



**TÜRKİYE’DEKİ BARAJ SU SEVİYELERİNİN
ZAMAN SERİSİ ve YAPAY ZEKA
ALGORİTMALARIYLA TAHMİNİ: YUSUFELİ ve
DERİNER BARAJLARI ÜZERİNE BİR ÇALIŞMA**

Ahmet Enes YEĞİN

**Danışman: Dr. Öğr. Üyesi Abdullah Ammar
KARCIOĞLU**

**Yüksek Lisans Tezi
Yazılım Mühendisliği Ana Bilim Dalı**

2025

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAZILIM MÜHENDİSLİĞİ ANA BİLİM DALI

**TÜRKİYE'DEKİ BARAJ SU SEVİYELERİNİN ZAMAN SERİSİ ve YAPAY ZEKA
ALGORİTMALARIYLA TAHMİNİ: YUSUFELİ ve DERİNER BARAJLARI
ÜZERİNE BİR ÇALIŞMA**

(Dam Water Levels Prediction in Turkey Using Time Series and Artificial Intelligence
Algorithms: A Study on Yusufeli and Deriner Dams)

YÜKSEK LİSANS TEZİ

Ahmet Enes YEĞİN

Danışman: Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU

Erzurum
Haziran, 2025

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU danışmanlığında sunulan “Türkiye’deki Baraj Su Seviyelerinin Zaman Serisi ve Yapay Zeka Algoritmalarıyla Tahmini: Yusufeli ve Deriner Barajları Üzerine Bir Çalışma” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	%1	30
Kuramsal Temeller	%1	30
Materyal ve Metot	%4	35
Araştırma Bulguları ve Tartışma	%0	20
Sonuçlar ve Öneriler	%0	20
Tezin Geneli	%4	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5’den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Ahmet Enes YEĞİN	Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU
19.11.2025	19.11.2025
İmza:	İmza:



FEN BİLİMLERİ ENSTİTÜSÜ
Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

Türkiye’deki Baraj Su Seviyelerinin Zaman Serisi ve Yapay Zeka Algoritmalarıyla Tahmini:
Yusufeli ve Deriner Barajları Üzerine Bir Çalışma

Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU danışmanlığında, Ahmet Enes YEĞİN tarafından hazırlanan bu çalışma, 12/01/2026 tarihinde aşağıdaki jüri tarafından Yazılım Mühendisliği Anabilim Dalı Yazılım Mühendisliği Bilim Dalı’nda Yüksek Lisans tezi olarak **oybirliği / oy çokluğu (.../...)** ile kabul edilmiştir.

Jüri Başkanı:	Dr. Öğr. Üyesi Merve YILDIRIM <i>Karadeniz Teknik Üniversitesi</i>	Aslı ıslak imzalıdır
Danışman:	Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Dr. Öğr. Üyesi Esra ODABAŞ YILDIRIM <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır

Enstitü Yönetim
Kurulunun .../.../.... tarih
ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof.Dr. Alper NUHOĞLU
Enstitü Müdürü

Aslı ıslak imzalıdır

TEŞEKKÜR

Bu çalışmanın hazırlanması sürecinde fikirleri, yönlendirmeleri ve akademik desteğiyle araştırmanın her aşamasına katkı sağlayan danışmanım Dr. Öğr. Üyesi Abdullah Ammar Karcıoğlu'na teşekkür ederim. Kendisinin bilimsel yaklaşımı, tecrübesi ve yapıcı geri bildirimleri, çalışmanın bilimsel niteliğinin güçlenmesine önemli ölçüde katkı sunmuştur.

Çalışmada kullanılan verilerin sağlanması sürecinde destek veren Elektrik Üretim A.Ş. (EÜAŞ) ve T.C. Enerji ve Tabii Kaynaklar Bakanlığı yetkililerine teşekkür ederim. Sağlanan teknik veriler, araştırmanın deneysel bölümünün gerçekleştirilebilmesi ve sonuçların bilimsel olarak değerlendirilebilmesi açısından büyük önem taşımıştır.

Araştırma süresince her koşulda beni destekleyen, motivasyonumu artıran ve sabır gösteren aileme ve yakın çevreme minnettarlığımı ifade etmek isterim. Akademik gelişimime katkı sunan tüm hocalarıma, çalışma arkadaşlarıma ve bu süreçte yanımda olan herkese teşekkür ederim.

Bu çalışma, veri tabanlı mühendislik yaklaşımlarının hidroelektrik baraj yönetimi süreçlerine entegre edilebileceğini göstermek amacıyla hazırlanmış olup, elde edilen bulguların ileride yapılacak akademik ve uygulamalı araştırmalara katkı sağlayacağı değerlendirilmektedir.

Ahmet Enes YEĞİN

ÖZET

YÜKSEK LİSANS TEZİ

TÜRKİYE'DEKİ BARAJ SU SEVİYELERİNİN ZAMAN SERİSİ ve YAPAY ZEKA ALGORİTMALARIYLA TAHMİNİ: YUSUFELİ ve DERİNER BARAJLARI ÜZERİNE BİR ÇALIŞMA

Ahmet Enes YEĞİN

Danışman: Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU

Amaç: Bu çalışmada, Türkiye'nin önemli hidroelektrik yapıları arasında yer alan Yusufeli ve Deriner Barajları için kısa vadeli su seviyesi tahmini gerçekleştirilmiştir. Baraj işletme süreçlerinde doğru tahminin; enerji üretim planlaması, taşkın riskinin azaltılması ve su kaynağı yönetiminin optimize edilmesi açısından kritik öneme sahip olması nedeniyle, hem istatistiksel zaman serisi yöntemleri hem de DL (derin öğrenme) tabanlı yaklaşımlar karşılaştırmalı olarak değerlendirilmiştir.

