık modellenmesi yapılmıştır. Yağış, akış ve buharlaşmanın etkisiyle, bağımlı değişken olan yeraltı suyu seviyesindeki (YSS) değişim modellenmiştir. Akarçay havzası içerisinde yer alan Afyon alt havzasına ait 6 gözlem istasyonundan alınan 1977-1989 yılları arasındaki 936 adet veri kullanılmıştır. İstasyonlardan alınan aylık ortalama verileri kullanılarak, su seviyelerindeki değişim; bulanık mantık yaklaşımı ile modellenmiş ve çıkan sonuçlar ile istasyonlardan alınan verilerin aylık ortalama değerlerinin çok yakın aralıkta olduğu tespit edilmiştir.

Aksoy vd. (2011) tarafından; İzmir ili Torbalı ilçesinde, mevcut akım verileri esasında, üç boyutlu zamana bağlı bir yeraltı suyu akış modeli oluşturulmuştur. Gelecekteki yeraltı suyu seviyesi tahmin edilmeye çalışılmıştır. Çalışma içeriğinde; 1996-2004 yılları arasında ölçülmüş yeraltı suyu seviyeleri kullanılmıştır. Bu doğrultuda, 2020 yılına kadar meydana gelebilecek seviye değişimleri tahmin edilmiştir. Model çıktıları; 2000-2020 yılları arasında, su seviyesinde yaklaşık 8 metre düşüş olacağını tespit etmiştir

Hatay ili, Reyhanlı ilçesinin yeraltı suyu seviyesinin tahmini için DSİ rasat kuyusuna ait 2000-2015 yıllarındaki su seviyesinin aylık ölçüm verileriyle, aylık ortalama yağış ve sıcaklık değerlerini girdi olarak kullanılıp; Çoklu Lineer Regrasyon (ÇLR), Anfis (Adaptif Neural Bulanık Çıkarım Sistemi) ve Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-RBF) ve Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-PK) modellerini çalıştırarak yapılan çalışmada, tahmin sonuçlarında en iyi performans değerini DVM modelinin sağladığını ortaya koymuştur. (Demirci vd. 2019).

Sahadan alınan yeraltı suyu verilerinin kalitesi ve miktarı sınırlı olduğunda, seviyelerin güvenilir mevsimsel tahmini, her zaman mümkün olmamaktadır. Yaptıkları çalışmada; yüzeye yakın (<10 m) olan bir akiferin yeraltı suyu seviye tahmini amacıyla, hibrit bir K – En Yakın Komşu – Rastgele Orman (KNN-RF) modeli kullanılmıştır. İklimsel veriler, geçmiş seviye gözlemleriyle birlikte modele girilip, 3 aylık seviyeler tahmin edilmiştir. RMSE, MAE, Nash – Sutcliffe (NSE) ve katsayısı R^2 değerleri; uygulanan yöntemlerden gerçekçi tahminler elde edildiğini ortaya koymuştur (Kombo vd. 2020).

Samantaray vd. (2022) yeraltı suyunun aşırı çekime maruz kaldığı 2 havzada, su seviyesinin tahmini için; Kademeli İleri Geri Yayılım Sinir Ağı (CFBPNN), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ve ANFIS – Gri Kurt Optimizasyonu hibrit modelinin uygulanabilirliğini araştırmışlardır. Çalışmada; yağış, boşalım, terleme, sıcaklık gibi farklı hidrolojik etkenlerden oluşan, 18 yıllık veriler kullanılmıştır. İstatistiksel yöntemlerle yapılan performans analizinde; hibrit modelin, tek başına uygulanan diğer 2 modelden çok daha iyi sonuçlar verdiği belirlenmiştir. Yine terleme etkeninin kullanımının, doğruluğu artırdığı ortaya konmuştur.

Affandi vd. (2007) Momentumlu Gradyan İniş, Adaptif Öğrenme Oranı ve Momentumlu Gradyan İniş, Fletcher – Reeves Konjuge Gradyan, Quasi – Newton ve Levenberg – Marquardt optimizasyon algoritmalarının yapay sinir ağı yöntemi kullanılarak yeraltı suyu değişim tahmininde elde edilen sonuçlarını karşılaştırmıştır. Model analizlerinde; bir rasat kuyusunun ölçülen 5 günlük seviye değişim değerleri kullanılmıştır. Çalışmanın sonucunda, yapay sinir ağı yönteminin, az sayıda veriyle dahi kullanılabileceği çıkarımına ulaşılmıştır. Çalışma sonucunda en gerçekçi verilere; Levenberg – Marquardt optimizasyon algoritması kullanılarak ulaşılmıştır.

Suryanarayana vd. (2014) aylık yeraltı suyu seviyesi tahmini için; dalgacık ve destek vektör makinesi modellerini entegre ederek kullanmışlardır. Giriş verilerini dalgacık serilerine ayırmak için; iki değişkenli kesikli dalgacık dönüşümünün kullanımı benimsenmiştir. Bu seriler aynı zamanda yeraltı suyu seviyesindeki dalgalanmaların tahmini için, destek vektör regresyon modeline, farklı kombinasyonlarda girdi olarak kullanılmıştır. Aylık yağış verileri, 2001 – 2012 dönemine ait; maksimum ve ortalama

sıcaklık ile yeraltı suyu derinliği verileri çalışmada kullanılan girdilerdir. Dalgacık Destek Vektör Regresyon (WA-SVR) modeli, Hindistan'ın Visakhapatnam şehrinde bulunan üç gözlem kuyusu için yeraltı suyu seviyesindeki değişimleri tahmin etmek amacıyla çalıştırılmıştır. WA-SVR modelinin performansı SVR, yapay sinir ağları ve ayrıca geleneksel Oto Regresif Entegre Hareketli Ortalama modelleriyle karşılaştırılmış ve WA-SVR modelinin çalışma alanındaki yeraltı suyu tahmin verilerinde diğerlerine göre doğruluğu daha yüksek sonuçlara ulaştığı ortaya konmuştur.

Kayhomayoon vd. (2022) İran'da bulunan Urmiye akiferinde, yeraltı suyu seviyesi değişiminin tahmini için yağış, sıcaklık, aylık yeraltı suyu seviye değişimi ve yüzey akışı verilerini girdi olarak kullanmıştır. Bu girdilerle de Adaptif Sinirsel Bulanık Mantık Modelini (ANFIS) çalıştırmışlardır. Değişkenlerin farklı kombinasyonlarıyla, 11 farklı girdi veri seti oluşturulmuştur. Verilerin yaklaşık %70'i modeli eğitmek, kalanı da doğrulamak için kullanılmıştır. İkinci adım olarak, parçacık sürü optimizasyonu, karınca kolonisi optimizasyonu (ACOR), diferansiyel evrim, genetik algoritma gibi meta – sezgisel algoritmalar; modeli geliştirmek ve daha verimli sonuç elde etmek için kullanılmıştır. Çalışmanın sonuçları; tüm girdi bileşenlerini kullanan ANFIS modeli tahminlerde düşük bir doğruluk ortaya koymuştur. Meta – sezgisel algoritmalar, ANFIS modelinin parametrelerini optimize etmiştir. Tüm değişkenlerin girdi olarak kullanıldığı ANFIS – ACOR hibrit modeliyle; en iyi tahmin sonuçları elde edilmiştir. Çalışmada yeraltı suyu seviyesi tahmininde; sıcaklık ve buharlaşma verilerinin, yağış ve seviye değişimi verilerinden daha fazla etkili olduğu ortaya konmuştur.

Sahoo ve Jha (2013) Japonya'daki Konan yeraltı suyu havzasında, 17 farklı noktada, yağış, ortam sıcaklığı, nehir su seviyesi verilerini kullanarak, Çoklu Lineer Regresyon ve Yapay Sinir Ağı teknikleriyle yeraltı suyu seviyelerinin tahmini yapmıştır. Modeller; Levenberg-Marquardt (LM) geri yayılım algoritmasıyla eğitilmiş çok katmanlı ileri besleme sinir ağları kullanılarak oluşturulmuş ve Genetik Algoritma ile modellerinin gizli nöron sayıları optimize edilmiştir. Çalışmada, yapay sinir ağları modellerinin, Çoklu Lineer Regresyon modellerine kıyasla, yeraltı suyu seviyesi tahmininde daha yüksek doğruluk sağladığı, özellikle doğrusal olmayan ilişkiler ve gürültülü verilerle çalışırken daha etkili olduğu ve bu metodolojinin farklı hidrojeolojik koşullara sahip bölgelerde uygulanabilir olduğu ortaya konmuştur.

Shirmohammadi vd. (2013) farklı tahmin dönemleri için, sistem tanımlama, zaman serileri, adaptif sinirsel bulanık mantık modelini (ANFIS) de kapsayan muhtelif veriye dayalı teknikleri incelemişlerdir. Çalışma alanı olarak; İran'ın Horasan Razavi ili, Meşhed ovası seçilmiştir. 1992 – 2007 yılları arasında bölgeden toplanmış 15 yıllık yağış, akış ve buharlaşma verileri; 10 yıllık eğitim ve 5 yıllık doğrulamada olacak şekilde çalışmada kullanılmıştır. Çalışmanın sonucu; ANFIS modelinin zaman serileri ve sistem tanımlama modellerinden daha iyi sonuç verdiğini ortaya koymuştur. Çalışmadaki yaklaşımların; 1 ve 2 aylık yeraltı suyu seviye tahmini için doğruluk sağladığı, 3 aydan ötesi için sonuçların tatmin edici olmadığı belirlenmiştir.

Yang vd. (2009) geçtiğimiz 50 yılda aşırı çekim dolayısıyla seviye düşüşü yaşanan, Çin'in Batı Jilin kentindeki kurak ve yarı kurak alanlarda; entegre zaman serisi (ITS) ve geri yayımlı yapay sinir ağı (BPANN) modellerinin, yeraltı suyu seviyesi tahminindeki avantaj ve dezavantajlarını incelemiştir. Sonuçlar; her iki modelin de seviye

tahminlerini yakın doğrulukta verdiğini göstermiştir. Yeraltı suyu seviye değişimi tahmininde; BPANN modelinin doğruluğu ITS modeline göre daha yüksektir.

Sattari vd. (2018) kuzeydoğu İran’da yer alan ve yağıştaki azalmalar, uzun dönem kuraklıklar ve aşırı çekimde nedeniyle ciddi miktarda yeraltı suyu seviye düşüşü yaşanan Ardebil Ovasında; destek vektör regresyon (SVR) ve M5 karar ağacı modellerini kullanarak seviye tahmininde bulunmuşlardır. Çalışmada girdi olarak; 24 kuyudan 17 yıllık periyotta alınan seviye verileriyle, her bir kuyuya düşen yağış ve kuyu sağım verileri kullanılmıştır. Modelden çıktı olarak; bulunulan aydaki seviye verisi alınmış ve istatistiksel metotlarla doğruluk analizi yapılmıştır. Sonuçlar; her iki modelin de başarılı düzeyde seviye tahmini ortaya koyduğunu göstermiştir. M5 karar ağacı modeli sonuçlarının daha uzun vadeli, daha sade ve yorumlanması daha kolay olduğu, SVR modelinin ise en yüksek doğruluklu sonuçları ortaya koyduğu bildirilmiştir.

Şentürk vd. (2023) Kaggle’den elde edilen AquiferAuser veri setindeki derinlik verilerini kullanarak, Levenberg-Marquardt ve Bayesian Regularization algoritmaları ile optimize edilmiş doğrusal olmayan otoregresif sinir ağı (NAR-NN) modeliyle, yeraltı su seviyesinin tahminini yapmışlardır. Çalışmada; Bayesian Regularization algoritması ile optimize edilmiş model, en yüksek doğruluğu sağlamıştır. [Metin girmek için buraya tıklayın veya dokununuz.](#)

Samani vd. (2022) İran’da sınırlı hidrojeolojik verilere sahip bir bölgedeki Qazvin Akiferi’nde, yeraltı suyu seviyesinin aylık tahminini yapmak için; yapay sinir ağı, bulanık mantık, uyarlanabilir nöro-bulanık çıkarım sistemi, veri işleme grup yöntemi ve en küçük kareler destek vektör makinesi gibi veri odaklı modellerin performansını karşılaştırmıştır. Çalışmada veri seti olarak, 2005-2020 yılları arasındaki 15 yıllık aylık yeraltı suyu seviyesi, yağış, sıcaklık ve evapotranspirasyon verileri kullanılmıştır. Yapay sinir ağı modeli olarak; Levenberg-Marquardt algoritması ile eğitilmiş olan çok katmanlı algılayıcı kullanılmıştır. Çalışmada; en küçük kareler destek vektör makinesi yönteminin en iyi performansı sergileyerek, düşük hata oranları ve yüksek korelasyon sağladığı belirlenmiştir.

Coulibaly vd. (2001) sınırlı hidrojeolojik veriye sahip yarı kurak bölgelerde su kaynakları yönetimi için güvenilir tahminler sunmak amacıyla, Burkina Faso’nun kuzeybatısındaki Gondo Akiferi’ne ait kısa süreli veri kayıtlarını kullanarak, farklı yapay sinir ağı modelleriyle, yeraltı suyu seviyesi dalgalanmalarını tahmin etmiştir. Çalışmada, statik hafıza yapısına sahip Girdi Gecikmeli Sinir Ağı, dinamik hafıza özelliği bulunan Tekrarlayan Sinir Ağı ile iki farklı Radyal Tabanlı Fonksiyon ağı varyantı olan Genelleştirilmiş Radyal Tabanlı Fonksiyon ve Olasılıksal Sinir Ağı test edilmiştir. Modeller, 7 yıllık kalibrasyon verisiyle eğitilmiş ve 3 yıllık veriyle doğrulanmıştır. Çalışmada; Tekrarlayan sinir ağı modelinin 7 yıllık kısa veri setleriyle bile yeraltı suyu seviyesi dalgalanmalarını modellemede en etkili yöntem olduğu ve 3 ay sonrası tahminlerde güvenilir sonuçlar sunduğu, Girdi Gecikmeli Sinir Ağı ve Olasılıksal Sinir Ağının 1-2 ay sonrası tahminlerde tatmin edici olduğu, Genelleştirilmiş Radyal Tabanlı Fonksiyonun ise kısa veri setleri ve gürültülü verilerle zayıf performans gösterdiği ortaya konmuştur.

Wen vd. (2017) Çin’in kuzeybatısındaki kurak bir iç nehir havzası olan Zhangye Havzasında, yeraltı suyu seviyelerinin 1, 2 ve 3 aylık zaman ölçeklerinde tahmin edilmesi

için dalgacık analizi – yapay sinir ağı birleşik modelinin performansını değerlendirmiştir. Model, yalnızca geçmiş yeraltı suyu seviyeleri, yalnızca geçmiş iklim verileri ve geçmiş yeraltı suyu seviyeleri ile iklim verilerinin kombinasyonu olmak üzere üç farklı giriş kombinasyonu ile test edilmiştir. Yapay sinir ağı modeli, Levenberg-Marquardt algoritmasıyla eğitilmiştir. Birleşik modelin tüm giriş kombinasyonları ve tahmin sürelerinde yapay sinir ağı modelinden daha iyi performans gösterdiği ve 1-3 aylık yeraltı suyu seviyesi tahminlerinde etkili bir araç olduğu, 1 aylık kısa vadeli tahminlerde yalnızca geçmiş yeraltı suyu seviyeleriyle, 2 – 3 aylık orta vadeli tahminlerde ise iklim verileriyle birlikte en iyi sonuçları verdiği ortaya konmuştur.

Khaki vd. (2015) Malezya'daki Langat Havzasında, 2007-2013 yılları arasındaki 7 yıllık yeraltı suyu seviyelerinin simülasyonu için yapay sinir ağları ve uyarlanabilir nöro-buluşsal çıkarım sistemi (ANFIS) modellerini kullanmıştır. Yeraltı suyu seviyelerinin zaman serisi verilerine ek olarak, seviyeleri etkileyen beş temel parametre (yağış, nem, buharlaşma, minimum sıcaklık, maksimum sıcaklık) zaman serileri giriş parametresi olarak kullanılmıştır. Elde edilen ölçütler; ANFIS modellerinin, yapay sinir ağları modellerine kıyasla daha üstün performans gösterdiğini ortaya koymuştur.

2.2. Meta – Sezgisel Algoritmalar ve Yeraltı Suyu Seviye Tahmininde Kullanımı

Zang vd. (2010) Biyoteknoloji çalışmalarını; doğadaki biyolojik yapılar ve organizasyon ilkeleriyle modern teknolojiler arasında köprü oluşturduğunu, yaşam formlarından insan teknolojilerine bilgi aktarımıyla da birçok matematiksel ve sezgisel algoritma geliştirildiğini aktarmaktadır. Biyoteknoloji çalışmalarının sonuçları; yalnızca fiziksel ürünler değil, farklı alanlarda kullanılabilecek hesaplama yöntemleri de ortaya koymaktadır. İnsanlar, biyolojik sistem ve yapılardan öğrendikleriyle gerek teorik gerekse pratik uygulamalarda kullanılabilen farklı optimizasyon algoritmaları geliştirmiştir. Çalışmada doğadan esinlenmiş bazı algoritmalar incelenerek analiz edilmiş ve her bir algoritmanın arkasında yatan ilkelere odaklanılmıştır. Doğadan esinlenen algoritmaların diğerleriyle hibrit şekilde kullanılarak performans ve zaman tasarrufu sağlanacağı ortaya konmuştur.