Yöntem: Çalışmada gerçek günlük hidrolojik veriler kullanılarak iki aşamalı bir yaklaşım uygulanmıştır. İlk aşamada ARIMA, SARIMA, ARIMAX ve SARIMAX modelleri ile geleneksel zaman serisi tahminleri yapılmış; veriler normalize edilerek eğitim-test ayrımı gerçekleştirilmiş ve hata metrikleri üzerinden model başarımları ölçülmüştür. İkinci aşamada DL tabanlı CNN, LSTM, GRU ve hibrit mimariler kullanılmıştır. Ayrıca mimari tasarım ve hiperparametre seçimini otomatik yürütmek için Bayes tabanlı Sinir Mimari Arama yöntemi uygulanmıştır. Bu kapsamda zamansal bağımlılıkları ve yapısal örüntüleri ortak öğrenebilmek amacıyla CGU (CNN-GRU Unified) modeli geliştirilmiştir.

Bulgular: İstatistiksel yöntemlerin yüksek performans değerleri sağladığını göstermiştir. Yusufeli Barajı için ARIMA modeli $0.9932 R^2$ skoru elde ederken, Deriner Barajı için SARIMAX modeli $0.9905 R^2$ skoruna ulaşmıştır. DL aşamasında hibrit modeller daha üstün performans sergilemiş ve CGU modeli test verisi üzerinde $R^2 = 0.9941$ değeri ile en yüksek R^2 skorunu sağlamıştır.

Sonuç: Elde edilen bulgular, su seviyesi tahmininde yapay zeka tabanlı hibrit modellerin güvenilir, hızlı ve uygulanabilir bir çözüm sunduğunu ortaya koymuştur. Özellikle CGU modelinin gerçek zamanlı karar destek mekanizmalarına entegre edilebilecek nitelikte olduğu değerlendirilmektedir. Gelecek çalışmalar için meteorolojik değişkenlerin eklenmesi ve farklı baraj sistemlerinde testlerin genişletilmesi önerilmektedir.

Anahtar Kelimeler: Su seviyesi tahmini, zaman serisi analizi, derin öğrenme, ARIMA, SARIMAX, CNN-GRU, sinir mimari arama

Ocak 2026, 69 sayfa

ABSTRACT

MASTER THESIS

Dam Water Levels Prediction in Turkey Using Time Series and Artificial Intelligence Algorithms: A Study on Yusufeli and Deriner Dams

Ahmet Enes YEĞİN

Supervisor: Assist. Prof. Dr. Abdullah Ammar KARCIOĞLU

Purpose: In this study, short-term water level prediction was carried out for the Yusufeli and Deriner Dams, which are among the important hydroelectric structures in Türkiye. Since accurate forecasting plays a critical role in energy production planning, reducing flood risk, and optimizing water resource management in dam operation processes, both statistical time-series methods and deep learning-based approaches were comparatively evaluated.

Methodology: In the study, a two-stage approach was applied using real daily hydrological data. In the first stage, traditional time-series forecasting was performed with ARIMA, SARIMA, ARIMAX and SARIMAX models; the data were normalized, training-test splitting was performed, and model performances were measured through error metrics. In the second stage, deep learning-based CNN, LSTM, GRU and hybrid architectures were used. In addition, a Bayesian-based Neural Architecture Search method was applied to automatically perform architectural design and hyperparameter selection. Within this scope, a CGU (CNN-GRU Unified) model was developed to jointly learn temporal dependencies and structural patterns.

Findings: The results showed that statistical methods produced high performance values. While the ARIMA model achieved a 0.9932 R^2 score for the Yusufeli Dam, the SARIMAX model reached a 0.9905 R^2 score for the Deriner Dam. In the deep learning stage, hybrid models exhibited superior performance, and the CGU model achieved the highest R^2 score on the test data with an $R^2 = 0.9941$ value.

Conclusion: The findings revealed that artificial intelligence-based hybrid models provide a reliable, fast and applicable solution for water level prediction. The CGU model, in particular, is considered suitable for integration into real-time decision-support mechanisms. For future studies, the inclusion of meteorological variables and expanding the tests on different dam systems are recommended.

Keywords: Water level prediction, time series analysis, deep learning, ARIMA, SARIMAX, CNN-GRU, neural architecture search

January 2026, 69 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
TABLolar DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	ix
KISALTMALAR VE SİMGELER DİZİNİ	x
GİRİŞ	1
Hidroelektrik Enerji ve Baraj Yönetiminin Stratejik Önemi	1
Baraj Su Seviyesi Tahmininde Karşılaşılan Zorluklar	1
Yusufeli ve Deriner Barajlarının Stratejik Konumu	2
Zaman Serisi ve Derin Öğrenme Yaklaşımları	2
Çalışmanın Amacı ve Hedefleri.....	3
Çalışmanın Bilimsel ve Pratik Katkıları.....	4
KURAMSAL TEMELLER	5
Baraj Su Seviyesi Tahmini ve Literatür Taraması.....	5
Literatürdeki Derin Öğrenme Tabanlı Çalışmalar	5
Türkiye'deki Barajlar Üzerine Yapılan Çalışmalar	6
Hibrit Model Yaklaşımları.	7
Neural Architecture Search (NAS) Teknikleri.	7
Literatür Değerlendirmesi ve Araştırma Boşlukları.	8
MATERYAL VE METOT	9
Deriner Barajı Veri Seti.....	9
Yusufeli Barajı Veri Seti	11

Veri Ön İşleme Adımları	11
Eksik Verilerin Tamamlanması	11
Veri Normalizasyonu	12
Zaman Serisi Yapılandırması	12
Eğitim ve Test Verilerinin Ayrılması.....	12
Performans Değerlendirme Metrikleri	12
Zaman Serisi Modelleme Teknikleri	13
ARIMA Modeli	13
SARIMA Modeli	13
ARIMAX ve SARIMAX Modelleri.....	14
Derin Öğrenme Mimarileri	14
LSTM Modeli	14
BiLSTM Modeli	15
GRU Modeli	16
CNN Modeli	16
Hibrit Modeller	17
CNN-LSTM Hibrit Modeli	17
CNN-BiLSTM Hibrit Modeli	18
CNN-GRU Hibrit Modeli	18
Bayes Optimizasyon Tabanlı Neural Architecture Search.....	19
Neural Architecture Search Yaklaşımı.....	19
Bayes Optimizasyon Yöntemi	19
NAS ile Optimize Edilen Derin Öğrenme Modelleri.....	20
CNN-GRU Unified (CGU) Hibrit Modeli	22
Önerilen Model Mimarisi	22
Model Eğitim Süreci	24
ARAŞTIRMA BULGULARI	26
Zaman Serisi Analizine Dayalı ACF ve PACF Bulguları.....	26