Desale vd. (2015) meta – sezgisel algoritmaların; arama sürecine rehberlik ettiğini, amaçlarının optimal çözümler bulmak amacıyla etkili bir arama sağlamak olduğunu aktarmışlardır. Meta – sezgisel algoritmaların; yaklaşık ve genellikle belirleyici olmadığını, zor ve karmaşık optimizasyon problemlerinin çözümü için iyi bir seçenek olduğunu belirtmişlerdir. Meta – sezgisel yöntemlerin probleme özgü olmadığını, sezgisel metotlardan daha iyi sonuçlar elde ettiklerini bildirmişlerdir.

Katipoğlu vd. (2023) yapay sinir ağları (ANN) algoritmasını yapay arı kolonisi (ABC) optimizasyonu ile geliştirmişlerdir. Geliştirilen hibrit modeli farklı sinyal ayrıştırma yöntemleriyle birleştirerek Karadeniz Bölgesindeki akarsu akışı tahminindeki performansını değerlendirmişlerdir. Bu amaçla, gecikmeli akış verileri, hibrit ABC – ANN algoritmasına verilen; ampirik zarflı yerel ortalama ayrıştırma (LMD) ve adaptif gürültülü bütüncül uyarlanabilir ampirik mod ayrıştırması (CEEMDAN) teknikleriyle alt bileşenlere ayrılmıştır. Böylelikle yeni hibrit LMD-ABC-ANN ve CEEMDAN-ABC-ANN yaklaşımlarının akış tahmini başarıları değerlendirilmiştir. Çıktıların; su kaynakları planlamacıları için güvenilir kaynaklar olduğu ortaya konmuştur.

Nabipour vd. (2020) Su kaynakları yönetiminde hidrolojik kuraklık tahminlerinin başrolde yer aldığını, özellikle su temini ve hidroelektrik enerji üretimi konularında büyük etki sahibi olduğunu bildirmektedir. Çalışmada; doğadan ilham alan optimizasyon algoritmaları ile Yapay Sinir Ağlarının melezleştirilmesine dayalı, kısa vadeli hidrolojik kuraklık tahmini yapılmıştır. Çekirge, Salp Sürüsü, Biyocoğrafya tabanlı optimizasyon, Parçacık Sürü optimizasyonu (PSO) ile yapay sinir ağları hibrit şekilde kullanılmış ve sonuçlar geleneksel yapay sinir ağları yöntemiyle karşılaştırılmıştır. Çalışmanın sonuçları; PSO ile yapay sinir ağları hibrit modelinin daha iyi sonuçlar verdiğini ortaya koymuştur.

Supreetha vd. (2020) engebeli topografya ve yağışlardaki düzensizlikler nedeniyle su seviyesi azalan Udipi havzasında; ileriye yönelik seviye tahmini için Uzun – Kısa Vade Hafızalı Aslan Algoritması kullanmışlardır. Modeli geliştirmek için geçmiş tarihli su seviyesi ve yağış verileri kullanılmıştır. Hibrit modelin; Beslemeli Sinir Ağı ve tek başına Uzun – Kısa Vade Hafızalı modelden daha iyi sonuçlar verdiği ortaya konmuştur.

Cui vd. (2022) yeraltı suyu seviyesi simülasyonu için gelişmiş bir yapay zeka modeli geliştirmeye çalışmıştır. Çalışmada, Kuzeybatı Bangladeş'in yoğun biçimde sulanan bir bölgesinde, Alfa Kılavuzlu Gri Kurt optimizasyonu (IA-GWO) ile geliştirilmiş adaptif sinirsel bulanık mantık modelini (ANFIS) kullanarak güvenilir yeraltı suyu seviyesi tahminine ulaşılması hedeflenmiştir. Yağış, buharlaşma, yeraltı suyu sağımı, sulama dönüş akışı gibi doğal ve antropojenik veriler modele girdi olarak kullanılmıştır. Tasarlanan modelin etkinliği; tek başına ANFIS ve yapay sinir ağları (ANN) modelleri ve parçacık sürü optimizasyonu hibritleriyle (ANFIS – PSO) karşılaştırılmıştır. Kalibrasyon ve doğrulama için 31 yıllık periyotta elde edilmiş veriler kullanılmıştır. Sonuçlar hem istatistiksel hem de saçılım grafiklerinin görsel incelemesi ile değerlendirilmiş olup ANFIS-IA-GWO hibrit modelinin performansının ANFIS – PSO modelinden daha iyi olduğunu ortaya koymuştur. Sonuçların görsel değerlendirmesiyle, ANFIS-IA-GWO hibrit modelinin, gözlemlenmiş verilerin; ortalama dağılım, çeyrekler açıklığı ve standart sapmasını daha iyi kopyalayabildiği belirlenmiştir.

Sureshkumar vd. (2023) 1980-2017 yılları arasında yağış ve sıcaklık verilerinden oluşan 37 yıllık bir veri seti kullanarak, optimize edilmiş derin sinir ağı modeliyle, yeraltı suyu seviyesi tahmini yapmışlardır. Modelin ağırlık parametreleri, balık sürülerinin doğal davranışlarından esinlenen bir meta-sezgisel optimizasyon yöntemi olan balık sürü optimizasyonu algoritmasıyla optimize edilmiştir. Tahmin sonuçları; Parçacık Sürü Optimizasyonu ile optimize edilmiş modelin sonuçları ile karşılaştırılmış ve balık sürü optimizasyonu algoritmasıyla optimize edilmiş modelin tüm ölçütlerde daha başarılı sonuçlar verdiği ortaya konmuştur.

Pandey vd. (2020) Hindistan'ın Uttar Pradesh eyaletinde yer alan bölgeye ait 1994-2014 yılları arasındaki 21 yıllık yeraltı suyu yenilenmesi, yeraltı suyu deşarjı ve önceki yeraltı suyu seviyesi verilerini kullanılarak, Genetik Algoritma ile optimize edilmiş Yapay Sinir Ağı modeliyle mevsimsel yeraltı suyu tabla derinliği tahmini yapmıştır. Çalışmada; Genetik Algoritma ile optimize edilmiş Yapay Sinir Ağı modelinin, geleneksel Genetik Algoritma modellerine göre mevsimsel su seviyesi tahmininde üstün performans gösterdiği belirlenerek, bu modellerin güvenilir, sağlam ve zaman tasarruflu olduğu, yoğun tarımsal sulama yapılan alanlarda yeraltı suyu yönetimi için uygulanabilir olduğu ortaya konmuştur

Rakhshandehroo vd. (2018) Dalgacık Sinir Ağı modelini, geliştirilmiş bir Harmony Search algoritmasıyla eğiterek, sığ ve derin iki ayrı kuyu verileriyle, bir yıl boyunca uzun vadeli tahminler yapmışlar ve Geliştirilmiş Harmony Search algoritmasının etkinliği, Diferansiyel Evrim, Harmony Search ve Parçacık Sürü Optimizasyonu algoritmalarıyla karşılaştırılarak doğrulanmışlardır. Çalışmada, Geliştirilmiş Harmony Search algoritmasının diğer evrimsel algoritmalarla kıyasla daha iyi optimizasyon sağladığı ve gürültü seviyesinin düşük olması nedeniyle derin kuyuda tahminlerin daha doğru çıktığı belirlenmiştir.

2.3. Çita Algoritması ve Çeşitli Alanlarda Kullanımı

Akbari vd. (2022) çitelerin avlanma süreçlerini temel alan bir optimizasyon algoritması olan çita optimizasyon algoritmasını incelemiştir. Algoritmanın karmaşık matematiksel yaklaşımları kullanmak yerine çitelerin muhtelif avlanma stratejilerine dayandığını, her karar değişkeninin çita grubunun olası bir dizilimi olarak kabul edildiğini belirtmiştir. Arama, oturup bekleme ve saldırı; matematiksel olarak modellenmiş olup, algoritmanın ana stratejilerini oluşturmaktadır. Aynı zamanda, avdan vazgeçme ve eve dönme stratejisi de algoritmanın erken yakınsama ve yerel optimal tuzaktan kaçınma yeteneklerini geliştirmek için kullanılmıştır. Çalışmada, algoritmanın karmaşık ve zorlu optimizasyon problemlerini çözmede mevcut en gelişmiş algoritmalarla daha iyi performans gösterdiği ortaya konmuştur.

Klein vd. (2018) Çita Optimizasyon Algoritmasını; 7 diğer algoritma ile 3 farklı karşılaştırma problemi üzerinden değerlendirmiştir. Algoritmaların karşılaştırılması için kullanılan test problemi; IEEE CEC2014 yarışması örneğinden alınmıştır. Çita Algoritması; Diferansiyel Evrim, JADE, Parçacık Sürü, Sosyal örümcek, Gri Kurt, Yapay Havai Fişek ve Çiçek Tozlaşması algoritmalarıyla karşılaştırılmıştır. Sonuçlar değerlendirildiğinde; Çita Algoritmasının küresel olarak ortalama bir değere sahip olduğu ve doğadan esinlenen algoritmalar içerisinde umut veren bir yere sahip olduğu ortaya konmuştur.

Khursheed ve Ashraf (2023) Jenerasyon Genişleme Planını; doğadaki son derece kısıtlı, dinamik, karmaşık, doğrusal olmayan, kesikli bir sorun olarak tanımlamış, işin içine yenilenebilir enerji kaynaklarının da dahil edilmesi halinde de daha karmaşık ve az güvenilir hale geldiğini belirtmiştir. Çalışmada; Çita Algoritması ile Düzeltmeli Matris Yöntemi kullanarak sorunu çözmeye çalışmıştır. Model, emisyon ve güvenilirlik kısıtlarına odaklanarak teknik ve ekonomik olarak fizibil sonuca ulaşmaya odaklanmıştır. Modelden tatmin edici sonuçlar elde edilmiş ve önceki çalışmalara göre daha düşük emisyon değeri yakalanmıştır.


Al-Shourbaji vd. (2024) güneş radyasyonu tahmininde, Çita optimizasyon algoritması ve Random Forest algoritmalarını birleştiren yenilikçi bir model olan CO-RF'yi kullanmışlardır. Model; Çita optimizasyon algoritması ile saatlik radyasyon tahmini için en iyi hiperparametreleri seçerek, tahmin için Random Forest algoritmasını kullanmaktadır. Model; HI-SEAS hava istasyonuna ait bir veri seti ile Suudi Arabistan'daki 41 güneş enerjisi tesisinden toplanan başka bir veri seti üzerinde test edilmiştir. Çita optimizasyon algoritmasının, hiperparametre belirlemede; PSO, ACO, RSA ve SO gibi diğer meta-sezgisel algoritmalarla göre daha iyi yakınsama sağlayarak, özellikle yerel ve küresel arama dengesinde öne çıktığı belirlenmiştir.

3. MATERYAL VE METOT

3.1. Materyal

3.1.1. Antalya Havzası

Antalya Havzası, Türkiye’deki 25 havzadan biridir ve Akdeniz’in kuzey sınırında, 36° 30’ 38° 28’ kuzey enlemleri ile 30° 10’ 32° 22’ doğu boylamları arasında yer almaktadır. Havza 2.235.036 hektarlık bir yüzölçümüne sahip olup Ülkemizin %2,56 oranındaki bölümünü kaplamaktadır (Işınkaralar vd. 2024). Havza; Antalya, Burdur ve Isparta illerinin sınırları içerisinde yer almaktadır (Şekil 3.1). Her bir ilin Havza alanı içerisinde kapladığı alan ve bu alanın havza alanı içerisindeki oranı Çizelge 3.1’de verilmiştir.



Şekil 3.1. Antalya Havzası'nın Türkiye'deki yeri


Çizelge 3.1. Antalya Havzası içerisindeki illerin kapladığı alanlar

İl	Havza içerisinde kalan yüzölçümü (ha)	Havza içerisinde kapladığı alanın oranı (%)
Antalya	1,390,036	62
Burdur	212.400	10
Isparta	632.600	28

3.1.1.1. Havzanın Topografik Yapısı ve Yüzey Şekilleri

Antalya Havzası, kuzeyde Eğirdir Gölü'nün kuzeyinden başlayıp Sultan Dağları, Karakuş Dağı, Akçal Dağları ve Geyik Dağları ile çevrelenirken, batıda Akdeniz kıyısına ve güneyde Antalya Körfezi'ne kadar uzanır. Havza su kaynakları bakımından oldukça

zengindir ve başlıca akarsuları Düden, Aksu, Manavgat, Karpuz, Alara, Kargı, Oba, Dim, Pupa, Hoyran ve Isparta çaylarıdır. Sahil ovaları Akdeniz’e açılan ve yüksekliği 100m’yi geçmeyen alanlarda, yüksek ovalar ise 800-1250m arasında yer alır, en büyük gölü Eğirdir Gölü olup havza içerisindeki diğer göller; Kovada, Gölcük, Ilvat ile Dipsiz Gölleridir. Havza, karstik yapısı nedeniyle, çok sayıda kaynak ve sulak alanı içermektedir; başlıca kaynaklar Arapsuyu, Bileydi, Duraliler, Gürvak, Hurma, İngiliz Gölü, Kırkgöz olup Kırkgöz kaynak sahası ile Kemerağzı (Yamansaz) önemli sulak alanlarıdır (Su Yönetimi Genel Müdürlüğü 2018).



Şekil 3.2. Havza topografik haritası

3.1.1.2. Havzanın Jeolojisi

Antalya Havzası, Güney Türkiye’de, Isparta Açısı adı verilen belirgin bir sentaksis içinde yer alır ve Aksu, Köprüçay ve Manavgat alt havzalarından oluşur; bu havza, Geç Senozoyik dönemde, Mezozoik otokton karbonat platformları (batıda Beydağları, doğuda Anamas-Akseki) ile Geç Kretase’dan Pliyosen’e kadar süren bir süreçte üzerine bindirmiş allokon birimler (Likya Napları, Antalya Napları ve Alanya Masifi) üzerinde uyumsuz olarak gelişmiştir. Havzanın Geç Miyosen sediment dolgusu, kalın bir Miyosen ve Pliyosen çökel dizisiyle karakterize edilir; bu dolgu, karasal ve denizel kırıntılılar, mercan resifleri, resifal şelf karbonatları ve yaygın traverten birikintilerini içerir, aynı zamanda yoğun tektonik aktiviteye bağlı iç deformasyonlar ve havza içi uyumsuzluklar sergiler. Antalya Havzası’nın bugünkü yapısı, kuzey-güney yönelimli Kırkkavak Fayı ve Geç Miyosen Aksu Bindirmesi ile sınırlı üç ayrı alt havzaya


bölünmüştür; bu alt havzalarda, Miyosen döneminde karasal yelpaze deltaları, alüvyal yelpazeler, yamaç resifleri ve resifal karbonat şelfleri gibi çeşitli çökelme ortamları gelişmiştir, özellikle Köprüçay ve Aksu alt havzaları yoğun tektonizmaya maruz kalmış, Manavgat alt havzası ise daha az deformasyonla nispeten sürekli bir Burdigaliyen-Messiniyen çökelişi göstermiştir (Çiner vd. 2008).

3.1.1.3. Havzanın İklimi


Antalya, Burdur ve Isparta illeri, coğrafi konumları ve topografik yapıları nedeniyle iklim ve bitki örtüsü açısından belirgin farklılıklar göstermektedir. Antalya’da sahil kesiminde tipik Akdeniz iklimi (yazlar sıcak ve kurak, kışlar ılık ve yağışlı), iç batı kesiminde daha soğuk ve şiddetli yağışlı tipi, iç doğu kesiminde ise meteorolojik değerler bakımından farklı bir iklim tipi görülmektedir. Burdur ili; Ege, Akdeniz ve Orta Anadolu arasında bir geçiş alanı oluşturmaktadır. Güneybatı ve batıdaki dağlar ılık ve nemli havanın iç kesimlere ulaşmasını engellediğinden, kışları soğuk, yazları sıcak geçen ve yağış düzeni Akdeniz iklimini andıran bir iklim hakimdir. Isparta ise Akdeniz ılıman iklimi ile İç Anadolu karasal iklimi arasında bir geçiş bölgesindedir ve genellikle karasal iklim hakimdir (yazlar sıcak ve kurak, kışlar soğuk ve kar yağışlı), ancak Toros Dağlarının güneyindeki çukur alanlarda, ılıman Akdeniz iklimi (yazlar kurak ve sıcak, kışlar ılık ve yağışlı) etkisini göstermektedir (Akşit 2011).

Antalya Havzası’nda genel olarak yazları sıcak ve kurak, kışları ise ılık ve yağışlı geçen Akdeniz iklimi etkili olmakla birlikte, havzanın farklı bölgelerinde yükseltiye bağlı olarak iklimsel çeşitlilikler gözlenmektedir. Özellikle dağların denize bakan yamaçlarında ve arkalarındaki kapalı havzalarda karasal etkilerin arttığı bir iklim tipi ortaya çıkmaktadır. Sahil kesiminde en sıcak ayın ortalama sıcaklığı 28.2 °C’ye ulaşırken, iç kesimlerde bu değer yaklaşık 5 °C daha düşük seyretmektedir; kış aylarında ise sahilde ortalama sıcaklık 9.9 °C iken, iç bölgelerde 0,5 °C’ye kadar düşebilmektedir. Havzanın ortalama yıllık yağış miktarı 973.7 mm olarak hesaplanmış olup, yağışların %48.9’u kış, %25.4’ü ilkbahar, %19.4’ü sonbahar ve yalnızca %6.3’ü yaz aylarında gerçekleşmektedir. Havzanın üst kotlarında kış aylarında kar yağışları da gözlenmektedir. Meteoroloji istasyonlarından elde edilen veriler, havza genelinde yağış ve sıcaklık dağılımının yanı sıra, rüzgar hızları ve yönlerinde de önemli farklılıklar olduğunu göstermektedir. Karasal iklim özellikleri kuzeyden güneye inildikçe azalırken, deniz etkisinden uzak ve yüksek alanlarda sıcaklıklar daha düşük, kışlar ise daha sert geçmektedir (Su Yönetimi Genel Müdürlüğü 2016).

Ercan vd. (2025) Antalya Havzası’nda; 1969-2022 yılları arasındaki aylık yağış ve sıcaklık verileri üzerinde, klasik eğilim analiz yöntemleri (Mann-Kendall ve Sen’s Slope) ile yenilikçi Frekans-Yenilikçi Eğilim Analizi (F-ITA) yöntemini birlikte kullanarak, iklim değişikliğinin etkilerini ve eğilimlerin büyüklük ve yönünü zamansal ve mekansal olarak incelemişlerdir. Sonuçlara göre, Antalya Havzası’nda yağışın genel olarak sabit veya istatistiksel olarak anlamlı olmayan bir azalma eğilimi gösterdiği belirlenmiş, sıcaklık verilerinde ise, havzanın tamamında ve özellikle güney kıyı kesimlerinde anlamlı ve güçlü bir artış eğilimi saptanmıştır.



Şekil 3.3. Antalya Havzasında uzun dönem (1970-2017) yıllık ortalama yağış miktarları (Tongal 2019)




Şekil 3.4. Antalya Havzasında uzun dönem (1969-2022) aylık ortalama sıcaklık değerleri (Ercan vd. 2025)

Kundzewicz ve Döll (2009) tarafından belirtildiğine göre; IPCC (2007) iklim sistemindeki ısınmanın tüm ülkelere yapılan gözlemlerde açıkça görülür olduğu, orman varlığının azalması ve artan gaz salınımları nedeniyle 1906-2005 döneminde küresel sıcaklığın 0.74 °C arttığını, 2100 yılında küresel sıcaklığın 1.1 ile 6.4 °C arasında artış göstereceğini raporlamıştır. (Kundzewicz ve Döll 2009)

Bahir vd. (2021)'e göre Fas Essaouira Havzası'nda, 1978 – 2015 arasında, %12-16 oranında azalan yağış miktarı ile 2.3°C artan sıcaklık, yeraltı suyu seviyelerinde ciddi düşüşlere ve kalite bozulmalarına yol açmıştır. Azalan yağış, beslenme oranlarını düşürmüş, artan sıcaklıklar ise buharlaşmayı artırarak su kaybını hızlandırmıştır. Bu nedenlerle, yarı kurak bölgelerde su kaynaklarının sürdürülebilir yönetimi için iklim değişikliği etkilerinin dikkate alınması kritik önem taşımaktadır (Bahir vd. 2021).


Abdelkarim vd. (2024) Tunus'un güneydoğusundaki Gabès bölgesinde, yarı kurak bir ortamda iklim değişikliği ve küresel ısınmanın yeraltı suyu kaynaklarına etkisini değerlendirmişler ve artan sıcaklıkların, buharlaşmayı artırarak yüzey suyunun ve sığ yeraltı sularının kaybına yol açtığını, azalan yağış miktarının ise beslenimi azaltarak yeraltı suyu seviyelerinde düşüşe neden olduğunu ortaya koymuşlardır. (Abdelkarim vd. 2024)

Sıcaklık ve yağışın yeraltı sularının beslenmesine olan etkileri göz önüne alınıp tahmin doğruluğunun artırılması için çalışmada girdi verisi olarak; Antalya Havalimanı, Isparta Merkez ve Burdur Gölü meteorolojik ölçüm istasyonlarından alınmış; 2008-2023 aralığını kapsayan aylık ortalama sıcaklık ve aylık ortalama yağış verileri kullanılmıştır. Veriler Meteoroloji Genel Müdürlüğünden temin edilmiş, her bir istasyonun havzanın ağırlık merkezine olan uzaklığı oranında ağırlık verilerek birleştirilmiştir.




Şekil 3.5. Meteoroloji ölçüm istasyonlarının havzaya göre konumları ve havza ağırlık merkezine uzaklıkları

Veriler incelendiğinde; en yüksek ortalama sıcaklığın, Ağustos ayında (28.01 °C) ve en düşük ortalama sıcaklığın da, Ocak ayında (5.71 °C) kaydedildiği görülmektedir. Sıcaklık değerleri, yaz aylarında (Haziran-Ağustos) zirve yaparken, kış aylarında (Aralık-Şubat) en düşük seviyelere inmektedir. Akdeniz ikliminin desenini yansıtan bu durum havzada görülen belirgin iklim tipini de ortaya koymaktadır.



Şekil 3.6. 2008-2023 aylık ortalama sıcaklıkları

Havzada en yüksek ortalama yağış, Aralık ayında (132.85 mm) ve en düşük ortalama yağış da Ağustos ayında (9.38 mm) gözlemlenmektedir. Yağışlar, kış aylarında (Kasım-Ocak) yoğunlaşırken, yaz aylarında (Temmuz-Ağustos) belirgin bir düşüş göstermektedir. Yağış durumu da, sıcaklık verilerinde olduğu üzere, Akdeniz iklim desenini yansıtmaktadır.



Şekil 3.7. 2008-2023 aylık ortalama yağış miktarları

Verilerin eğilimlerini gözlemlemek için; Mann-Kendall eğilim testi uygulanmıştır. Mann-Kendall eğilim testi; zaman serilerinde monoton eğilimleri tespit etmek için kullanılan ve parametrik olmayan bir yöntemdir. Gözlemlerin sıralarına dayalı yapısıyla veri dağılımından bağımsız olduğundan aykırı değerlere karşı duyarsız ve hidrolik zaman serileri gibi çarpık dağılımlı veriler için özellikle uygun bir yöntemdir. Parametrik testlerden farklı olarak, normal dağılım gerektirmemesi ve aykırı değerlere karşı daha az hassas olması, bu testin meteorolojik ve hidrolojik verilerde güvenilir sonuçlar üretmesini ve eğilim analizlerinde güçlü bir araç olarak öne çıkmasını sağlamaktadır (Hamed 2008).

Çizelge 3.2. Aylık ortalama sıcaklık ve yağış değerlerinin Mann-Kendall eğilim testi sonuçları

Değişken	Trend	Z-değeri	p-değeri	Tau	Sen Eğimi
Sıcaklık	Artan	2.019	0.044	0.098	0.005 °C/yıl
Yağış	Trend yok	-1.071	0.284	-0.052	-0.016 mm/yıl


Çizelge 3.2’de yer alan ölçütlerden, Z-değeri; eğilimin yönünü ve gücünü göstermektedir. Z-değeri pozitif ise artan, negatif ise azalan eğilimi ifade etmekte olup mutlak değeri ne kadar büyükse, eğilimin o kadar güçlü olduğunu ortaya koymaktadır. p-değeri ise eğilimin istatistiksel anlamlılığını test etmekte olup 0.05 değerinden küçük olması, eğilimin %95 güven düzeyinde anlamlı olduğunu belirtmektedir. Kendall’ın Tau katsayısı; eğilimin gücünü ve yönünü ölçmektedir. Değeri -1 ile 1 arasında olan bu sayı pozitifse artan, negatifse azalan eğilimi göstermektedir. Sen Eğimi; eğilimin büyüklüğünü (değişim oranını) tahmin ederek zaman birimine (örneğin yıl) göre değişimi göstermektedir.

Mann-Kendall eğilim testi sonuçları, aylık ortalama sıcaklık değerlerinde istatistiksel olarak anlamlı bir artış eğilimi ($Z = 2.019$, $p = 0.044$ ve $Tau = 0.098$) tespit ortaya koyarken, aylık ortalama yağış değerlerinde anlamlı bir eğilime rastlanmamaktadır ($Z = -1.071$, $p = 0.284$, $Tau = -0.052$). Sen eğim tahmini, sıcaklıkta yılda 0.005 °C ’lik bir artış, yağışta ise yılda -0.016 mm ’lik ancak anlamlı olmayan bir azalma göstermektedir.

3.1.1.4. Gözlem Kuyuları

Antalya ili içme suyunun %3’ü doğal kaynaklardan %97’si ise yeraltı sularından elde edilmektedir (Akdeniz 2024). Isparta şehrinin içme suyunun büyük bölümü; Eğirdir Gölünden ve şehirdeki birkaç mahallenin içme suyu da Gölcük krater gölünden sağlanmaktadır (Sargın 2003). Dolayısıyla, bu kullanımların orta ve uzun vadede planlanabilmesi için, geleceğe yönelik tahminlere ihtiyaç duyulmaktadır.


Çalışmada materyal olarak; DSİ Genel Müdürlüğü tarafından, Antalya Havzasındaki akiferlerin izlenmesi için aylık olarak ölçümleri yapılan 18 adet rasat kuyusunun, yıllara sari seviye değerleri kullanılmıştır. Kuyuların ölçümleri Ocak 2008 ile Aralık 2023 döneminde aylık olarak gerçekleştirilmiştir.



Şekil 3.8. Gözlem kuyularının konumları

Kuyuların ölçüm verilerindeki eksiklikler; Random Forest modeliyle tahmin edilmiştir. Alsaber vd. (2021) beş hava kalitesi izleme istasyonundan 2012-2018 yılları arasında toplanan veri setindeki eksik verileri tamamlamak için çoklu tamamlama yöntemlerini incelemiştir. Çalışmada; K-Nearest Neighbour, Bayesyen temel bileşen analizi, beklenti maksimizasyonu, öngörülme ortalama eşleştirme, Random Forest tabanlı öngörülme iteratif tamamlama yöntemleri karşılaştırılmıştır. Sonuçlar; Random Forest tabanlı öngörülme iteratif tamamlama yönteminin en yüksek doğruluğu sağladığını göstermiştir.

2008-2023 yılları arasında 18 kuyudan alınmış aylık yeraltı suyu seviyeleri incelendiğinde; Ocak-Mayıs (kış/ilkbahar) döneminde, kuyu su seviyelerinin daha sığ olduğunu göstermektedir, bu da yağışın akiferleri besleyerek su tablasını yükselttiğini yansıtmaktadır. Temmuz-Ekim (yaz/sonbahar) döneminde ise su seviyelerinin daha derin olup bu durum kuraklık ve artan su çekimini ortaya koymaktadır.



Şekil 3.9. 2008-2023 aralığında aylık yeraltı suyu seviyelerinin dağılımı

Akdeniz iklim kuşağında yağışların hem zamansal hem de mekansal dağılımı oldukça düzensiz olup bu iklim tipine sahip ülkeler, kuraklık riskinden en fazla etkilenen bölgeler arasında yer almaktadır. Özellikle yaz aylarında, yağış miktarının yetersiz olması bitkisel üretimi sınırlandıran başlıca etkenlerden biridir ve bu nedenle, Türkiye'nin de dahil olduğu Akdeniz iklim zonunda, yaz dönemindeki yağış eksikliği, tarımsal üretimde sulama uygulamalarını zorunlu hale getirmektedir (Kaman vd. 2022).

Antalya'daki konaklama tesislerine gelen turist sayısı aylara göre düzenli dağılmamaktadır. Yaz aylarında doluluk oranları %75'lere çıkan Antalya'da, bu oran kışın %40 seviyelerine düşmektedir (Kapan ve Timor 2018). Yaz döneminde artan sulama suyu ihtiyaçları ve yaz turizmi, yeraltı sularından daha çok çekim yapılmasını beraberinde getirerek su seviyelerinin düşüşünü desteklemektedir. 2008-2023 yılları aralığında ölçülmüş kuyu su seviyelerinin eğilimlerini görmek amacıyla, verilere Mann – Kendall eğilim testi uygulanmıştır.

Çizelge 3.3. Kuyu su seviye değerlerinin Mann-Kendall eğilim testi sonuçları


Kuyu No	Trend	Z-Değeri	p	Tau	Eğim
k_3861	Azalan	-3.651	2.610e-04	-0.177	-0.00686
k_25572/A	Azalan	-11.18	1.000e-100	-0.543	-0.04973
k_9470	Azalan	-15.58	1.000e-100	-0.756	-0.1227
k_25390	Azalan	-15.53	1.000e-100	-0.754	-0.1015
k_50396	Azalan	-13.53	1.000e-100	-0.657	-0.08965
k_9479	Azalan	-13.31	1.000e-100	-0.646	-0.1477
k_60370	Trend yok	0.812	4.170e-01	0.039	0.00111

Çizelge 3.3'in devamı

k_60364	Azalan	-8.457	1.000e-100	-0.411	-0.00338
k_41524/B	Azalan	-8.036	8.880e-16	-0.39	-0.02151
k_52277	Azalan	-16.61	1.000e-100	-0.807	-0.1637
k_60368	Azalan	-17.69	1.000e-100	-0.859	-0.1963
k_60373	Trend yok	-1.611	1.070e-01	-0.078	-0.00498
k_60365	Azalan	-13.15	1.000e-100	-0.638	-0.1306
k_60367	Azalan	-14.67	1.000e-100	-0.712	-0.1143
k_60378	Azalan	-6.054	1.420e-09	-0.294	-0.01211
k_52276/B	Azalan	-14.33	1.000e-100	-0.696	-0.2033
k_27106	Azalan	-13.01	1.000e-100	-0.631	-0.1412
k_60363	Azalan	-12.54	1.000e-100	-0.609	-0.00921

2008-2023 yılları arasında 18 kuyudan alınan yeraltı suyu seviyelerinin Mann-Kendall testiyle yapılan trend analizi; havzadaki su kaynaklarının genel olarak azalma eğiliminde olduğunu ortaya koymaktadır. Toplamda 16 kuyu, istatistiksel olarak anlamlı bir azalma eğilimi gösterirken, yalnızca iki kuyu (k_60370 ve k_60373) trend göstermemiştir. Azalma eğilimi gösteren kuyuların çoğunluğu (14 kuyu) güçlü bir derinleşme sergilemekte olup, özellikle k_52276/B (-0.203 m/yıl), k_60368 (-0.196 m/yıl) ve k_52277 (-0.164 m/yıl) gibi kuyular, yüksek Z-değerleri ve küçük p-değerleriyle ($p < 10^{-30}$) hızlı bir su seviyesi düşüşüne işaret etmektedir. Bu durum, havzada artan su çekimi (tarım, turizm ve nüfus artışı) ve potansiyel olarak zayıf akifer beslenmesinin etkisini yansıtmaktadır.


Anlamlı trendi olmayan iki kuyu (k_60370 ve k_60373); Manavgat-Alanya sahil kesiminde, denize çok yakın bir bölgede ve ova alanında konumlanmaktadır; bu bölge, havzadaki yıllık ortalama sıcaklığın maksimum olduğu (18-20°C civarında), ancak aynı zamanda yıllık ortalama yağışın en yüksek olduğu (1000-1200 mm) alandır. Bu kuyuların stabil su seviyeleri (k_60370: 0.00 %/yıl, k_60373: -0.02 %/yıl oransal değişim hızı), yüksek yağışın akiferleri düzenli olarak beslemesiyle, denize yakınlık ve ova alanındaki yüzeysel akifer yapısının yağışın infiltrasyonunu kolaylaştırarak su seviyesindeki dalgalanmaları minimize etmesiyle açıklanabilmektedir. Buna karşın, bölgedeki yüksek sıcaklıkların buharlaşmayı artırma potansiyeli, yoğun yağışlarla dengelenmiş görünmektedir; bu durum, sahil kesimindeki kuyuların, havzanın iç kesimlerinde gözlenen güçlü azalma eğilimlerinden farklı olarak, daha stabil bir hidrolojik rejime sahip olduğunu göstermektedir.



Şekil 3.10. Kuyu su seviyelerinin eğilimleri

Havzada yer alan 18 kuyunun su seviyeleri ile sıcaklık, yağış ve kuyular arası ilişkileri incelemek için Pearson korelasyon katsayısı yöntemiyle analiz yapılmıştır. Pearson korelasyon katsayısı; değişkenler arasındaki doğrusal ilişkinin gücünü ve yönünü ölçmek amacıyla kullanılmakta olup -1 ile 1 arasında değer almaktadır. Değerin 1'e yaklaşması pozitif doğrusal ilişkiyi (bir değişken artarken diğeri de artar), -1'e yaklaşması negatif doğrusal ilişki (bir değişken artarken diğeri azalır) ve 0 olması da doğrusal ilişki olmadığını göstermektedir.