Deriner Barajı ACF ve PACF Analizi	26
Yusufeli Barajı ACF ve PACF Analizi	27
Deriner Barajı Zaman Serisi Modelleme Sonuçları	28
SARIMA Modeli Sonuçları	29
SARIMAX Modeli Sonuçları	29
ARIMAX Modeli Sonuçları.....	30
ARIMA Modeli Sonuçları.....	30
Deriner Barajı Tahmin Örnekleri ve Hata Analizi	30
Yusufeli Barajı Zaman Serisi Modelleme Sonuçları	31
ARIMA Modeli Üstün Performansı	32
SARIMA Modeli Sonuçları	32
ARIMAX ve SARIMAX Modelleri Sonuçları	33
Yusufeli ve Deriner Barajları Karşılaştırmalı Analizi	33
Derin Öğrenme Modelleri Performans Değerlendirmesi	33
Temel Derin Öğrenme Modellerinin Performans Sonuçları	33
CNN Modeli Sonuçları	33
LSTM Modeli Sonuçları	34
BiLSTM Modeli Sonuçları	34
GRU Modeli Sonuçları	34
Hibrit Derin Öğrenme Modellerinin Performans Sonuçları	35
CNN-LSTM Hibrit Modeli Sonuçları	35
CNN-BiLSTM Hibrit Modeli Sonuçları	35
CNN-GRU Hibrit Modeli Sonuçları	35
Bayes Optimizasyon Tabanlı NAS Tekniği Sonuçları	35
NAS Optimizasyonlu CNN Modeli Sonuçları.....	36
NAS Optimizasyonlu LSTM Modeli Sonuçları	36
NAS Optimizasyonlu GRU Modeli Sonuçları.....	36
NAS Optimizasyonlu CNN-LSTM Hibrit Modeli Sonuçları	37

NAS Optimizasyonlu CNN-BiLSTM Hibrit Modeli Sonuçları	37
Önerilen CGU Hibrit Modeli Sonuçları	37
CGU Modelinin Mimari Özellikleri ve Optimizasyon Süreci	37
CGU Modelinin Eğitim Süreci ve Konverjans Davranışı	38
Kapsamlı Model Karşılaştırması ve Performans Analizi	39
Sonuçların Literatür ile Karşılaştırılması ve Değerlendirme	41
SONUÇLAR VE ÖNERİLER	44
KAYNAKLAR	49
ÖZGEÇMİŞ	54



TABLÖLAR DİZİNİ

Tablo 1. Deriner Barajı için yapılan çalışma sonuçları	28
Tablo 2. Mayıs 2023 dönemine ait örnek tahminler değerlendirilmesi	31
Tablo 3. Yusufeli Barajı için yapılan çalışma sonuçları	31
Tablo 4. Literatürdeki çalışmalarla karşılaştırma	42



ŞEKİLLER DİZİNİ

Şekil 1. Deriner Barajının veri seti içeriği	10
Şekil 2. Yusufeli Barajının veri seti içeriği	11
Şekil 3. LSTM'nin mimari gösterimi	15
Şekil 4. BiLSTM'nin mimari gösterimi	15
Şekil 5. GRU'nun mimari gösterimi.....	16
Şekil 6. CNN'in mimari gösterimi	17
Şekil 7. CNN-LSTM'nin mimari gösterimi	17
Şekil 8. CNN-BiLSTM'nin mimarisi ve LSTM'nin hücre yapısı	18
Şekil 9. CNN-GRU'nun mimari gösterimi.....	18
Şekil 10. Bayes Optimizasyonu tabanlı NAS'ın genel iş akışı	20
Şekil 11. Bayes Optimizasyon tabanlı NAS tekniğini kullanan CNN modelinin ayrıntılı blok diyagramı	21
Şekil 12. Bayes Optimizasyon tabanlı NAS tekniği kullanılarak GRU modelinin detaylı blok diyagramı	21
Şekil 13. Bayes Optimizasyon tabanlı NAS tekniğini kullanan LSTM modelinin ayrıntılı blok diyagramı..	22
Şekil 14. Bayes Optimizasyon tabanlı NAS tekniğini kullanan BiLSTM modelinin ayrıntılı blok diyagramı.....	22
Şekil 15. Önerilen CGU modelinin üst düzey mimari görselleştirmesi	24
Şekil 16. Bayes Optimizasyon Tabanlı NAS tekniği kullanılarak önerilen CGU modelinin blok diyagramı	24
Şekil 17. Deriner Barajı veri seti ACF grafiği	27
Şekil 18. Deriner Barajı veri seti PACF grafiği	27
Şekil 19. Yusufeli Barajı veri seti ACF grafiği	28
Şekil 20. Yusufeli Barajı veri seti ACF grafiği	28
Şekil 21. SARIMAX modelinin aylık tahmin sonuçları.....	30
Şekil 22. ARIMA modelinin aylık tahmin sonuçları	32

Şekil 23. Önerilen CGU modelinin kayıp grafiği	38
Şekil 24. Önerilen CGU modelinin test verisi tahmin sonuçları.....	39
Şekil 25. Deriner Barajı veri setinde DL modellerinin R^2 puanları	41



KISALTMALAR VE SİMGELER DİZİNİ

ARIMA : Autoregressive Integrated Moving Average (Otoregresif Bütünleşik Hareketli Ortalama)

SARIMA : Seasonal ARIMA (Mevsimsel ARIMA)

ARIMAX : ARIMA with Exogenous Variables (Dışsal Değişkenli ARIMA)

SARIMAX : Seasonal ARIMAX (Mevsimsel ARIMAX)

ACF : Autocorrelation Function (Otokorelasyon Fonksiyonu)

PACF : Partial Autocorrelation Function (Kısmi Otokorelasyon Fonksiyonu)

YZ : Yapay Zekâ

ML : Machine Learning (Makine Öğrenmesi)

DL : Deep Learning (Derin Öğrenme)

ANN : Artificial Neural Network (Yapay Sinir Ağı)