Analiz sonuçlarında; tüm kuyular için su seviyesi ile sıcaklık arasında negatif korelasyon olduğu, çoğu kuyu için de yağış ile su seviyesi arasında pozitif korelasyon olduğu belirlenmiştir. İklim parametreleri, kuyuların su seviyelerini etkilemekte ancak bu etki mekansal olarak farklılık göstermektedir. Sahil kesimindeki kuyuların su seviyeleri yüksek yağış sayesinde stabil kalırken, iç kesimlerdeki kuyuların su seviyeleri; artan sıcaklık ve düşük yağış miktarı etkisiyle hızlı azalma eğilimindedir.




Şekil 3.11. Kuyu su seviyeleri ile iklimsel veriler arası korelasyon değerleri

Kuyular arasında genelde pozitif korelasyon bulunmakta olup bu durum; çoğu kuyunun su seviyesi değişimlerinin benzer eğilimler izlediğini göstermektedir. Kuyular; korelasyon katsayısı 0.7'den büyük olanlar (güçlü korelasyon), korelasyon katsayısı 0.7 ile 0.3 arasında olanlar (orta korelasyon) ve korelasyon katsayısı 0.3'den küçük olanlar (zayıf korelasyon) şeklinde gruplandırılmıştır.

Kuyu su seviyeleri arasındaki korelasyon analizi; iç kesimlerdeki k_9470, k_25390, k_50396, k_9479, k_52277, k_60368, k_60365, k_60367, k_52276/B ve k_27106 kuyularının birbirleriyle 0.78 ile 0.89 arasında yüksek korelasyon gösterdiğini, Manavgat-Alanya sahil kesimindeki k_60370 ve k_60373 kuyularının diğer kuyularla 0.41 ile 0.45 arasında orta-düşük korelasyon sergilediğini, sık kuyular olan k_60364 ve k_60363'ün diğer kuyularla 0.27 ile 0.29 arasında zayıf korelasyon gösterdiğini ve k_3861'in 0.37 ortalama korelasyon ile orta düzeyde bir ilişki içinde olduğunu ortaya koymaktadır.



Şekil 3.12. Kuyu su seviyeleri arasındaki korelasyon değerleri



Şekil 3.13. Kuyu su seviyeleri arası korelasyon durumu

3.2. Metot

Bu çalışma kapsamında, Antalya Havzasında yer alan gözlem kuyularına ait seviye değişimlerinin yapay zeka yöntemleriyle incelenmesi için, yapay sinir ağları modelinden yararlanılmıştır. Yapay sinir ağları modeli; COA ile optimize edilerek çalıştırılarak 12 aylık seviye tahminlerine yönelik değerlendirme ölçütleri elde edilmiştir. Sonrasında, yapay sinir ağları modeli, mimarisi değiştirilmeden; PSO, GWO ve SA algoritmaları ile de çalıştırılarak elde edilen değerlendirme ölçütleri birbirleriyle karşılaştırılmış ve COA'nın yeraltı suyu seviye değişimlerinin tahminindeki performansı değerlendirilmiştir.

İran'daki Qazvin akiferinde 15 yıllık geçmiş veriler (Samani vd. 2022), Burkina Faso'daki Gondo Akiferi'nde 10 yıllık geçmiş veriler (Coulibaly vd. 2001) ve Çin'deki Zhangye Havzası'nda 8 yıllık geçmiş veriler (Wen vd. 2017) kullanılarak, YSA modelleriyle su seviye tahminleri yapılmış ve bir ay sonrası tahminlerde tatmin edici sonuçlar üretildiği, iki ay sonrası tahminlerde performansın kısmen korunduğu ancak üç ay sonrası tahminlerde doğruluğun belirgin bir düşüş gösterdiği belirlenmiştir. Çin'in Fujian Eyaleti'ndeki Dongshan Adası'nda gerçekleştirilen bir çalışmada (Yang vd. 2015), 2000-2011 yılları arasındaki aylık yeraltı suyu seviyesi verileri kullanılarak, YSA modeliyle yeraltı suyu seviyesi tahminleri yapılmış ve bir ay sonrası tahminlerde tatmin edici sonuçlar elde edilmiştir.


Çalışmada COA'nın yeraltı suyu seviye tahmini için çalıştırılan YSA modeli üzerinde gösterdiği performansı değerlendirebilmek amacıyla, model bir ay sonrası için tahmin yapacak şekilde çalıştırılmıştır. Bu amaçla Şekil 3.7'deki akış şeması önerilmiştir.

3.2.1. Veri Analizi

3.2.1.1. Time-Lag


Bir zaman serisi verisinde, bir değişkenin geçmiş değerlerinin, mevcut veya gelecekteki bir durumu açıklamak için kullanılması amacıyla değişkenler arasındaki zamansal ilişkileri ve gecikmeli etkileri yakalamak için bir araç olarak kullanılmaktadır. Hidrolojik sistemlerde, örneğin yağışın kuyu su seviyesine etkisi anında değil, belirli bir gecikmeyle ortaya çıkmaktadır; bu nedenle time-lag, geçmiş verilerin modele eklenmesiyle bu gecikmeli süreçleri temsil etmektedir. Time-lag kullanımı, giriş özelliklerini zenginleştirerek YSA modelinin zamansal bağımlılıkları öğrenmesini sağlamakta, böylece statik modellerin aksine, zamanla değişen desenleri ve uzun vadeli etkileri tahmin etme yeteneği kazandırmaktadır. Bu durum; verinin zamansal yapısının korunarak geçmiş olayların mevcut sonuçlar üzerindeki etkisini hesaba katmakta ve modelin doğruluğunu artırmaktadır.

Sapac vd. 2020 tarafından ormanlık bir havzada $\text{NO}_3\text{-N}$ akışının gecikmeli dinamiklerini anlamak için time-lag kullanmış, Sultan vd. 2022 ise tropikal havzalarda akış tepkilerini modellemek için time-lag ile analiz yapmıştır; her iki çalışma, time-lag kullanımının süreçlerin zamansal ilişkilerini ortaya çıkardığını göstermiştir.



Şekil 3.14. Çalışmanın akış şeması


Şekil 3.9’da belirli bir ayda ölçülen sıcaklık değerinin, yaklaşık üç ay sonra yeraltı su seviyesinde meydana gelen değişimle ilişkili olabileceği görülmektedir. Çevresel faktörlerin etkisinin, belirli bir zaman gecikmesiyle ortaya çıkabileceğini modellemek ve zamansal bağımlılıklar ile uzun vadeli etkileri modele aktarabilmek amacıyla, çalışmada; aylık ortalama sıcaklık, aylık ortalama yağış ve su seviyeleri için 1, 2, 3, 4, 5, 6, 9 ve 12 aylık time-lag’ler oluşturulmuştur. Bunlar veri çerçevesine yeni sütunlar olarak eklenmiş ve YSA modeline giriş olarak verilerek, çevresel faktörlerin kuyu su seviyesine gecikmeli etkilerinin modellenmesi sağlanmıştır. 1-6 aylık time-lag kullanımıyla sıcaklık veya yağışın su seviyesine daha yakın zamanlı etkilerini yakalamak, 9 ve 12 ay time-lag ile mevsimsel desenleri yakalamak ve 12 aylık time-lag, bir önceki yılın aynı ayındaki değeri temsil ederek yıllık döngülerin modellenmesini sağlamak amaçlanmıştır.



Şekil 3.15. Sıcaklık ile k_3861 kuyusu su seviyesi arasındaki 3 aylık gecikmeli ilişki

3.2.1.2. Hareketli Ortalamalar

Hareketli ortalama, zaman serisi verilerindeki trendleri yakalamak ve öngörü yapmak için kullanılan bir yöntem olarak kullanılmaktadır (Hansun 2013). Hareketli ortalama ile; bir zaman serisi değişkeninin, belirli bir zaman penceresindeki (örneğin, 2, 3, 6, 12 ay) ortalama değerleri hesaplanarak verideki ani dalgalanmaların yumuşatılması ve eğilimin ortaya çıkarılması sağlanmaktadır. Bu yöntem, gürültüyü azaltmak, mevsimsel veya uzun vadeli desenleri yakalamak ve modelin genelleme kapasitesini artırmak amacıyla uygulanmakta olup çalışmada modelin; sıcaklık, yağış ve su seviyesindeki periyodik değişimleri algılayabilmesi için kullanılmıştır. Çalışmada, modelin zamansal trendleri öğrenmesi ve gürültüden etkilenmeden daha doğru tahminler yapması amaçlanarak; aylık ortalama sıcaklık, aylık ortalama yağış ve su seviyeleri için 2, 3, 6 ve 12 aylık hareketli ortalamalar hesaplanmıştır.



Şekil 3.16. 2008-2010 yılları sıcaklık zaman serisi ve hareketli ortalamalar


Şekil 3.9’da 2008-2010 yılları arasındaki aylık sıcaklık verisinin orijinal hali ile 2, 3, 6 ve 12 aylık hareketli ortalamaları gösterilmektedir. Kısa pencere uzunluklarına sahip hareketli ortalamalar (2 ve 3 ay), orijinal verideki dalgalanmaları kısmen yumuşatırken, pencere boyutu büyüdükçe (özellikle 12 ay) kısa bir zaman aralığında kısa vadeli değişimler tamamen filtrelenerek genel eğilim daha belirgin hale gelmekte ve hareketli ortalama çizgisi daha düz ve sabit bir hale gelmektedir.

3.2.1.3. Döngüsel Özellikler

Dönüşümler, matematiksel problemlerdeki karmaşıklığı azaltmak için kullanılmaktadır. Diferansiyel denklemler ve integral denklemler, uygun dönüşümlerin dikkatli bir şekilde uygulanmasıyla, çözümleri daha kolay elde edilen cebirsel denklemlere dönüştürülebilmektedir (Hatun ve Vatansever 2022). Çalışmada; sine cosine ve ay bazlı one-hot encoding dönüşümleri kullanılmıştır.


Döngüsel özellikler zaman serilerindeki periyodik desenleri, özellikle mevsimselliği modellemek amacıyla kullanılmış olup ayların döngüsel doğasının (örneğin, Aralık ve Ocak’ın yakınlığı) korunması ay numarasını (1-12) döngüsel bir forma dönüştürmek için sinüs ve kosinüs dönüşümleri uygulanmıştır. Ayrıca modelin her yıl Aralık’tan Ocak’a geçişteki sürekliliği öğrenmesi ve belirli ayların kendine özgü etkilerini (artan sıcaklıklar, vb.) yakalaması için ikili sütunlar oluşturularak ay bazlı one-hot kodlama yapılmıştır.

Şekil 3.10’da zaman serisi verisindeki ay bilgisinin döngüsel (sinüs ve kosinüs dönüşümü) olarak gösterimi yer almaktadır. Ay numaralarının sinüs ve kosinüs dönüşümleriyle elde edilen değerler; Aralık (12) ve Ocak (1) aylarının, sayısal olarak uzak görünmelerine rağmen matematiksel olarak birbirine yakın olduğu göstermektedir. Bu dönüşüm ile modelin örneğin Aralık’tan Ocak’a geçişteki sürekliliği ve mevsimsel etkileri daha iyi yakalaması sağlanmaktadır.



Şekil 3.17. Ayların Sinüs ve Kosinüs Dönüşümü

Şekil 3.11’de ay bazlı one-hot encoding dönüşümünün matris şeklinde gösterimi yer almaktadır. Her satır bir ayı, her sütun ise bir one-hot kodlama sütununu temsil etmekte olup her ay için yalnızca ilgili sütunda “1” değeri bulunurken, diğer tüm sütunlarda “0” değeri yer almaktadır. Bu dönüşüm ile modelin ay bilgisini kategorik ve karşılaştırılabilir bir biçimde kullanabilmesi ve böylece her ayın modele özgü etkisinin ayrı ayrı tanımlanabilir olması ayrıca aylar arasında herhangi bir büyüklük veya sıralama ilişkisi olmadığının, her birinin eşit ve bağımsız bir kategori olduğunun modele aktarılması sağlanmıştır.




Şekil 3.18. Ay bazlı one-hot encoding gösterimi

3.2.1.4. Etkileşim Terimi

Bir değişkenin sonucu veya etkisinin, ikinci bir değişkenin sonucu veya etkisine bağlı olarak değişmesi halinde, etkileşim ortaya çıkmaktadır. Bu durumla, çoklu değişkenli (veya çok etkenli) deneylerde karşılaşılmaktadır (McDermott 2002).

Uygulamalı araştırmalarda, iki değişkenin bağımlı değişken üzerindeki çarpımsal etkisini araştırmak için etkileşim terimlerinin kullanılmaktadır (Bun ve Harrison 2019). Çalışmada kullanılan giriş verilerinden; sıcaklık ve yağış bağımsız olarak kuyu su seviyesini etkilese de yüksek sıcaklık ve düşük yağışın birlikte kuraklığa yol açması gibi etkenlerin de göz önüne alınması için sıcaklık ve yağış değişkenlerinin çarpımıyla oluşturulan etkileşim terimi giriş verilerine eklenmiştir. Bu işlem ile hidrolojik süreçlerdeki karmaşık, doğrusal olmayan ilişkilerin yakalanarak modelin yalnızca tekil değişkenlere değil, çevresel faktörlerin kombinasyonlarına da duyarlı olması amaçlanmıştır.




Şekil 3.19. Sıcaklık, Yağış ve Etkileşim Terimi (Sıcaklık × Yağış)

Şekil 3.12’de ilk 24 aylık dönemde sıcaklık, yağış ve bu iki değişkenin çarpımıyla elde edilen etkileşim terimi görülmektedir. Sıcaklık ve yağış değerleri kendi içlerinde dalgalanırken, etkileşim terimi bu iki değişkenin aynı anda yüksek veya düşük olduğu dönemlerde daha belirgin dalgalanmalar göstermektedir ve bu durum modelin sıcaklık ve yağışın birlikte etkili olduğu zaman dilimleri ile bu etkilerin büyüklüğünü belirlemesini sağlamaktadır.

3.2.1.5. Türev Özellikleri

Çalışmada kullanılan sıcaklık, yağış ve kuyu su seviyesi gibi değişkenlerin zaman içindeki değişimini hesaplayarak, örneğin 1 aylık ve 12 aylık farklarla değişim hızını, eğilim ve anomalileri yakalamak amacıyla türev özellikleri kullanılmıştır. Türev kullanılarak modelin sadece anlık değerleri değil, değişim hızlarını ve yönlerini de öğrenmesi, dinamik süreçleri anlaması, kısa vadeli değişimleri ve yıllık eğilimleri tespit etmesi ve süreçlerin hızı ile yönünü öğrenmesi hedeflenmiştir.



Şekil 3.20. Sıcaklık ve yağışın yıllık değişimleri

3.2.2. Özellik Seçimi

Yüksek boyutlu verilerdeki; gürültülü, gereksiz ve ilgisiz boyutların varlığı gibi unsurlar, makine öğrenimi yöntemleri için büyük bir zorluk oluşturmaktadır. Bu boyutlar, öğrenme algoritmalarını yavaşlatarak öğrenme görevlerinin performansını düşürmekte ve modelin yorumlama kabiliyetini azaltmaktadır. Özellik seçimi; gürültülüyle, ilgisiz ve gereksiz özellikleri kaldırarak orijinal özelliklerden küçük, ilgili bir alt küme seçme yeteneğiyle bu sorunları gidermektedir (Miao ve Niu 2016).

Özellik seçimi aşamasında, veri setindeki en bilgilendirici özellikler belirlenerek modelin etkinliği ve hesaplama verimliliği artırılmıştır. Hedef kuyu dışındaki diğer kuyular veriden çıkarılarak karşılıklı bilgi yöntemiyle en fazla 20 özellik seçilmiştir. Mallows ve Reza (1964) karşılıklı bilginin iki değişken arasındaki ilişkiyi ölçerek, bir değişkenin diğerine dair ne kadar bilgi sağladığını belirlediğini, bir özelliğin hedef değişken üzerindeki etkisini ölçmek ve en bilgilendirici özellikleri seçmek için kullanıldığını belirtmiştir. Bu yöntem ile, özelliklerin hedef değişkenle olan ilişkisi değerlendirilerek en yüksek bilgi katkısı sağlayan özellikler korumuş ve gereksiz veri elimine edilmiştir.

3.2.3. Temel Bileşen Analizi

Temel Bileşen Analizinin amacı, birbiriyle ilişkili çok sayıda değişkenden oluşan bir veri setinin boyutluluğunu azaltmak, ancak veri setindeki varyasyonun mümkün olduğunca büyük bir kısmını korumaktır. Bu, veriyi yeni bir değişken setine, yani temel bileşenlere dönüştürerek gerçekleştirilir. Bu bileşenler birbiriyle ilişkisizdir ve ilk birkaç bileşenin, orijinal değişkenlerdeki toplam varyasyonun çoğunu kapsayacağı şekilde sıralanır (Jolliffe 2002). Çalışmada; seçilmiş özellikler üzerinden, verideki bilgiyi kaybetmeden boyut indirgeme yapılmış, elde edilen özet bileşenler, orijinal seçilmiş özelliklerle birleştirilerek modelin hem orijinal hem de özetlenmiş bilgiden faydalanması sağlanmıştır.

3.2.4. Normalizasyon


Veri analizinde kullanılan ölçüm birimleri; farklı değer aralığına ve dolayısıyla farklı ağırlıklara neden olabilmektedir. Bu etkiyi önlemek için veriler, $[-1,1]$ veya $[0,1]$ gibi ortak bir aralığa dönüştürülerek normalize edilip tüm özelliklerin eşit ağırlığa sahip olması sağlanmaktadır. Normalizasyon, özellikle sinir ağları ve en yakın komşu sınıflandırması gibi uzaklık ölçümlerine dayalı algoritmalarda, öğrenme sürecini

hızlandırmakta, modelin tüm özelliklere eşit şekilde odaklanmasını sağlayarak daha doğru ve güvenilir sonuçlar elde edilmesine yardımcı olmaktadır (Han vd. 2012). Normalizasyon, farklı ölçeklerdeki skorları veya veri setlerini karşılaştırılabilir hale getirmek için gerçekleştirilen birim ölçüsünü ortadan kaldırma işlemi olup farklı birimler veya ölçeklerle ölçülen verileri standart bir forma dönüştürerek karşılaştırmayı mümkün kılmaktadır (Abdi 2010).

Çalışmada; MinMaxScaler normalizasyonu kullanılarak, her bir özellik; kendi minimum ve maksimum değerleri kullanılarak [0,1] aralığına ölçeklendirilmiştir. MinMaxScaler normalizasyonu; her bir özellik için, o özelliğin minimum değerini 0 ve maksimum değerini 1 yapmakta ve diğer tüm değerleri 0 ile 1 arasında bir ondalık sayıya dönüştürmektedir. Bu yöntem, farklı ölçeklerdeki özellikleri aynı aralığa getirerek, modelin tüm özelliklere eşit şekilde odaklanmasını sağlamakta ve özellikle sınır ağları gibi algoritmaların performansını artırmaktadır (Raju vd. 2020).

Min-Max normalizasyonu (3.1) formülüyle hesaplanmakta olup burada d orijinal veri değerini, min(P) özniteliğin minimum değerini ve max(P) özniteliğin maksimum değerini temsil etmektedir (Jain ve Bhandare 2013).

$$d' = \frac{d - \min(P)}{\max(P) - \min(P)} \quad (3.1)$$



Şekil 3.21. Normalize edilmiş sıcaklık ve yağış verileri


3.2.5. Veri Bölme

Modelin eğitimi, doğrulanması ve test edilmesi için veriler ilk aşamada iki ana parçaya ayrılmıştır. Verilerin %85'lik kısmı eğitim ve doğrulama için, %15'lik kısmı ise test için kullanılmak üzere ayrılmıştır. Ardından, ayrılan %85'lik eğitim ve doğrulama seti kendi içinde tekrar bölünerek %82.35'i (toplam verinin %70'i) eğitim seti olarak,

%17.65'i (toplam verinin %15'i) ise doğrulama seti olarak ayrılmıştır. Eğitim seti, modelin parametrelerini öğrenmek için kullanılırken, doğrulama seti model hiperparametrelerini ayarlamak ve aşırı öğrenmeyi kontrol etmek için kullanılmaktadır. Test seti ise, eğitim tamamlandıktan sonra modelin performansını değerlendirmek için saklanmaktadır.

3.2.6. Yapay Sinir Ağı Modeli Oluşturma


Yapay sinir ağları; insan beynindeki sinir sisteminden esinlenerek tasarlanmış bir yapay zeka modelidir. İnsan beyninde nöronlar, sinapslar aracılığıyla birbirleriyle iletişim kurarak bilgi işlerken, YSA'lar da yapay nöronlardan oluşan katmanlar halinde çalışır; giriş katmanından gelen verileri işleyerek ara katmanlarda analiz eder ve çıkış katmanında bir sonuç üretir. İnsan sinir sistemindeki öğrenme süreci, deneyimlerle sinapsların güçlenmesiyle gerçekleşirken, YSA'larda bu süreç, ağırlıkların ve önyargıların (bias) veri setleri üzerinde yapılan eğitimle optimize edilmesiyle sağlanır. Her iki sistemde de temel prensip, girdilerden öğrenerek çıktılar üretmek ve zamanla daha doğru sonuçlara ulaşmaktır; ancak YSA'lar, biyolojik sinir sisteminin karmaşıklığını ve duygusal boyutunu taklit edemese de örüntü tanıma ve karar verme gibi konularda oldukça etkilidir. (Maltarollo vd. 2013)



Şekil 3.22. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo vd. 2013)

Çalışmada, YSA modeli olarak İleri Besleme Sinir Ağları kullanılmıştır. FFNN'ler biyolojik sinir sistemlerinden esinlenerek tasarlanmış, girişten çıkışa doğru bilgi akışının olduğu ve geri besleme bağlantılarının bulunmadığı yapay sinir ağı modelleridir. Temel yapı taşları nöronlardır, nöronlar, bir önceki katmandan gelen ağırlıklı girişleri toplar, bu toplamı bir aktivasyon fonksiyonundan geçirerek çıkış üretir ve bu çıkış bir sonraki katmana iletilir. FFNN'ler, genellikle giriş, bir veya daha fazla gizli katman ve çıkış katmanı olmak üzere katmanlı bir yapıdadır; tek katmanlı (yalnızca giriş ve çıkış katmanı) veya çok katmanlı (arada gizli katmanlar ile) olabilir. Gizli katmanların varlığı ağın yüksek dereceli istatistikleri çıkarabilmesini sağlar. FFNN'ler, çevreden gelen verilerle serbest parametrelerini (ağırlıklar ve bias) ayarlayarak

performansını artırır ve özellikle desen sınıflandırma, sistem modelleme gibi alanlarda yaygın olarak kullanılır (Murat 2006).



Şekil 3.23. 3 Katmandan oluşmuş tipik İleri Besleme Sinir Ağı Modeli

Model, giriş katmanı hariç, üç gizli katman ve bir çıkış katmanı olmak üzere toplam dört katmandan oluşmaktadır. Birinci Gizli Katman 64 nöron içermekte, gelen veriyi işleyerek daha yüksek boyutlu bir temsil oluşturmaktadır. İkinci Gizli Katman 32 nöron içermekte, bir önceki katmanın çıktısını alarak daha özet bir temsil üretmektedir. Üçüncü Gizli Katman 16 nöron içermekte, özellik temsili daha da sıkıştırarak modelin genelleme yapmasını sağlamaktadır. Çıkış Katmanı tek bir nöron içermekte ve modelin nihai çıktısını üretmekte olup su seviyesi tahmini gibi sürekli bir değer döndürmek için tasarlanmıştır.

Çok katmanlı ağlarda, gradyan iniş algoritması kullanan öğrenme süreçlerinde; yerel minimumlar ve düzlükler nedeniyle yavaş yakınsama sorunu ortaya çıkmaktadır. Gradyan iniş algoritmasında, ağırlık vektörü amaç fonksiyonunun en dik iniş yönünde güncellenmekte ve çıktının türevi dikkate alınmaktadır. Bu sorunu önlemek için türev teriminin bir sabit ile değiştirildiği bir öğrenme yöntemi olan ReLU (Düzeltilmiş Doğrusal Birim) aktivasyon fonksiyonunun yakınsamayı hızlandırabildiği ortaya konmuştur (Hara et al. 2015). Çalışmada, her gizli katmanda ReLU aktivasyon fonksiyonu kullanılmaktadır.

ReLU aktivasyon fonksiyonunun yanı sıra, çalışmada; her gizli katmanda L1/L2 düzenliliştirilmesi uygulanmıştır. L1 düzenliliştirilmesi, modelin ağırlıklarının toplam mutlak değerini ceza terimi olarak ekleyerek ağırlıkların bir kısmının sıfıra çekilmesini ve sparse (seyrek) çözümler elde edilmesini sağlamakta, özellikle gereksiz özelliklerin etkisini ortadan kaldırmak ve değişken seçimi yapmak için kullanılmaktadır. L2 düzenliliştirme, modelin ağırlıklarının karelerinin toplamını ceza terimi olarak ekleyerek tüm ağırlıkları küçültmeye çalışmakta ve aşırı büyük ağırlıkları engellemektedir (Xu vd. 2010). Her iki yöntem de modelin aşırı öğrenmesini (overfitting) önlemeye yardımcı olmaktadır.

Modelde, her gizli katmanın ardından %20 oranında Dropout uygulanmaktadır. Dropout, sinir ağlarında aşırı öğrenmeyi (overfitting) önlemek için kullanılan etkili bir düzenleme yöntemidir. Yöntem; eğitim sırasında ağıdaki gizli ve giriş katmanlarındaki bazı nöronları rastgele ve geçici olarak devre dışı bırakarak modelin yalnızca belirli nöronlara veya bağlantılara aşırı bağımlı olmasını engelleyip genelleme yeteneğini artırmaktadır (Srivastava vd. 2014).


Modelin çıkış katmanı, tek bir nörondan oluşmakta ve lineer aktivasyon fonksiyonu kullanmaktadır. Lineer aktivasyon fonksiyonları, yapay sinir ağlarında giriş verisine doğrusal bir dönüşüm uygulayarak çıktının girişe orantılı olmasını sağlamaktadır. Bir sinir ağının tüm katmanlarda lineer aktivasyon fonksiyonu kullanılması halinde, ağın derinliği ne kadar fazla olursa olsun, sonuçta elde edilen model tek katmanlı bir ağ ile aynı işlevi görmektedir, yani ağın karmaşıklığı artmamaktadır. Bu nedenle, lineer aktivasyon fonksiyonları genellikle regresyon problemlerinde veya ağın çıktı katmanında tercih edilmektedir (Myakala 2025).

3.2.7. Optimizasyon Algoritmaları

Modelin optimizasyonu için Çita Optimizasyon Algoritması kullanılmıştır. Çitalar; Afrika ve İran'ın merkezi bölgelerine özgü olan büyük kediler olup benekleri, siyah gözyaşı çizgileri ve hızlarıyla tanınmaktadır. Çitalar, dünyanın en hızlı kara memelisidir ve kısa mesafelerde saatte 70 mil (yaklaşık 113 km) hıza ulaşabilirler. Hız için tasarlanmış vücut yapıları; güçlü kaslar, yarı geri çekilebilir pençeler ve dümen görevi gören uzun bir kuyruk ile desteklenir (Brandon 2024).

Algoritma, vahşi doğada avlanan çitaların kullandığı üç ana basit strateji üzerine kurulmuştur ve ayrıca optimizasyon problemlerinde yaygın olan çeşitlilik eksikliği ve erken yakınsama sorunlarını ele alan ek bir strateji içerir. Çitaların avlanma rutinlerinin matematiksel modellenmesi basit ve esnektir; büyük ölçekli optimizasyon problemlerini etkili bir şekilde çözmek için kanıtlanmış bir yöntemdir (Abd Elaziz vd. 2023).

Çitaların genellikle üç temel avlanma stratejisi vardır; arama, oturma ve bekleme ve saldırı modları. Bir çitanın, dolaşırken veya çevresini izlerken bir av bulma şansı vardır. Bir çita avını gördüğünde, saldırmadan önce pozisyon alıp oturabilir ve avının yaklaşmasını bekleyebilir. Hücum ve yakalama, saldırı modunun iki aşamasıdır. Çita, yorgunluk veya avının fazla hızlı koşması gibi bazı nedenlerle avlanmayı bırakabilir ve dinlenerek avlanmaya yeniden başlamak için evine dönebilir. Çita, avın durumunu, alanını ve mesafesini değerlendirdikten sonra bu tekniklerden birini seçebilir. COA, çitaların avlanma zamanlarındaki bu stratejilerini etkin olarak kullanmaya odaklanır. (Zare vd. 2024)



Şekil 3.24. Çitaların avlanma stratejisi a) arama b) oturup bekleme c) hücum d) yakalama (Akbari et al. 2022)

Çitalar, avlarını avlamak için üç ana strateji kullanır: arama, oturup-bekleme ve saldırma. (Pandey et al. 2023) Bir çita çevresini devriye gezdiğinde veya taradığında, avı tespit edebilir. Avı gördüğünde, çita yerinde oturup avın kendisine yaklaşmasını bekleyebilir ve ardından saldırıya geçer. Saldırı modu, koşma ve yakalama aşamalarını içerir. Çita, enerji sınırları, avın hızlı kaçması gibi çeşitli nedenlerle avlanmayı bırakabilir. Daha sonra eve dönüp dinlenir ve yeni bir avlanma başlatır. Avın durumunu, alanını ve ava olan mesafeyi değerlendirerek, çita bu stratejilerden birini seçebilir. Genel olarak, CO algoritması, avlanma dönemleri (iterasyonlar) sırasında bu avlanma stratejilerini akıllıca kullanmaya dayanır (Akbari vd. 2022).

Çitalar, avlarını ararken iki farklı yaklaşım kullanır; ya çevreyi ayakta veya oturarak taramak, ya da alan içinde aktif olarak devriye gezmek. Bu modda, çita enerji tasarrufu yaparken olası hedefler için de bir gözetim sürdürür. Çitanın her bir iterasyonda mevcut konumuna ve isteğe bağlı adım boyutuna dayalı olarak yeni konumunu geliştirmek için (3.2) rastgele arama denklemi önerilmiştir. Denklemden; $Y_{p,q}^{t+1}$ ve $Y_{p,q}^t$ çitanın p'nin q konfigürasyonundaki mevcut ve sıradaki konumunu, t indeksi avlanma zamanını, $R_{p,q}$ rassallık faktörünü, $a_{p,q}^t$ çitanın p'nin q konfigürasyonundaki adım uzunluğunu ifade eder (Pandey vd. 2023).

$$Y_{p,q}^{t+1} = Y_{p,q}^t + R_{p,q} \times a_{p,q}^t \quad (3.2)$$

Çitalar, avlarıyla karşılaştıklarında, yapacakları her eylem, avı uyarma potansiyeline sahiptir ve bu da avın kaçmasına neden olabilir. Bundan kaçınmak için, çita

gizlenerek veya yere yatarak pusuya yatmayı deneyebilir. Dolayısıyla, bu modda çalışırken çita avının kendisine daha yaklaşmasını bekler. Bu durum (3.3) denklemiyle modellenmektedir (Pratap vd. 2024).

$$Y_{p,q}^{t+1} = Y_{p,q}^t \quad (3.3)$$

Çitalar, avlarını etkili bir şekilde yakalamak için hız ve esneklik parametrelerine güvenirlir. Bir çita saldırıya geçmeye karar verdiğinde, tam hıza ulaşarak olağanüstü çeviklik ve hızını sergiler. Ani baskın ve çevik hareketler, çitanın ava hızlıca yaklaşmasını sağlar. Çitanın avlanma stratejisi, avın konumunu yakından takip etmeyi ve hareket yönünü dinamik olarak ayarlayarak avın yolunu kesmeyi ve yakalamayı içerir. Çita becerili manevralarla avın yolunu kesmeyi ve avın kaçmak için sınırlı seçenekleri olduğu bir durum yaratmayı amaçlar. Çitanın bir sonraki konumları, avın son konumlarının yakınında olur. Denklem (3.4) çitaların saldırı stratejilerini matematiksel terimlerle ifade etmektedir. Burada $Y_{B,q}^t$ avın mevcut konumunu gösterirken $R_{p,q}$ ve $\beta_{p,q}^t$ parametreleri de q düzenlemesindeki bireysel çita p ile ilişkili parametrelerdir. Bunlar sırasıyla dönüşüm ve etkileşim parametresini temsil ederler (Pandey vd. 2023).

$$Y_{p,q}^{t+1} = Y_{B,q}^t + R_{p,q} \times \beta_{p,q}^t \quad (3.4)$$

Çita, avda başarısız olması halinde; pozisyonunu değiştirir veya sınırlarına geri döner. Yine belli bir zaman aralığında başarılı av yapamaması halinde; avı son gördüğü noktaya geri dönerek etrafında aranmaya devam eder (Akbari vd. 2022).

Model önce COA ve takiben de sırayla PSO, GWO ve SA algoritmaları ile çalıştırılmış ve eğitim – test süreçleri gerçekleştirilerek ve R^2 , RMSE ve MAE değerleri hesaplanmıştır. Model her bir optimizasyon algoritması ile 10 defa çalıştırılmış ve bu 10 çalıştırmada elde edilen R^2 , RMSE ve MAE değerlerinin aritmetik ortalamaları, değerlendirmeye esas alınmıştır.

PSO, doğadaki bireylerin grup içi sosyal davranışlarından esinlenerek geliştirilmiş, evrimsel bir hesaplama tekniği olan global bir optimizasyon algoritmasıdır. PSO, bir optimizasyon problemindeki çözümleri bulmak için bir arama uzayında rastgele konumlar ve hızlarla başlatılan bir parçacık (birey) popülasyonunu kullanır; burada her parçacık, problemin serbestlik derecesi kadar uzunlukta bir vektörle temsil edilir. Algoritma, her bir parçacığın uygunluk fonksiyonunu değerlendirir ve zaman ilerledikçe parçacıkların konumlarını ve hızlarını, kendi en iyi konumları ve tüm sürüdeki ya da komşuluklardaki en iyi global konumu dikkate alarak günceller. PSO'nun basitliği ve etkinliği, onu mühendislik problemlerinden ters problemlere kadar geniş bir yelpazede uygulanabilir kılan temel özelliklerindendir (Fernández-Martínez ve García-Gonzalo 2011).