CNN : Convolutional Neural Network (Evrişimsel Sinir Ağı)

LSTM : Long Short-Term Memory (Uzun-Kısa Dönem Bellek)

BiLSTM : Bidirectional LSTM (Çift Yönlü LSTM)

GRU : Gated Recurrent Unit (Kapılı Tekrarlayan Birim)

CNN-LSTM : Convolutional Neural Network - Long Short-Term Memory

CNN-BiLSTM: CNN - Bidirectional LSTM

CNN-GRU : CNN - Gated Recurrent Unit

CGU : CNN-GRU Unified (Birleşik CNN-GRU Modeli)

NAS : Neural Architecture Search (Sinirsel Mimari Arama)

BO : Bayesian Optimization (Bayes Optimizasyon)

R² : Coefficient of Determination (Determinasyon Katsayısı)

RMSE : Root Mean Square Error (Kök Ortalama Kare Hatası)

MAE : Mean Absolute Error (Ortalama Mutlak Hata)

MSE : Mean Square Error (Ortalama Kare Hatası)

EÜAŞ : Elektrik Üretim Anonim Şirketi

HES : Hidroelektrik Santral

kWh : Kilowatt-hour (Kilowatt-saat)

m³/s : Metreküp/saniye (Debi birimi)

m³ : Metreküp (Hacim birimi)

CPU : Central Processing Unit (Merkezi İşlem Birimi)

GPU : Graphics Processing Unit (Grafik İşlem Birimi)

RAM : Random Access Memory (Rastgele Erişimli Bellek)

CUDA : Compute Unified Device Architecture



GİRİŞ

Hidroelektrik Enerji ve Baraj Yönetiminin Stratejik Önemi

Hidroelektrik enerji, düşük karbon emisyonu, yüksek verimlilik ve uzun ömürlü altyapı özellikleri nedeniyle yenilenebilir enerji kaynakları arasında kritik bir konuma sahiptir. Fosil yakıtlara dayalı enerji üretim sistemlerinin çevresel etkileri ve karbon salınımı sorunlarının küresel ölçekte artması, temiz enerji kaynaklarına yönelik arayışları hızlandırmıştır.

Türkiye, coğrafi yapısı ve zengin akarsu potansiyeli sayesinde hidroelektrik enerji üretimi açısından önemli avantajlara sahiptir. Ülkenin enerji stratejisinde hidroelektrik santraller (HES) merkezi bir rol oynamakta ve yenilenebilir enerji hedeflerinin gerçekleştirilmesinde kilit öneme sahip projeler olarak değerlendirilmektedir. Özellikle Doğu Anadolu Bölgesi'ndeki Çoruh Nehri havzası, yüksek akış hızı ve dağlık coğrafyası nedeniyle ülkenin en büyük hidroelektrik potansiyelini barındırmaktadır.

Barajların etkin yönetimi, hidroelektrik enerji üretiminin sürekliliğini sağlamanın yanı sıra taşkın kontrolü, tarımsal sulama ve su temini gibi çok boyutlu işlevlerin yerine getirilmesinde de belirleyici bir faktördür. Baraj rezervuarlarındaki su seviyelerinin doğru tahmin edilmesi, enerji üretim planlaması, taşkın erken uyarı sistemleri ve su kaynaklarının uzun vadeli yönetimi için hayati önem taşımaktadır.

Baraj Su Seviyesi Tahmininde Karşılaşılan Zorluklar

Baraj su seviyesi tahminleri, yağış miktarı, kar erimesi, buharlaşma oranı, rezervuara gelen su debisi ve enerji üretim talebi gibi çok sayıda değişkenden etkilenmektedir. Bu dinamiklerin doğru modellenmesi, yüksek hassasiyetli tahmin yöntemlerinin geliştirilmesini gerektirmektedir.

Su seviyesinin optimum düzeyin altına düşmesi, türbinlerin verimli çalışmasını engelleyerek enerji üretim kapasitesinde kayıplara yol açarken, rezervuarın aşırı dolması durumunda taşkın riski ortaya çıkmaktadır. Özellikle büyük ölçekli barajlarda, su seviyelerinde meydana gelen beklenmedik değişimler hem enerji üretiminin sürekliliğini tehdit edebilmekte hem de çevresel ve toplumsal riskler yaratabilmektedir.

Geleneksel olarak, baraj su seviyesi tahminleri fiziksel modellere dayalı hidrolojik simülasyonlar veya ampirik yöntemlerle gerçekleştirilmekteydi. Ancak bu yöntemler, karmaşık hidrolojik dinamikleri tam olarak yakalama konusunda sınırlılıklar içermekte ve yüksek

hesaplama maliyeti gerektirmektedir. Son yıllarda makine öğrenmesi ve DL gibi veri odaklı yaklaşımlar, hidrolojik tahmin süreçlerinde yeni fırsatlar sunmuştur. Bu yöntemler, geçmiş verilere dayalı öğrenme kapasiteleri sayesinde yüksek doğruluk oranlarına ulaşabilmekte ve operasyonel karar destek sistemlerine entegre edilebilmektedir.

Literatürde, Türkiye'deki büyük ölçekli barajlar üzerine gerçekleştirilen veri odaklı tahmin çalışmalarının sayısı sınırlıdır. Mevcut çalışmaların büyük kısmı kısa vadeli tahminlere odaklanmış veya belirli bir model türüyle sınırlı kalmıştır. Farklı model türlerinin karşılaştırmalı değerlendirilmesi, tahmin performansının optimize edilmesi ve operasyonel uygulamalara entegre edilebilecek en uygun yöntemin belirlenmesi açısından kritik önem taşımaktadır.

Yusufeli ve Deriner Barajlarının Stratejik Konumu

Çoruh Nehri, Türkiye'nin en yüksek akış hızına sahip akarsularından biri olup, Doğu Karadeniz Bölgesi'nin dağlık arazisinden geçerek Karadeniz'e ulaşmaktadır. Bu nehir üzerinde gerçekleştirilen hidroelektrik projeleri, Türkiye'nin enerji arz güvenliğine önemli katkılar sağlamaktadır. Çoruh Havzası'nda inşa edilen barajlar arasında Yusufeli ve Deriner barajları, hem yapısal büyüklükleri hem de enerji üretim kapasiteleri açısından öne çıkmaktadır.