Jahandideh-Tehrani vd. (2020) tarafından yapılan literatür incelemeleri, PSO algoritmasının su kaynakları mühendisliğinde yaygın ve başarılı bir şekilde kullanıldığını ortaya koymuştur. PSO ve varyantları, hidrolojik modelleme (yağış – akış tahmini, akarsu debisi tahmini), hidrolik sistem tasarımı (su dağıtım şebekeleri, boru ağları), rezervuar operasyonları, yeraltı suyu modellemesi, su kalitesi analizi ve su yönetimi (taşkın kontrolü, sel yayılımı) gibi alanlarda etkin sonuçlar vermiştir. Özellikle istatistiksel

yöntemler (SVM, ANN, ANFIS) ve diğer evrimsel algoritmalarla (GA, DE, SA) birleştirilerek geliştirilen hibrit PSO modelleri, tek ve çok amaçlı optimizasyon problemlerinde NSGA-II gibi yöntemlere kıyasla daha hızlı yakınsama, geniş arama uzayı ve yüksek doğruluk sağlamıştır. Mevcut çalışmalar, PSO'nun su kaynakları optimizasyonunda etkin bir araç olduğunu ve özellikle diğer evrimsel algoritmalarla (ACO, FA, ICA) hibrit olarak yeni uygulama alanlarında başarıyla kullanılabileceğini göstermektedir.

Gri Kurt Optimizasyon (GWO) algoritması, doğadaki gri kurtların avlanma davranışlarından esinlenen bir sürü zekası tabanlı optimizasyon yöntemidir. Algoritma, kurt sürüsündeki hiyerarşik yapıyı taklit ederek çalışır; sürü üyeleri avlanma sürecindeki rollerine göre alfa (en iyi çözüm), beta, delta ve omega olmak üzere dört gruba ayrılır. GWO'nun arama süreci, rastgele bir kurt popülasyonu oluşturmakla başlar, ardından bu gruplar oluşturulur ve ava (hedef çözüme) olan mesafeler hesaplanır. Her kurt bir aday çözümü temsil eder ve süreç boyunca güncellenir. Algoritma, yerel optimumlara takılmayı önlemek için keşif (exploration) ve sömürü (exploitation) dengesini sağlayan, iki parametreyle kontrol edilen güçlü operasyonlar kullanır. Diğer popülasyon tabanlı algoritmalarla benzer şekilde global optimumu tahmin etmekle beraber, GWO'nun matematiksel modeli özgündür ve bir çözümün başka bir çözüm etrafında n-boyutlu arama uzayında yeniden konumlandırılmasıyla kurtların avı takip etme ve kuşatma davranışını simüle eder. Parçacık Sürü Optimizasyonu (PSO) gibi algoritmalarla kıyasla, GWO yalnızca bir konum vektörü kullandığı için daha az bellek gerektirir ve sadece en iyi üç çözümü saklar. GWO küresel optimizasyon, elektrik mühendisliği, çizelgeleme, kontrol mühendisliği, robotik ve çevre planlaması gibi çok çeşitli optimizasyon problemlerinin çözümünde başarıyla uygulanmaktadır (Faris vd. 2018).

SA algoritması, bir optimizasyon probleminin çözüm uzayında, başlangıçta rastgele ve geniş bir arama yaparak, zamanla bu aramayı daraltan ve daha iyi çözümlere odaklanan bir yaklaşımdır. Yöntem, fiziksel sistemlerdeki tavlama sürecini taklit eder; yani bir malzemenin yüksek sıcaklıkta düzensiz bir haldeyken, yavaşça soğutulularak daha düzenli ve düşük enerjili bir yapıya ulaşması gibi, algoritma da çözüm arayışında önce serbestçe hareket eder, sonra giderek daha az “kötü” çözümü kabul ederek en iyi sonuca yaklaşır. Bu süreç, yerel minimumlara takılmadan küresel optimuma ulaşma olasılığını artırır (Rutenbar 1989).

3.2.8. Modelin Eğitilmesi

Model, 300 epoch boyunca eğitilmiştir. Bir epoch; eğitim verisinin tamamının bir kez modelden geçirilmesi anlamına gelmekte olup, 300 epoch modelin veriyi 300 kez tarayarak öğrenmesini sağlamaktadır. Eğitim verisi, 16'lık küçük gruplar (batch) halinde modele verilerek gradyan iniş algoritmasının her adımda tüm veriyi değil, 16 örnek üzerinden gradyan hesaplamasını yapması sağlanmış; bu şekilde hesaplama verimliliğinin artması ve daha stabil öğrenmesi sağlanmıştır.

Eğitim sürecini optimize ve kontrol etmek için üç geri çağırma mekanizması kullanılmıştır. Eğitim sırasında eğitim kümesindeki kayıp azalırken, test kaybı bir noktadan sonra sabitlenip ve tekrar artmaya başlamaktadır. Bu istenmeyen durumu önlemek için genellikle erken durdurma yöntemi kullanılmakta; yani, belirlenen bir erken durdurma kriteri sağlandığında optimizasyon işlemi sonlandırılmaktadır (Mahsereci vd.

2017). Modelde; kayıp belirli 50 epoch boyunca iyileşmezse eğitim durdurulmakta ve modelin daha fazla eğitimle gereksiz yere karmaşıklaşmasının veya aşırı öğrenmesinin önüne geçilmektedir.

Modelin yerel minimumlara takılmasını önlemek ve daha iyi bir yakınsama yapmasını sağlamak için ReduceLROnPlateau (Öğrenme Oranı Azaltma) geri çağırma mekanizması kullanılmıştır. ReduceLROnPlateau modeli, eğitim sırasında doğrulama veri kümesindeki başarı belirli bir süre değişmezse, öğrenme oranını önceden belirlenen bir katsayı ile çarparak düşürmekte ve bu işlemi öğrenme oranı en düşük değere ulaşana kadar devam ettirerek ve modelin daha verimli öğrenmesini sağlamaktadır (Üzen ve Hanbay 2020). Modelde; kayıp 25 epoch boyunca iyileşmezse, öğrenme oranı 0.1 ile çarpılarak azaltılmaktadır.

ModelCheckpoint geri çağırma mekanizması; eğitim sırasında modeli sürekli olarak kaydetmektedir. Tercihe bağlı olarak, yalnızca o ana kadar en iyi performansı gösteren modeli kaydetme yani bir epoch sonunda en iyi sonucu veren modelin sürümünü saklama kabiliyetine sahiptir (Cunha 2022). Çalışmada, modelde kullanılan bu mekanizma; her epoch sonunda doğrulama kaybını kontrol ederek, kaybın önceki en iyi değerden daha düşük olması halinde, modelin o anki ağırlıklarını bir dosyaya kaydedmekte ve eğitim sürecinde en iyi performansı gösteren modelin saklanmasını ve gerektiğinde kullanılmasını sağlamaktadır.

Model, Adam optimizasyon algoritması ve MSE (Ortalama Kare Hata) kayıp fonksiyonu kullanılarak eğitilmektedir. Her epoch içerisinde, eğitim verisi batch (kümeler) halinde modele verilip, kayıp hesaplanmakta ve ağırlıklar gradyan iniş yöntemiyle güncellenmektedir. Aynı zamanda doğrulama verisi üzerindeki kayıp izlenerek geri çağırımlar devreye girmektedir. Adam (Adaptive Moment Estimation), optimizasyon algoritması; özellikle büyük veri ve yüksek boyutlu parametre alanlarına sahip makine öğrenimi problemlerinde kullanılan, birinci dereceden gradyan tabanlı stokastik optimizasyon algoritmasıdır. Adam, her parametre için adaptif öğrenme oranları hesaplamak amacıyla gradyanların birinci (ortalama) ve ikinci momentlerinin (varyans) hareketli ortalamalarını kullanmaktadır. Hesaplama açısından verimli, hafıza gereksinimi düşük ve uygulaması kolay olan Adam, parametre güncellemelerinde otomatik olarak adım büyüklüğünü ayarlayarak hızlı ve kararlı bir şekilde yakınsama sağlamak ve genellikle hiperparametre ayarlarında hassasiyet gerektirmemektedir (Kingma and Ba 2015). Regresyon problemlerinde yaygın olarak kullanılan MSE kayıp fonksiyonu; tahmin edilen ve gerçek değerler arasındaki farkların karesinin ortalamasını almakta ve büyük hataları daha fazla cezalandırmakta olup verilerin normal dağılıma sahip olması halinde tercih edilmektedir (Raximov vd. 2022).

Gradyan iniş yöntemi; makine öğrenmesi uygulamalarında hata fonksiyonunu minimize etmek için kullanılan temel bir optimizasyon tekniğidir. Bu yöntemde, ağırlık vektörü, toplam hata terimini şekilde azaltacak biçimde güncellenir ve bu işlem, hata belirli bir seviyeye inene veya istenen iterasyon sayısına ulaşılan kadar devam eder. Gradyan iniş metodu, modelin parametrelerini en uygun değerlere yaklaştırarak, öğrenme sürecinin temelini oluşturmaktadır (Sharaff ve Sinha 2021).

3.2.9. Tahmin Yapılması

Tahmin yapma aşamasında, önceki adımda eğitilmiş ve optimize FFNN modeli, test verisi üzerinde kullanılarak tahminler üretilmektedir. Bu süreçte, daha önce veri ön işleme aşamasında ayrılmış ve normalleştirilmiş olan test verisi modele giriş olarak verilerek modelin, her bir test örneği için bir çıkış değeri üretmesi sağlanır ve çıkış katmanında tek bir nöron ile lineer aktivasyon fonksiyonu kullanıldığı için sürekli bir değer (su seviyesi tahmini) elde edilir. Modelin çıktısı olan tahminler, normalizasyon aşamasında yapılan işlemler nedeniyle, normalize edilmiş değerler şeklindedir. Gerek modelin tahmin ettiği değerler gerekse gerçek test değerleri; karşılaştırma ve değerlendirme yapılabilmesi için orijinal birimlerine geri dönüştürülmektedir.

3.2.10. Değerlendirme Ölçütleri

Çalışmada model sonuçlarının değerlendirilmesi için R^2 , RMSE ve MAE ölçütleri kullanılmıştır. R^2 ; regresyon analizinde uygunluğun ölçülmesi için temel ölçütlerdendir. Belirleme katsayısı, bağımsız değişkenlerin bağımlı değişkendeki varyasyonun ne kadarını açıkladığını gösterir ve 0 ile 1 arasında bir değer alır; 1'e ne kadar yakınsa modelin o kadar iyi bir uyum sağladığını ve varyasyonun büyük ölçüde açıklandığını ifade eder (Watson ve Teelucksingh 2010). R^2 ; aşağıda yer alan (3.5) bağıntısında gösterildiği şekilde hesaplanmaktadır.

$$R^2 = \frac{\text{Model tarafından açıklanabilen varyans}}{\text{Toplam varyans}} \quad (3.5)$$

RMSE değeri; tahmin edilen değerler ile gerçek değerler arasında bulunan farklılıkların, örnek standart sapmasını göstermektedir. Formülü (3.6) bağıntısında verilmiştir. Bağıntıda yer alan; y_t tahmini değeri, y_g gerçek (gözlemlenen) değeri, n ise gözlem sayısını göstermektedir. RMSE hesaplamasında; hataların ortalamaları alınmadan önce kareleri alındığından, büyük hatalara büyük önem veren bir yöntemdir ve buna bağlı olarak çoğunlukla büyük hataların istenmediği uygulamalarda kullanılmaktadır (Ebren Kara ve Şamlı 2021).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_t - y_g)^2}{n}} \quad (3.6)$$

MAE; regresyon modellerini değerlendirmek için kullanılan anlaşılması kolay ve en basit kayıp fonksiyonlarından biridir. Matematiksel olarak, bir regresyon modelinin etkinliğini değerlendirmek için kullanılan mutlak hataların ortalaması olup sadece hatanın büyüklüğünü ölçmekte, hatanın yönünü ölçmemektedir. MAE'nin düşük olması, modelin doğruluğunun yüksek olduğunu göstermektedir (Wang 2024). MAE Formülü (3.7) bağıntısında verilmiştir. Bağıntıda yer alan; y_i tahmini değeri, x_i gerçek (gözlemlenen) değeri, n ise gözlem sayısını göstermektedir.

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (3.7)$$

4. BULGULAR ve TARTIŞMA


4.1. Bulgular

YSA modeli; eğitim ve optimizasyon süreçlerinin tamamlanmasından sonra, test seti üzerinde yapılan nihai değerlendirme aşamasına ait değerlendirme ölçütlerini hesaplamaktadır. Model; her bir kuyunun su seviyesi tahmini için her bir optimizasyon algoritması kullanılarak 10'ar defa çalıştırılmıştır. Her bir çalışma sonucunda elde edilen değerlendirme ölçütlerinin ortalaması alınarak modelin değerlendirilmesinde bu ortalama değerler kullanılmıştır. Bu değerler Çizelge 5.1'de gösterilmektedir.

Çizelge 4.1. Değerlendirme ölçütleri

Kuyu No	COA			PSO			GWO			SA		
	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE
k_3861	0.7810	0.7129	0.5574	0.8959	0.4921	0.3766	0.8923	0.5005	0.3828	0.8566	0.5776	0.4781
k_25572/A	0.9731	0.6531	0.5096	0.9764	0.6113	0.4976	0.9796	0.5682	0.4358	0.9778	0.5937	0.4689
k_9470	0.9787	0.9848	0.7747	0.9661	1.2437	0.8503	0.9710	1.1503	0.8736	0.9808	0.9363	0.7365
k_25390	0.9720	0.8924	0.7084	0.9699	0.9257	0.6993	0.9635	1.019	0.7822	0.9771	0.8074	0.6399
k_50396	0.9440	1.1559	0.9118	0.9523	1.0667	0.8448	0.9317	1.2758	0.9925	0.9347	1.2474	0.9495
k_9479	0.9534	1.8098	1.4575	0.9350	2.1365	1.6935	0.9336	2.1599	1.7105	0.9392	2.0673	1.6436
k_60370	0.9216	0.2853	0.2275	0.9140	0.2988	0.2440	0.8929	0.3335	0.2646	0.9154	0.2964	0.2478
k_60364	0.8974	0.1905	0.1501	0.8404	0.2376	0.1685	0.9453	0.1391	0.1023	0.9239	0.1641	0.1256
k_41524/B	0.8739	1.0310	0.6104	0.8954	0.9388	0.5432	0.9149	0.8471	0.4688	0.9064	0.8884	0.5133
k_52277	0.8822	3.4594	1.6072	0.8836	3.4391	1.6673	0.8932	3.2949	1.5697	0.8901	3.3423	1.6228
k_60368	0.9755	1.6248	1.2787	0.9674	1.8742	1.4484	0.9762	1.6014	1.2467	0.9731	1.7023	1.3863
k_60373	0.9242	0.8679	0.6295	0.8951	1.0213	0.7885	0.9448	0.7409	0.565	0.9091	0.9503	0.7188
k_60365	0.9798	1.0285	0.7867	0.9760	1.1204	0.9583	0.9750	1.1441	0.9795	0.9608	1.4334	1.248
k_60367	0.9031	2.0583	1.6026	0.8830	2.2622	1.8125	0.9188	1.8841	1.4776	0.9027	2.063	1.678
k_60378	0.9190	0.4005	0.2863	0.8733	0.5010	0.3964	0.9427	0.3368	0.2553	0.9129	0.4154	0.3189
k_52276/B	0.9788	1.7214	1.4130	0.9723	1.9686	1.5423	0.9715	1.9948	1.5329	0.9832	1.5338	1.1182
k_27106	0.9700	1.3739	1.0422	0.9654	1.4769	1.1054	0.9623	1.5404	1.1362	0.9724	1.3173	0.9461
k_60363	0.7228	0.2950	0.2033	0.8143	0.2414	0.1634	0.7230	0.2949	0.219	0.7517	0.2792	0.1917

COA ile optimize edilmiş model 3 adet kuyuda diğer algoritmalarından daha yüksek R² ve daha düşük RMSE ile MAE değerine ulaşmaktadır. PSO ile optimize edilmiş model sonuçları; COA ile optimize edilmiş model ile aynı sayıda en yüksek R² ve en düşük RMSE ile MAE değerine sahiptir. GWO ile optimize edilmiş model 8 adet kuyuda diğer algoritmalarından daha yüksek R² ve daha düşük RMSE ile MAE değerine ulaşarak en çok kuyuda en iyi değerlere sahip olan modeldir. SA ile optimize edilmiş model 4 adet kuyuda diğer algoritmalarından daha yüksek R² ve daha düşük RMSE ile MAE değerine ulaşmaktadır.



Şekil 4.1. En iyi değerlendirme ölçütlerine göre kuyu sayıları

Çizelge 4.2. 18 kuyudan elde edilen değerlendirme ölçütlerinin ortalama değerleri

OPRİMİZASYON ALGORİTMASI	COA			PSO			GWO			SA		
ÖLÇÜT	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE
ORTALAMA DEĞERİ	0.9122	1.2661	0.8692	0.9073	1.3580	0.9560	0.9248	1.2480	0.8655	0.9177	1.2696	0.8919

Çizelge 4.1’de 18 kuyudan elde edilen değerlendirme ölçütlerinin aritmetik ortalamaları yer almaktadır. GWO algoritması en yüksek ortalama R² değeriyle en iyi doğruluk oranına ve en düşük MAE değeriyle en düşük ortalama mutlak hataya sahiptir. Ayrıca GWO, en düşük RMSE değeriyle de en iyi kök ortalama kare hata performansını göstermektedir. COA algoritması, R² değeri bakımından üçüncü sırada yer alırken, RMSE ve MAE değerleriyle GWO’dan sonra ikinci en iyi performansı sergilemektedir. SA algoritması ikinci en yüksek doğruluk oranına sahip olmasına rağmen, hata ölçütleri GWO ve COA’dan daha yüksektir. PSO algoritması ise en düşük doğruluk oranına ve en yüksek hata ölçütlerine sahiptir. Genel olarak, tüm algoritmaların R² değerleri birbirine yakın ve yüksek performans göstermektedir, ancak GWO algoritması tüm ölçütler açısından diğer algoritmalara göre daha üstün sonuçlar vermektedir.

Veri setindeki 18 kuyunun 2 tanesinin anlamlı eğilim göstermediği, diğerlerinin ise azalan eğilimde olduğu aktarılmıştır. Anlamlı eğilim göstermeyen kuyular incelendiğinde; k_60370 kuyusunun COA ile optimize edilmiş modelde en yüksek ölçütleri sağladığı, k_60373 kuyusunun ise GWO ile optimize edilmiş modelde en yüksek ölçütleri sağladığı belirlenmiştir.

4.2. Tartışma

Bu çalışma, FFNN modelinin COA, PSO, GWO ve SA algoritmaları ile optimize edilmesi sonucunda, 1 aylık tahminlere dayanan R², RMSE ve MAE ölçütlerini ortaya koymuştur. Bu bölümde ölçütlerin değerleri tartışılmış ve literatürdeki benzer çalışmaların sonuçları ile karşılaştırmalar yapılarak yorumlanmıştır.

İklimsel parametreler incelendiğinde, sıcaklık ve yağış desenlerinde belirgin değişimler dikkat çekmektedir. 2008 – 2023 yılları arasındaki sıcaklık verilerinin analizi, havzada bir ısınma eğiliminin varlığını ortaya koymaktadır. Mann-Kendall trend testi sonuçları (p-değeri = 0.0435, z = 2.0186), sıcaklıktaki artışın rastlantısal olmadığını ve %95 güven düzeyinde anlamlı olduğunu göstermektedir. Bu tarih aralığında havzadaki yıllık ortalama sıcaklık 16.25°C ve yıllık Sıcaklık Artış Hızı 0.1057°C olarak belirlenmiştir. Bu artış hızı, küresel ısınma senaryolarıyla uyumlu olup, 15 yıllık bir sürede yaklaşık 1.6°C’lik bir artışa karşılık gelmektedir. Sıcaklık artışının yıllık bazda 0.1057°C olması, havzanın iklim değişikliğinden önemli ölçüde etkilendiğini göstermektedir. Bu artış hızı devam ederse, önümüzdeki on yılda yaklaşık 1°C daha artış beklenebilir, bu da ekosistemleri, tarımsal üretimi ve su kaynaklarını etkileyebilir.

Yağış verileri, sıcaklıktaki belirgin artışın aksine, istatistiksel olarak anlamlı bir trend göstermemektedir. Mann-Kendall test sonuçları (p-değeri = 0.2844, z = -1.0705), yağıştaki değişimlerin rastlantısal olabileceğini göstermektedir. Bu tarih aralığında havzadaki aylık ortalama yağış miktarı 63.01 mm ve yıllık yağış değişim hızı -0.2844

mm olarak belirlenmiştir. Yağış miktarında hafif bir azalma eğilimi gözlenmekle birlikte, bu azalma istatistiksel olarak anlamlı değildir. Ancak, yağış rejimindeki değişkenlik ve mevsimsel dağılımdaki olası değişimler, su kaynakları yönetimi açısından dikkatle izlenmelidir.

Dams vd. tarafından; yeraltısuyu seviyelerinin iklimsel değişikliklere karşı çok hassas olduğu ve gelecek projeksiyonda; yıllık ortalama yeraltısuyu seviyesinde düşüşler meydana geleceği ortaya konmuştur. Bu çalışmada kullanılan 18 adet kuyu su seviyesi verisinin 16 adedi, sıcaklık artışı ve yağış düşüşüne paralel olarak azalma eğilimi göstermektedir.

Wunsch vd. (2022) iklim değişikliğinin 21. yüzyılda Almanya'daki yeraltı suyu kaynaklarını doğrudan nasıl etkileyeceğini araştırmak amacıyla ülke genelinde dağılan sahalarda, yapay sinir ağlarına dayalı bir makine öğrenimi yeraltı suyu seviyesi tahmin yaklaşımı uygulamışlardır. Çalışmada; ülke ölçeğinde iklim bazlı olarak yeraltısuyu seviyelerinde önemli düşüşler olacağı tespit edilerek sera gazı emisyonlarının azaltılmasının, gelecekteki yeraltı suyu seviyelerinin iklim kaynaklı kısmı için görünür bir etkiye sahip olabileceği ortaya konmuştur.

Myakala (2025), Hindistan'daki yeraltı suyu için iklim değişikliği senaryosunu ve iklim değişikliğinin yeraltı suyu kaynakları üzerindeki etkisini değerlendirme metodolojisini kullanarak yaptığı çalışmada; iklim değişikliğinin yaygın olarak kabul edilmesine rağmen, iklim değişikliğinin yeraltı suyu sistemi üzerindeki etkilerine ilişkin araştırmaların sınırlı olduğunu, iklim değişikliği ile tatlı yeraltı suyu kaynaklarının kaybı arasındaki ilişkinin araştırılmasının farklı bölgelerin özelliklerini anlamak için önem taşıdığını, gelecekteki iklim değişikliği etkilerinin, tarım ve nüfus artışına bağlı enerji, tatlı su ve gıda talepleri nedeniyle daha şiddetli hissedilebileceğini belirterek gelecekte hidrojeologların; sosyo-ekonomistler, tarım modelcileri ve toprak bilimcileri gibi diğer disiplinlerden araştırmacılarla birlikte daha fazla çalışma yapması gerektiğini ortaya koymuştur.

Çita Optimizasyon Algoritması (COA) ile optimize edilmiş modelin yeraltısuyu seviye değişimlerinin tahminindeki performansı, diğer meta-sezgisel algoritmalarla karşılaştırmalı olarak değerlendirilmiştir. COA ile optimize edilmiş model sonuçlarının 0.7228 ile 0.9798 aralığında değişen R^2 değeri, modelin yeraltısuyu seviyelerindeki değişimleri açıklamada oldukça başarılı olduğunu göstermektedir. Hata ölçütlerine bakıldığında, RMSE değerlerinin 0.1905 ile 3.4594 aralığında ve MAE değerlerinin 0.1501 ile 1.6072 aralığında olduğu görülmektedir.

COA algoritması, incelenen 18 kuyu içerisinde 3 kuyuda diğer algoritmalarından (PSO, GWO ve SA) daha yüksek R^2 ve daha düşük RMSE ile MAE değerleri sağlamıştır. Bu durum, COA'nın belirli hidrojeolojik koşullarda diğer algoritmalarla göre daha etkili olabileceğini göstermektedir. Özellikle dikkat çekici olan, trend analizi sonucunda anlamlı eğilim göstermeyen k_60370 kuyusunda COA'nın en yüksek performansı sergilemesidir. Bu kuyuda COA ile optimize edilmiş model, 0.9798 R^2 değeri, 0.1905 RMSE değeri ve 0.1501 MAE değeri ile diğer tüm algoritmaların önüne geçmiştir. Bu sonuç, COA'nın özellikle belirgin bir trend göstermeyen, yani zamansal değişimleri daha karmaşık ve öngörülmesi zor olan sistemlerde daha başarılı olabileceğini göstermektedir. COA'nın en düşük RMSE değeri (0.1905), tüm algoritmalar arasında GWO'dan (0.1391)

sonra ikinci en düşük değerdir, bu da algoritmanın hata minimizasyonunda oldukça etkili olduğunu ortaya koymaktadır.

COA algoritması, her ne kadar en iyi genel performansı sergilemese de GWO'ya oldukça yakın sonuçlar vermektedir. Özellikle RMSE ve MAE değerleri GWO ile çok yakın seviyede olup, bu da COA'nın tahmin hatası açısından rekabetçi bir algoritma olduğunu göstermektedir. COA'nın R^2 değeri de oldukça yüksek olup, diğer algoritmalarla arasındaki fark minimal düzeydedir. Bu durum, COA'nın yeraltı suyu seviyesi tahmininde güvenilir bir alternatif olarak değerlendirilebileceğini ortaya koymaktadır. SA algoritması ikinci en yüksek doğruluk oranına sahip olmasına rağmen, hata ölçütleri GWO ve COA'dan daha yüksektir. PSO algoritması ise en düşük doğruluk oranına ve en yüksek hata ölçütlerine sahiptir. Genel olarak, tüm algoritmaların R^2 değerleri birbirine yakın ve yüksek performans göstermektedir. Algoritmaların performans farklarının nispeten küçük olması, yeraltı suyu seviyesi tahmininde bu dört optimizasyon algoritmasının da başarılı sonuçlar verebileceğini göstermektedir. Bununla birlikte, GWO algoritması tüm ölçütler açısından diğer algoritmalara göre daha üstün sonuçlar vermektedir.

5. SONUÇ

Bu çalışma, Antalya Havzasında yeraltı suyu seviye değişimlerinin; yapay sinir ağı modelinin Çita Optimizasyon Algoritması ile optimize edilerek tahmin edilmesi yoluyla, iklimsel parametreler ile su seviyeleri arasındaki karmaşık ilişkileri ortaya koyarak gelecekteki su yönetimi politikaları için bilimsel bir temel oluşturmayı amaçlamıştır. Çalışmada, 2008-2023 yılları arasındaki aylık su seviyeleri, sıcaklık ve yağış verileri kullanılarak, bir ay sonrası su seviyesi tahminleri elde etmiştir.

Mann-Kendall testi sonuçları, havzada sıcaklıkta anlamlı bir artış (yıllık 0.1057°C) olduğunu, ancak yağışta istatistiksel olarak anlamlı bir trend bulunmadığını göstermektedir. Sıcaklık değerleri ve su seviyeleri karşılaştırıldığında, sıcaklık artışının yeraltı suyu seviyelerinde azalmaya neden olduğu, özellikle kurak dönemlerde bu etkinin daha belirgin olduğu gözlemlenmektedir. Yağış rejimindeki değişkenlik ve eğilimindeki belirsizlik, su seviyelerinde meydana getirdiği etkiyi yorumlamayı güçleştirerek kaynak yönetiminde uzun vadeli planlamaya yeterli katkıyı sunmamaktadır.

COA ile optimize edilmiş YSA modeli, 18 kuyudan 3'ünde en yüksek R^2 ve düşük RMSE ile MAE değerleri elde ederek, özellikle trend göstermeyen kuyularda güçlü bir performans sergilemiştir. Ancak, GWO ile optimize edilen model, 8 kuyuda en iyi sonuçları vererek genel performansta öne çıkmıştır. Bu, COA'nın belirli hidrojeolojik koşullarda rekabetçi olabileceğini, ancak GWO'nun daha geniş bir alanda etkili olduğunu göstermektedir.

2008-2023 yılları arasındaki 16 yıllık veriler, kısa vadeli eğilimlerin modellenmesi için yeterli olsa da daha uzun süreli veriler modelin genelleme kapasitesini artırabilir. Gözlem kuyularının miktarının daha fazla ve mekansal dağılımının homojen olması halinde, havza bütünündeki durum daha iyi temsil edilecektir. Ancak modelin 1 adet kuyu için ve 1 kere çalıştırılması; yaklaşık 1 saat 20 dakika sürmektedir. Bu durum, çalışmanın tamamlanması için uzun süre gerektirmekte olup kuyu sayısının artması halinde modelin çalıştırılması için çok daha fazla zamana ihtiyaç duyulacaktır. YSA modelinin karmaşık hidrojeolojik süreçleri tam olarak yakalayabilmesi için jeolojik formasyonlar, toprak özellikleri ve antropojenik etkiler gibi ek değişkenlerin modele dahil edilmesi, daha yüksek doğruluğa sahip sonuçları yakalamakta etkili olacaktır.

Literatürdeki benzer çalışmalar, yeraltı suyu seviyesi tahminlerinde YSA ve meta-sezgisel algoritmaların etkinliğini desteklemektedir. COA'nın özgün katkısı, literatürde daha önce yeraltı suyu tahminlerinde yaygın olarak kullanılmamış bir algoritma olarak denenmesi ve özellikle trend göstermeyen kuyularda yüksek performans sergilemesidir. Ancak, GWO'nun daha tutarlı sonuçları, algoritma seçiminde hidrojeolojik koşulların önemini vurgulamaktadır.

Daha uzun süreli ve daha fazla gözlem kuyusunu kapsayan veri setleri kullanılarak modelin genelleme kapasitesi artırılabilir. Ayrıca, uydu tabanlı uzaktan algılama verileri ile yeraltı suyu depolama değişimlerinin modellenmesi; çalışmanın mekansal kapsayıcılığını güçlendirebilir. Modele jeolojik formasyonlar, toprak nemi, arazi kullanımı, tarımsal sulama ve kentsel su tüketimi gibi antropojenik ve çevresel faktörlerin modele eklenmesi, hidrojeolojik süreçlerin daha kapsamlı modellenmesini sağlayabilir.

COA'nın performansının farklı hidrojeolojik özelliklere sahip havzalarda test edilmesi, algoritmanın kullanımında genelleştirmeyi değerlendirmek için önem taşımaktadır.



6. KAYNAKLAR

- Abd Elaziz, M., Ghoneimi, A., Nabih, M., Bakry, A. and Al-Betar, M.A. 2023. Contribution of Fluid Substitution and Cheetah Optimizer Algorithm in Predicting Rock-Physics Parameters of Gas-Bearing Reservoirs in the Eastern Mediterranean Sea, Egypt. *Natural Resources Research* 32(5): 1987-2005.
- Abdelkarim, B., Agoubi B., Abaab, N. and Antunes, I. 2024. Predicted impacts of global warming and climate change on groundwater resources in a semi-arid region, southeastern Tunisia. *Euro-Mediterranean Journal for Environmental Integration* 9(1): 325–337.
- Abdi, H. 2010. The greenhouse-geisser correction. In: Neil J. Salkind (Ed.), *Encyclopedia of Research Design*. Sage Publications, CA, pp. 545-548.
- Akbari, M.A., Zare, M., Azizipanah-Abarghooee, R. and Mirjalili, S. 2022. The cheetah optimizer: a nature-inspired metaheuristic algorithm for large-scale optimization problems. *Scientific Reports* 12(1): 1-20.
- Akdeniz, T. 2024. İdari Ve Fiziki Su Kayıplarının Yönetiminde Hızlı Ve Etkili Yöntemler: Antalya Örneği. *Akdeniz Mühendislik Dergisi* 2(2): 58–64.
- Akın, A. 2005. Suyun insan sağlığı için önemi ve su kirliliği. *Antropoloji*, 21: 31-58.
- Aksungur, N. ve Firidin, Ş. 2008. Su kaynaklarının kullanımı ve sürdürülebilirlik. *Aquaculture Studies*, 2: 9-11.
- Akşit, C. Antalya ve Burdur havzalarında don risk tarihlerinin değerlendirilmesi. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, 84 s.
- Alsaber, A.R., Pan, J. and Al-Hurban, A. 2021. Handling complex missing data using random forest approach for an air quality monitoring dataset: A case study of kuwait environmental data (2012 to 2018). *International Journal of Environmental Research and Public Health* 18(3): 1–26.
- Alshourbaji, I., Kachare, P.H., Jabbari, A. and Kirner, R. 2024. Improving prediction of solar radiation using Cheetah Optimizer and Random Forest. *PLOS ONE* 19(12): 1-20.
- Andonie, R. 2019. Hyperparameter optimization in learning systems. *Journal of Membrane Computing* 1(4): 279-291.
- Bahadırılı, Z.M. 2021. Yeraltı Suyu Seviye Değişiminin M5 Karar Ağacı Ve Yapay Sinir Ağları Yöntemleriyle Belirlenmesi. Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi, Hatay, 60 s.
- Bahir, M., Ouhamdouch, S. and Ouazar, D. 2021. An assessment of the changes in the behavior of the groundwater resources in arid environment with global warming in Morocco. *Groundwater for Sustainable Development*, 12: 1-18.