Yusufeli Barajı, 275 metre baraj yüksekliği ile Türkiye'nin en yüksek barajı olup, yıllık yaklaşık 2 milyar Kilowatt-saat (kWh) elektrik enerjisi üretim kapasitesine sahiptir. Baraj, rezervuar hacmi ve yapısal özellikleri nedeniyle bölgedeki su kaynaklarının stratejik olarak depolanmasına olanak tanımakta ve mevsimsel dalgalanmaların yönetilmesinde önemli bir rol oynamaktadır.

Deriner Barajı ise 249 metre yüksekliği ile Türkiye'nin ikinci en yüksek barajıdır. Yıllık yaklaşık 2.5 milyar kWh enerji üretim kapasitesiyle Türkiye'nin hidroelektrik portföyünde kritik bir konuma sahiptir. Baraj, hem taşkın kontrolü hem de enerji üretimi açısından çok işlevli bir yapıdır ve bölgenin ekonomik kalkınmasına doğrudan katkı sağlamaktadır.

Her iki baraj da, yapısal özellikleri ve işletme süreçlerinin karmaşıklığı nedeniyle gelişmiş izleme ve yönetim sistemlerine ihtiyaç duymaktadır. Bu barajların su seviyelerinin gerçek zamanlı olarak izlenmesi, enerji üretiminin planlanması ve acil durum senaryolarına hazırlıklı olunması açısından hayati öneme sahiptir. Dolayısıyla, Yusufeli ve Deriner barajları üzerinde gerçekleştirilecek tahmin çalışmaları, yalnızca bilimsel bir katkı sunmakla kalmayıp operasyonel düzeyde de uygulanabilir sonuçlar üretme potansiyeline sahiptir.

Zaman Serisi ve Derin Öğrenme Yaklaşımları

Zaman serisi analizi, zamansal bağımlılıkları ve mevsimsel örüntüleri modellemek için kullanılan istatistiksel yöntemlerdir. ARIMA (Otoregresif Bütünleşik Hareketli Ortalama), SARIMA (Mevsimsel ARIMA), ARIMAX (Dışsal Değişkenli ARIMA) ve SARIMAX (Mevsimsel ARIMAX) gibi modeller, hidrolojik verilerdeki trend ve mevsimsel bileşenleri yakalamada etkili olmuştur. Bu modeller, özellikle uzun süreli veri setlerinde mevsimsel döngülerin net bir şekilde gözlemlenebildiği durumlarda yüksek tahmin performansı göstermektedir.

DL yaklaşımları ise karmaşık ve doğrusal olmayan ilişkileri yakalamada üstünlük sağlamaktadır. CNN (Evrişimsel Sinir Ağı), LSTM (Uzun-Kısa Dönem Bellek), BiLSTM (Çift Yönlü LSTM) ve GRU (Kapılı Tekrarlayan Birim) gibi sinir ağı mimarileri, zaman serisi verilerindeki hem yerel hem de küresel örüntüleri öğrenebilme kapasitesine sahiptir. Özellikle hibrit modeller, farklı mimarilerin güçlü yönlerini birleştirerek tahmin doğruluğunu artırma potansiyeli taşımaktadır.

Son yıllarda, BO (Bayesian Optimizasyon) tabanlı NAS (Sinirsel Mimari Arama) teknikleri, DL modellerinin hiper-parametrelerinin otomatik olarak optimize edilmesinde kullanılmaya başlanmıştır. Bu teknikler, manuel parametre ayarlama süreçlerinin getirdiği sınırlamaları aşarak model performansını sistematik bir şekilde iyileştirebilmektedir.

Çalışmanın Amacı ve Hedefleri

Bu çalışmanın temel amacı, Yusufeli ve Deriner barajlarının su seviyelerini yüksek doğrulukla tahmin edebilecek veri odaklı modellerin geliştirilmesi ve bu modellerin performanslarının kapsamlı bir şekilde değerlendirilmesidir. Çalışma kapsamında hem zaman serisi analizi temelli istatistiksel yöntemler hem de DL tabanlı modern YZ teknikleri kullanılarak çok yönlü bir modelleme yaklaşımı benimsenmiştir. Bu amaç doğrultusunda çalışmanın hedefleri aşağıda listelenmiştir:

- Geçmiş hidrolojik verilere dayalı olarak baraj su seviyelerindeki zamansal örüntüleri tespit etmek ve ARIMA, SARIMA, ARIMAX ve SARIMAX gibi zaman serisi modelleri kullanarak bu örüntüleri etkili bir şekilde modellemek,
- CNN, LSTM, BiLSTM ve GRU gibi DL mimarileri ile hibrit modeller tasarlayarak su seviyesi tahmin süreçlerinin doğruluğunu artırmak,
- BO tabanlı NAS tekniği uygulayarak modellerin hiper-parametrelerini optimal düzeyde ayarlamak,

- Geliştirilen modellerin performanslarını RMSE (Kök Ortalama Kare Hatası), MAE (Ortalama Mutlak Hata) ve R^2 (Determinasyon Katsayısı) gibi metrikler kullanarak karşılaştırmak ve operasyonel kullanıma en uygun model veya model kombinasyonlarını belirlemek,
- Elde edilen bulguların baraj işletme otoritelerine ve enerji planlama birimlerine uygulanabilir bir karar destek sistemi altyapısı sunmasını sağlamak,
- Hidroelektrik enerji üretiminin optimizasyonu, taşkın erken uyarı sistemleri ve su kaynaklarının uzun vadeli yönetimi için güvenilir tahmin araçları geliştirmek.

Çalışmanın Bilimsel ve Pratik Katkıları

Bu araştırma, Türkiye'deki büyük ölçekli hidroelektrik barajlar üzerine gerçekleştirilen kapsamlı tahmin çalışmalarından biridir. Özellikle Yusufeli Barajı üzerine veri odaklı tahmin çalışmaları literatürde oldukça sınırlı olup, bu baraj üzerinde ilk kez ileri düzey YZ teknikleri kullanılmıştır.

Bilimsel açıdan, çalışma zaman serisi modelleri ile DL mimarilerinin karşılaştırmalı analizini sunmakta ve her iki yaklaşımın güçlü yönlerini ortaya koymaktadır. Zaman serisi modelleri, özellikle mevsimsel bileşenlerin güçlü olduğu veri setlerinde yüksek performans gösterirken, DL modelleri karmaşık ve doğrusal olmayan ilişkileri yakalamada üstünlük sağlamıştır.

Özellikle BO tabanlı NAS tekniğinin baraj su seviyesi tahmini problemine uygulanması, bu alanda yenilikçi bir yaklaşım olarak öne çıkmaktadır. NAS tekniği, genellikle görüntü işleme ve doğal dil işleme alanlarında kullanılmakta olup, hidrolojik zaman serisi tahminlerinde uygulanması sınırlı düzeydedir.

Pratik açıdan, geliştirilen modeller baraj işletme otoriteleri için uygulanabilir bir karar destek çerçevesi sunmaktadır. Modeller gerçek zamanlı veri akışı ile entegre edilebilir yapıda tasarlanmış olup, enerji üretim planlaması, su depolama stratejileri ve taşkın erken uyarı sistemlerine doğrudan katkı sağlayabilmektedir. Ayrıca, çalışma kapsamında elde edilen sonuçlar, benzer hidrolojik koşullara sahip diğer barajlara da adapte edilebilir nitelikte olup, ulusal enerji politikalarına veri odaklı bir perspektif kazandırmaktadır.

Baraj Su Seviyesi Tahmini ve Literatür Taraması

Baraj su seviyesi tahminleri, hidroelektrik enerji üretiminin planlanması, taşkın kontrolü ve su kaynaklarının etkin yönetimi için kritik önem taşımaktadır. Geleneksel olarak fiziksel modellere dayalı hidrolojik simülasyonlar kullanılsa da bu yöntemler karmaşık dinamikleri tam olarak yakalama konusunda sınırlılıklar içermekte ve yüksek hesaplama maliyeti gerektirmektedir. Son yıllarda, veri odaklı makine öğrenmesi ve DL yaklaşımları hidrolojik tahmin süreçlerinde yeni fırsatlar sunmuştur.

Literatürdeki Derin Öğrenme Tabanlı Çalışmalar

DL mimarileri, baraj ve rezervuar su seviyesi tahminlerinde yüksek başarı oranlarına ulaşmıştır. Gömülü sistemler ve LSTM tabanlı akıllı baraj kontrol sistemi geliştirilmiş ve su seviyesi tahmininde etkili sonuçlar elde edilmiştir (Wyawahare ve Subhash, 2023). Üç Boğaz Barajı'nın Poyang Gölü su seviyesi üzerindeki etkisi makine öğrenmesi ile günlük ölçekte analiz edilmiş ve baraj operasyonlarının göl dinamiklerine etkisi başarıyla modellenmiştir (Huang vd., 2021).

Olasılıksal doğrusal olmayan model kullanılarak rezervuarlarda günlük su seviyesi tahmininde yüksek doğruluk sağlanmıştır (Das vd., 2016). Üç Boğaz Rezervuarı'nın mansap bölgesinde kısa vadeli su seviyesi tahmini için DL modelleri kullanılmış ve afet risk yönetimi açısından önemli bulgular sunulmuştur (Mao vd., 2024). Nehir su seviyesi tahminleri için yeni çift ayrıştırma DL yöntemleri geliştirilmiş ve geleneksel yöntemlere göre üstün performans elde edilmiştir (Ahmed vd., 2022).

Açık kaynaklı DL kütüphaneleri kullanılarak nehir su seviyesi tahmininde başarılı sonuçlar rapor edilmiştir (성호정 vd., 2018). Göl su seviyesi tahmin modelleri üzerine kapsamlı bir sistematik literatür taraması gerçekleştirilmiş ve farklı modelleme yaklaşımlarının güçlü ve zayıf yönleri ortaya konmuştur (Ozdemir vd., 2023).

İstatistiksel makine öğrenmesi modelleri ARIMA ile birleştirilerek Kızıl Nehir için su seviyesi tahmininde başarılı sonuçlar üretilmiştir (Nguyen, 2020). Çin'deki Üç Boğaz Barajı'nda hidroelektrik enerji üretimi makine öğrenmesi algoritmaları ile tahmin edilmiş ve yüksek doğruluk oranlarına ulaşılmıştır (Hanoon vd., 2023). Bulut tabanlı veri analitiği ve LSTM ağları kullanılarak verimli baraj su seviyesi yönetimi için gerçek zamanlı tahmin sistemi geliştirilmiştir (Raman ve Rathi, 2024).

Göl su seviyesi dalgalanmalarının tahmini için makine öğrenmesi algoritmaları üzerine sistematik bir derleme çalışması yapılmış ve farklı algoritmaların performansları karşılaştırılmıştır (Sannasi Chakravarthy vd., 2022). Sulama ve drenaj sistemlerinde su seviyesi tahmininde makine öğrenmesi tabanlı yöntemler başarıyla uygulanmıştır (Truong vd., 2021). Büyük ölçekli bir rezervuarda baraj temel gerilimi ve nehir vadisi daralmasını simüle etmek ve tahmin etmek için analitik ve makine öğrenmesi yaklaşımları entegre edilmiştir (Zhou vd., 2024).

Tonle Sap Gölü'nde ters akış ve su seviyesini tahmin etmek için makine öğrenmesi çerçevesi geliştirilmiştir (Morovati vd., 2021). Red River of the North için DL zaman serisi analizi uygulanmış ve su seviyesi dalgalanmaları yüksek doğrulukla tahmin edilmiştir (Atashi vd., 2022). KRS Rezervuarı için çok ufuklu su seviyesi tahmini gerçekleştiren DL modeli geliştirilmiş ve R^2 değeri 0.93 elde edilmiştir (Dayal vd., 2024).