- Brandon, S. 2024. The business of saving cheetahs: Cheetah ecology and the diverse politics at work in human wildlife conflict (HWC) interventions in Namibia. *Environment and Planning E: Nature and Space*, 7(1): 102-122.
- Bun, M.J.G. and Harrison, T.D. 2019. OLS and IV estimation of regression models including endogenous interaction terms. *Econometric Reviews*, 38(7): 814-827.
- Çiner, A., Karabıyıkoglu, M., Monod, O., Deynoux, M. and Tuzcu, S. 2008. Late Cenozoic sedimentary evolution of the Antalya Basin, southern Turkey. *Turkish Journal of Earth Sciences*, 17(1): 1-41.
- Coulibaly, P., Anctil, F., Ramon, A. and Bobee, B. 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, 37(4): 885-896.
- Cui, F., Al-Sudani, Z.A., Hassan, G.S., Afan, H.A., Ahammed, S.J. and Yaseen, Z.M. 2022. Boosted artificial intelligence model using improved alpha-guided grey wolf optimizer for groundwater level prediction: Comparative study and insight for federated learning technology. *Journal of Hydrology*, 606: 1-16.
- Chollet, F. 2022. Deep learning with Python. Manning Publications Co., New York, 504 p.
- Demirci, M., Üneş, F. and Körlü, S. 2019. Modeling of groundwater level using artificial intelligence techniques: A case study of Reyhanlı region in Turkey. *Applied Ecology and Environmental Research*, 17(2): 2651-2666.
- Demiroğlu, M. 2017. Yeraltı suları bütçesi tartışmaları. *Jeoloji Muhendisligi Dergisi* 41(1): 79–89.
- Desale, S., Rasool, A., Andhale, S. and Rane, P. 2015. Heuristic and Meta-Heuristic Algorithms and Their Relevance to the Real World: A Survey. *International Journal Of Computer Engineering In Research Trends*, 351(5): 296-304.
- Ebren Kara, Ş. ve Şamlı, R. 2021. Yazılım Projelerinin Maliyet Tahmini için WEKA’da Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Analizi. *European Journal of Science and Technology*, 23: 415 – 426.
- Edwin K. and Zak S., 2013. An Introduction to Optimization. Wiley, New jersey, 642 p.
- Ercan, C., Arra, A.A. and Şişman, E. 2025. Investigation of precipitation and temperature trends using classical and innovative approaches with corresponding frequencies in Antalya Basin, Türkiye. *Physics and Chemistry of the Earth*, 139: 1-16.
- Faris, H., Aljarah, I., Al-Betar, M.A. and Mirjalili, S. 2018. Grey wolf optimizer: a review of recent variants and applications. *Neural Comput & Applic.* 30: 413-435.

- Fernández-Martínez, J.L. and García-Gonzalo, E. 2011. What Makes Particle Swarm Optimization a Very Interesting and Powerful Algorithm? In: Panigrahi, B.K., Shi, Y. and Lim, M.H. (Eds.), *Handbook of Swarm Intelligence. Adaptation, Learning, and Optimization*, vol 8. Springer, Berlin, pp. 37-65.
- Hamed, K.H. 2008. Trend detection in hydrologic data: The Mann-Kendall trend test under the scaling hypothesis. *Journal of Hydrology* 349(3-4): 350-363.
- Han, J., Kamber, M. and Pei, J. 2012. *Data Mining : Concepts and Techniques : Concepts and Techniques*. Morgan Kaufmann, Massachusetts, 744 p.
- Hansun, S. 2013. A new approach of moving average method in time series analysis. *Conference on New Media Studies*, pp. 1-4, 27-28 November, Tangerang.
- Hara, K., Saito, D. and Shouno, H. 2015. Analysis of function of rectified linear unit used in deep learning. *International Joint Conference on Neural Networks*, pp. 1-8, 12-17 July, Killarney.
- Hatun, M. and Vatansever, F. 2022. The design of control system simulator. *Uludağ University Journal of The Faculty of Engineering*, 1: 41-56.
- Hökelekli, E. and İçağa 2010. Akarçay Kuzey Alt Havzası Yeraltı Suyu Modellemesi. *AKÜ Fen Bilimleri Dergisi*, 2: 5-16.
- Işınkaralar, O., Sharifi A. and Işınkaralar, K. 2024. Assessing spatial thermal comfort and adaptation measures for the Antalya basin under climate change scenarios. *Climatic Change* 177(8): 1-17.
- Jahandideh-Tehrani, M., Bozorg-haddad, O. and Loaiciga, H. 2020. Application of particle swarm optimization to water management: an introduction and overview. *Environ Monit Assess*, 192: 1-18.
- Jain, Y.K. and Bhandare, S.K. 2013. Min Max Normalization Based Data Perturbation Method for Privacy Protection. *International Journal of Computer and Communication Technology*, 4(4): 233-238.
- Jolliffe, I.T. 2002. Principal Component Analysis. In: Lovric, M. (Ed.) *International Encyclopedia of Statistical Science*. Springer, Berlin, pp. 1094-1096.
- Jury, W.A. and Vaux, H. 2005. The role of science in solving the world's emerging water problems. *Proceedings of the National Academy of Sciences of the United States of America*, 102(44): 15715-15720.
- Kaman, H., Çetin, M. ve Sesveren, S. 2022. Akdeniz İklim Kuşağında, Sulamadan Dönen Suların Sulamada Kullanılmasının Taban Suyu Kalitesi ve Derinliği Üzerine Etkilerinin Araştırılması: Aşağı Seyhan Ovası Yemişli Sulama Sahası Örneği. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 25(1): 158-168.

- Kapan, K. ve Timor, A.N. 2018. Turizm gelişme modellemeleri açısından Antalya şehri. *Türk Coğrafya Dergisi*, 71: 53-61
- Katipoğlu, O.M., Keblouti, M. and Mohammadi, B. 2023. Application of novel artificial bee colony optimized ANN and data preprocessing techniques for monthly streamflow estimation. *Environmental Science and Pollution Research*, 30(38):89705-89725.
- Khaki, M., Yussof, I. and Islami, N. 2015. Simulation of groundwater level through artificial intelligence system. *Environmental Earth Sciences*, 73(12): 8357-8367.
- Khursheed, T. and Ashraf, M.M. 2023. Cheetah Optimizer-based Framework for Least Cost Generation Expansion Planning Incorporating Renewable Energy Sources. 2nd International Conference on Emerging Trends in Electrical, Control, and Telecommunication Engineering, pp. 1-6, 27-29 November, Lahore.
- Kımençe, T. 2023. Su kaynakları yönetiminde havza ölçekli faaliyetler. In: Aydın, M.E. ve Şahin, A.D. (Eds.), İklim Değişikliği Çerçevesinde Su Kaynaklarının Mevcut Durumu ve Geleceği, TÜBA Yayınları, Ankara, ss. 155-170.
- Kingma, D.P. and Ba, J.L. 2015. Adam: A method for stochastic optimization. International Conference on Learning Representations, pp. 1-15, 14-16 April, Alberta.
- Klein, C.E., Mariani, V.C. and Coelho, L.S. 2018. Cheetah based optimization algorithm: A novel swarm intelligence paradigm. Computational Intelligence and Machine Learning, pp. 685-690, 25-27 April, Bruges.
- Kombo, O.H., Kumaran, S., Sheikh, Y.H., Bovim, A. and Jayavel, K. 2020. Long-term groundwater level prediction model based on hybrid KNN-RF technique. *Hydrology*, 7(3): 1-24.
- Myakala, P.K. 2025. Mastering Machine Learning. Eliva Press, Chişinău, 85 p.
- Kundzewicz, Z.W. and Döll, P. 2009. Will groundwater ease freshwater stress under climate change? *Hydrological Sciences Journal*, 54(4): 665–675.
- Mahsereci, M., Nalles, L., Lassner, C. and Hennig, P. 2017. Early Stopping without a Validation Set. *ArXiv*, 1703.09580: 1-16.
- Mallows, C.L. and Reza, F.M. 1964. An Introduction to Information Theory. *The American Mathematical Monthly*, 71(1): 364-378.
- Maltarollo, V.G., Honorio, K.M. and Silva, A.B.F. 2013. Applications of Artificial Neural Networks in Chemical Problems. In: Suzuki K. (Ed.), Artificial Neural Networks - Architectures and Applications. IntechOpen, Rijeka, pp. 203-223.
- McDermott, R. 2002. Experimental methods in political science. *Annual Review of Political Science*, 5: 31-61.


- McNutt, M. 2013. Climate Change Impacts. *Science* 341(6145): 435.
- Miao, J. and Niu, L. 2016. A Survey on Feature Selection. *Procedia Computer Science*, 91: 919-926.
- Murat H.S. 2006. A brief review of feed-forward neural networks. *Communications Faculty Of Science University of Ankara*, 50(1): 11-17.
- Nabipour, N., Dehghani, M., Band, S.S. and Mosavi, A. 2020. Short-Term Hydrological Drought Forecasting Based on Different Nature-Inspired Optimization Algorithms Hybridized with Artificial Neural Networks. *IEEE Access*, 8: 15210-15222.
- Pandey, A., Soren, N. and Sankar, M.M. 2023. Optimal Allocation of Renewable Distributed Energy Resources in Distribution System using Cheetah Optimization Algorithm. International Conference on Evolutionary Algorithms and Soft Computing Techniques, pp. 1-6, 20-21 October, Bengaluru.
- Pandey, K., Kumar, S., Malik, A. and Kuriqi, A. 2020. Artificial neural network optimized with a genetic algorithm for seasonal groundwater table depth prediction in Uttar Pradesh, India. *Sustainability*, 12(21): 1-24.
- Picton, P. 1994. What is a Neural Network? In: Picton, P. (Ed.), Introduction to Neural Networks. Red Globe Press, London, 168 p.
- Pratap, A., Tiwari, P., Maurya, R. and Singh, B. 2024. Cheetah Optimization Algorithm for Simultaneous Optimal Network Reconfiguration and Allocation of DG and DSTATCOM with Electric Vehicle Charging Station. *Serbian Journal of Electrical Engineering*, 21(1): 1-37.
- Raju, V.N.G., Lakshmi, K.P., Jain, V.M., Kalindi, A. and Padma, V. 2020. Study the Influence of Normalization/Transformation process on the Accuracy of Supervised Classification. Third International Conference on Smart Systems and Inventive Technology, pp. 729-735, 20-22 August, Tirunelveli.
- Rakhshandehroo, G., Akbari, A., Igder, M.A. and Ostadzadeh, E. 2018. Long-Term Groundwater-Level Forecasting in Shallow and Deep Wells Using Wavelet Neural Networks Trained by an Improved Harmony Search Algorithm. *Journal of Hydrologic Engineering* 23(2): 1-16.
- Raximov, N., Kuvandikov, J. and Dilmurod, K. 2022. The importance of loss function in artificial intelligence. International Conference on Information Science and Communications Technologies, pp. 1-3, 28-30 September, Tashkent.
- Rutenbar, R.A. 1989. Simulated annealing algorithms: An overview. *IEEE Circuits and Devices Magazine*, 5(1): 19-26.
- Sahoo, S. and Jha, M.K. 2013. Groundwater-level prediction using multiple linear regression and artificial neural network techniques: A comparative assessment. *Hydrogeology Journal*, 21(8): 1865-1887.

- Samani, S., Vadiati, M., Azizi, F., Zamani, E. and Kişi, O. 2022. Groundwater Level Simulation Using Soft Computing Methods with Emphasis on Major Meteorological Components. *Water Resources Management*, 36(10): 3627-3647.
- Sapac, K., Vidmar, A., Bezak, N. and Rusjan, S. 2020. Lag times as indicators of hydrological mechanisms responsible for NO₃-N flushing in a forested headwater catchment. *Water*, 12(4): 1-13.
- Sargın, S. 2003. Isparta Şehri'nin çevre sorunları. *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*, 5(2): 147-166.
- Şen, Z. 2009. Global warming threat on water resources and environment: a review. *Environmental Geology*, 57(2): 321-329.
- Şentürk, R., Kurban, R. ve Çakıroğlu, F. 2023. Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini. *SETSCI Conference Proceedings*, 15(6): 59-63.
- Sharaff, A. and Sinha, G.R. 2021. Data Science and Its Applications. Chapman and Hall, New York, 378 p.
- Simlandy, S. 2015. Importance of Groundwater as Compatible with Environment. *International Journal of Ecosystem*, 5(3A): 89-92.
- Singha, K. and Navarre-Sitchler, A. 2022. The Importance of Groundwater in Critical Zone Science. *Groundwater* 60(1): 27-34.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. 2014. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56):1929-1958.
- Sultan, D., Tsunekawa, A., Tsubo, M., Haregeweyn, N., Adgo, E., Meshesha, D.T., Fenta, A.A., Ebabu, K., Berihun, M.L. and Setargie, T.A. 2022. Evaluation of lag time and time of concentration estimation methods in small tropical watersheds in Ethiopia. *Journal of Hydrology: Regional Studies* 40(3): 1-15.
- Supreetha, B.S., Shenoy, N. and Nayak, P. 2020. Lion Algorithm-Optimized Long Short-Term Memory Network for Groundwater Level Forecasting in Udupi District, India. *Applied Computational Intelligence and Soft Computing*, 2020: 1-8.
- Sureshkumar, V., Rajasomashekar, S. and Sarala, B. 2023. An efficient underground water prediction using optimal deep neural network. *Concurrency and Computation: Practice and Experience* 35(1): 1-14.
- Su Yönetimi Genel Müdürlüğü 2016. Antalya Havzası Taşkın Yönetim Planı (yayınlanmamış), Ankara.
- Su Yönetimi Genel Müdürlüğü 2018. Antalya Havzası Kuraklık Yönetim Planı (yayınlanmamış), Ankara.


- Tongal, H. 2019. Spatiotemporal analysis of precipitation and extreme indices in the Antalya Basin, Turkey. *Theoretical and Applied Climatology* 138(3-4): 1735-1754.
- Üstün, G.E., Can, T. ve Küçük, G. 2020. Binalarda yağmur suyu hasadı. *Uludağ University Journal of The Faculty of Engineering*, 25(3): 1593-1610.
- Üzen, H. ve Hanbay, K. 2020. Yaya Özellik Tanıma için LM Filtre Temelli Derin Evrişimsel Sinir Ağı. *Politeknik Dergisi*, 23(3): 605-613.
- Wang, W. 2024. Principles of Machine Learning: The Three Perspectives. Springer, New York, 604 p.
- Watson, P.K. and Teelucksingh, S.S. 2010. A Practical Introduction to Econometric Methods. University Press of the West Indies, Barbados, 320 p.
- Wen, X., Feng, Q., Deo, R. and Wu, M. 2017. Wavelet analysis-artificial neural network conjunction models for multi-scale monthly groundwater level predicting in an Arid Inland River Basin, northwestern China. *Hydrology Research*, 48 (6): 1710–1729.
- Wunsch, A., Liesch, T. and Broda, S. 2022. Deep learning shows declining groundwater levels in Germany until 2100 due to climate change. *Nature Communications* 13: 1-13.
- Xu, Z., Zhang, H., Wang, Y., Chang, X. and Liang, Y. 2010. L1/2 regularization. *Science in China, Series F: Information Sciences* 53(6): 1159-1169.
- Yang, Q., Hou, Z., Wang, Y., Zhau. Y. and Delgado, J. 2015. A comparative study of shallow groundwater level simulation with WA–ANN and ITS model in a coastal island of south China. *Arabian Journal of Geosciences* 8: 6583–6593.
- Zang, H., Zhang, S. and Hapeshi, K. 2010. A review of nature-inspired algorithms. *Journal of Bionic Engineering* 7: 232-237.
- Zare, M., Farhang, S., Akbari, M.A., Azizipanah-Abarghooee, R. and Trojovský, P. 2024. Optimizing reserve-constrained economic dispatch: Cheetah optimizer with constraint handling method in static/dynamic/single/multi-area systems. *Energy* 313: 1-23.


7. EKLER


EK-1. k_3861 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-2. k_9470 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-3. k_9479 kuyusunun test verileri ölçüm ve tahmin değerleri


EK-4. k_25390 kuyusunun test verileri ölçüm ve tahmin değerleri

EK-5. k_25572A kuyusunun test verileri ölçüm ve tahmin değerleri



EK-6. k_27106 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-7. k_41524B kuyusunun test verileri ölçüm ve tahmin değerleri




EK-8. k_50396 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-9. k_52276B kuyusunun test verileri ölçüm ve tahmin değerleri





EK-10. k_52277 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-11. k_60363 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-12. k_60364 kuyusunun test verileri ölçüm ve tahmin değerleri



EK-13. k_60365 kuyusunun test verileri ölçüm ve tahmin değerleri


EK-14. k_60367 kuyusunun test verileri ölçüm ve tahmin değerleri




EK-15. k_60368 kuyusunun test verileri ölçüm ve tahmin değerleri



EK-16. k_60370 kuyusunun test verileri ölçüm ve tahmin değerleri

EK-17. k_60373 kuyusunun test verileri ölçüm ve tahmin değerleri


EK-18. k_60378 kuyusunun test verileri ölçüm ve tahmin değerleri

ÖZGEÇMİŞ

Erdem ATÇA

ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2022-2025	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı, Antalya
Lisans 2000-2004	Anadolu Üniversitesi Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Eskişehir

MESLEKİ VE İDARİ GÖREVLER

Şube Müdürü 2011-Devam ediyor.	ASAT Genel Müdürlüğü Yatırım ve İnşaat Dairesi Başkanlığı, Antalya
Mühendis 2008-2011	ASAT Genel Müdürlüğü Etüt ve Plan Dairesi Başkanlığı, Antalya

ESERLER

Ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1- Atça E., San K.D. 2014. Landsat 8 Uydu Görüntüleri ve Ek Bantlar Kullanılarak Arazi Örtüsü Sınıflandırması: Manavgat Çayı Havzası Örneği. JEOUZAL 2014, ss. 63-66, 13-14 Mart, Akdeniz Üniversitesi, Antalya.