Taehwa Nehir havzasında DNN ve LSTM tabanlı DL modelleri kullanılarak su seviyesi tahmininde yüksek doğruluk oranlarına ulaşılmıştır (Lee vd., 2021). Malezya'daki Durian Tunggal Nehri için çeşitli makine öğrenmesi algoritmaları kullanılarak su seviyesi tahmini gerçekleştirilmiş ve farklı algoritmaların performansları karşılaştırılmıştır (Ahmed vd., 2022). Günlük baraj su seviyeleri tahmininde makine öğrenmesi uygulamaları başarılı sonuçlar üretmiştir (Almubaidin vd., 2023).

Malezya'daki Muda Nehri için doğru su seviyesi tahmininde makine öğrenmesi algoritmaları keşfedilmiş ve optimal model seçimi yapılmıştır (Zakaria vd., 2023). Baraj sızıntısı üzerindeki hidrolik ve hidroklimatik etkiler DL modelleri uygulanarak analiz edilmiş ve sivil ve yapısal mekanizmalar modellenmiştir (Ishfaq vd., 2024).

Türkiye'deki Barajlar Üzerine Yapılan Çalışmalar

Türkiye'deki barajlar üzerine yapılan çalışmalar, ulusal su kaynakları yönetimi açısından önemli katkılar sunmuştur. Yalova Gökçe Barajı için ANN (yapay sinir ağları) kullanılarak su seviyesi tahmini gerçekleştirilmiş ve %94.14 doğruluk elde edilmiştir (Damla vd., 2020). İstanbul barajlarının su seviyeleri ARIMA modelleri kullanılarak tahmin edilmiş ve başarılı sonuçlar rapor edilmiştir (Sekban vd., 2022).

Göl su seviyesindeki değişim YZ yöntemleri ile tahmin edilmiş ve farklı modellerin performansları karşılaştırılmıştır (Buyukyildiz vd., 2014). Keban Barajı göl seviye değişimi ANFIS ve Destek Vektör Makineleri ile tahmin edilmiş ve her iki yöntem de yüksek doğruluk göstermiştir (Arslan vd., 2020). Günlük baraj su seviyeleri tahmininde Destek Vektör

Makineleri (SVM) modeli Uyarlamalı Nöro-Bulanık Çıkarım Sistemi (ANFIS) ile karşılaştırılmış ve her iki yöntemin de etkili sonuçlar ürettiği görülmüştür (Hipni vd., 2013).

Türkiye'deki Akmeşe Barajı üzerinde CMIP6 çoklu model topluluk tabanlı analizi yapılarak potansiyel iklim değişikliği etkilerinin sulama suyu talebi ve arzı üzerindeki etkileri SWAT ve CROPWAT modelleri kullanılarak değerlendirilmiştir (Yalcin, 2024). Ermenek Barajı için kayan pencere ve DL tabanlı çok model yaklaşımı ile rezervuar girişi tahmininin iyileştirilmesi sağlanmıştır (Feizi vd., 2022).

Seyhan Nehir Havzası'nda iklim değişikliğinin su kaynakları üzerindeki etkileri dinamik olarak ölçeklendirilmiş veriler kullanılarak hidrolojik simülasyonlarla değerlendirilmiştir (Fujihara vd., 2008). Dibis Barajı'nın su seviye tahmini ANN kullanılarak gerçekleştirilmiş ve başlangıç su seviyelerine dayalı tahminler başarıyla yapılmıştır (Salam ve Keskin, 2018).

Arazi kullanımı ve iklim faktörlerine dayalı olarak Vektör Otoregresyon, Rastgele Orman Regresyonu ve MLP-ANN modelleri kullanılarak baraj su seviyesi tahmini gerçekleştirilmiştir (Ouma vd., 2022). Melen Havzası'ndaki nehir akış hızları modellenerek ve tahmin edilerek su kaynakları planlamasına katkı sağlanmıştır (Akiner ve Akkoyunlu, 2012). Türkiye için Uzun Kısa Süreli Bellek (LSTM) tabanlı DL modeli kullanılarak hidroelektrik enerji üretim tahmini yapılmış ve yüksek performans gösterilmiştir (Bulut, 2021).

Hibrit Model Yaklaşımları

Hibrit modeller, farklı algoritmaların güçlü yönlerini birleştirerek tahmin performansını artırmaktadır. İnsan aktivitesi tanıma için yeni bir CNN-BiLSTM-GRU hibrit DL modeli geliştirilmiş ve üstün performans sergilenmiştir (Lalwani ve Ganeshan, 2024). Dinamik DL güdümlü mimari kullanılarak karmaşık Android kötü amaçlı yazılımlarla mücadele edilmiş ve güvenlik sistemleri geliştirilmiştir (Bibi vd., 2020).

Çevrimiçi veri akışı sınıflandırması için asenkron çift hatlı DL çerçevesi önerilmiş ve gerçek zamanlı işleme kapasitesi gösterilmiştir (Lara-Benítez vd., 2020). CNN-LSTM (Convolutional Neural Network - Long Short-Term Memory) modeline dayalı olarak sporcular için momentum tahmin algoritması geliştirilmiş ve performans analizi gerçekleştirilmiştir (Xu vd., 2024). CNN-BiLSTM (CNN - Bidirectional LSTM) ve Random Forest kullanılarak çok değişkenli sıcaklık tahmin modeli geliştirilmiş ve yüksek doğruluk elde edilmiştir (Bai vd., 2025).

Sinirsel Mimari Arama (NAS) Teknikleri

NAS tekniği alanındaki son gelişmeler kapsamlı olarak incelenmiş ve evrimsel algoritmalar, pekiştirmeli öğrenme gibi yaklaşımlar kategorize edilmiştir (Baymurzina vd.,

2022). Hesaplama açısından verimli NAS yöntemleri gözden geçirilmiş ve vekil tabanlı ve proxy destekli yaklaşımlar sınıflandırılmıştır (Liu vd., 2022).

Takviyeli öğrenme tabanlı NAS yaklaşımları, evrimsel sinir ağı tasarımını otomatikleştirmedeki etkinlikleri vurgulanarak gözden geçirilmiştir (Jaafr vd., 2019). Değişken mimari kodlama stratejisini takviyeli evrimsel algoritma ile entegre eden ölçeklenebilir bir NAS yöntemi önerilmiş ve hesaplama maliyeti azaltılırken arama verimliliği artırılmıştır (Zhang vd., 2021).

Sinir mimarilerini ve karma hassasiyet kuantalamayı birlikte optimize eden bir NAS çerçevesi, hem doğruluğu hem de donanım enerji tüketimini hedefleyerek geliştirilmiştir (Gong vd., 2019). NAS'ın temel prensipleri ve farklı yaklaşımları detaylı olarak açıklanmıştır (Karagiannakos, 2022).

Gömme füzyonu ile derin sinir ağı kullanan Çince Adlandırılmış Varlık Tanıma yöntemi önerilmiş ve bağlamsal, kelime, bigram ve sözlüksel bilgiler evrimsel ve öz-dikkat mekanizmaları kullanılarak entegre edilmiştir (Long vd., 2023). Gaz ve koku karışımlarının sınıflandırılması için BO tabanlı NAS (Neural Architecture Search) yöntemi geliştirilmiştir (Gupta vd., 2024).

Çok amaçlı evrimsel NAS için Pareto-tabanlı sıralama sınıflandırıcısı geliştirilmiş ve optimal mimari tasarım süreçleri iyileştirilmiştir (Ma vd., 2023). NAS sistemi için tek-alanlı geliştirilmiş öngörücü önerilmiş ve görünmeyen hedef uzaylarda yüksek genelleme sağlanmıştır (Ma vd., 2024).

Literatür Değerlendirmesi ve Araştırma Boşlukları

Literatürde, baraj su seviyesi tahminlerine yönelik çalışmaların büyük kısmı belirli bir model türüyle sınırlı kalmış veya kısa vadeli tahminlere odaklanmıştır. Farklı model türlerinin karşılaştırmalı değerlendirilmesi ve hibrit yaklaşımların geliştirilmesi, tahmin performansının optimize edilmesi açısından kritik önem taşımaktadır.

Özellikle Türkiye'deki büyük ölçekli barajlar üzerine gerçekleştirilen çalışmalar sınırlı sayıda olup, Yusufeli ve Deriner gibi stratejik barajlar üzerinde kapsamlı tahmin modelleme çalışmalarına ihtiyaç duyulmaktadır. Mevcut çalışmalarda, zaman serisi modelleri ile DL mimarilerinin sistematik karşılaştırması nadiren yapılmış ve her iki yaklaşımın güçlü yönlerinin birleştirildiği hibrit modelleme stratejileri yeterince araştırılmamıştır.

BO tabanlı NAS tekniğinin hidrolojik tahminlerde uygulanması literatürde oldukça sınırlıdır. Bu tekniğin baraj su seviyesi tahmini problemine uygulanması, otomatik hiper-parametre optimizasyonu ve mimari tasarım açısından yenilikçi katkılar sunma potansiyeli

taşımaktadır. Ayrıca, CNN-GRU (CNN - Gated Recurrent Unit) gibi hibrit mimarilerin sistematik olarak optimize edilmesi ve performanslarının kapsamlı bir şekilde değerlendirilmesi, operasyonel baraj yönetim sistemlerine entegre edilebilir güvenilir tahmin araçlarının geliştirilmesi için önemlidir.

Bu çalışmada, literatürdeki bu boşlukları gidermek amacıyla Yusufeli ve Deriner barajları için hem ARIMA, SARIMA, ARIMAX ve SARIMAX gibi zaman serisi modelleri hem de CNN, LSTM, BiLSTM, GRU ve hibrit mimariler kullanılarak kapsamlı bir karşılaştırmalı analiz gerçekleştirilmiştir. Özellikle BO tabanlı NAS tekniği ile optimize edilmiş CGU (CNN-GRU Unified) modeli önerilmiş ve bu yaklaşımın baraj su seviyesi tahminindeki etkinliği deneysel olarak gösterilmiştir.



MATERYAL VE YÖNTEM

Bu çalışmada, Deriner Barajı ve Yusufeli Barajı su seviyesi tahminleri için kapsamlı bir metodoloji geliştirilmiştir. Çalışma kapsamında veri setlerinin oluşturulması, ön işleme adımları, modelleme teknikleri ve performans değerlendirme yaklaşımları sistematik olarak sunulmaktadır.

Deriner Barajı Veri Seti

Deriner Barajı verileri, Türkiye Elektrik Üretim Anonim Şirketi ve T.C. Enerji ve Tabii Kaynaklar Bakanlığı'nın resmi kayıtlarından temin edilmiştir. Deriner Barajı, Artvin ili sınırları içerisinde Çoruh Nehri üzerinde konumlanmakta olup 249 metre yüksekliğiyle Türkiye'nin ikinci en yüksek barajı konumundadır. Barajın hidroelektrik kurulu gücü 670 MW olup yıllık yaklaşık 2.5 milyar kWh enerji üretim kapasitesine sahiptir. Şekil 1'de Deriner barajına ait verilerin grafiksel gösterimi verilmiştir.

	tarih	gelen_su(m ³)	debi(m ³ /s)	goldeki_su_miktari(m ³)	enesjiye_sarf_edilen_su(m ³)	depo_edilen_su(m ³)	gol_kotu(m)
0	01.01.2014	3331718.0	38.56	1.208548e+09	4331088.0	-999370.0	358.50
1	02.01.2014	2260482.0	26.16	1.204550e+09	5258592.0	-2998110.0	358.30
2	03.01.2014	3254942.0	37.67	1.201153e+09	6652800.0	-3397858.0	358.13
3	04.01.2014	1561830.0	18.08	1.198154e+09	4559940.0	-2998110.0	357.98
4	05.01.2014	2192086.0	25.37	1.195556e+09	4790448.0	-2598362.0	357.85
...	...	...	...	...	...	...	...
3444	07.06.2023	18059114.0	209.02	1.783050e+09	15016094.0	3043020.0	384.65
3445	08.06.2023	16560029.0	191.67	1.790150e+09	9459649.0	7100380.0	384.93
3446	09.06.2023	16480540.0	190.75	1.797250e+09	9380160.0	7100380.0	385.21
3447	10.06.2023	19841552.0	229.65	1.809169e+09	7923057.0	11918495.0	385.68
3448	11.06.2023	12727030.0	147.30	1.814748e+09	7148160.0	5578870.0	385.90

Şekil 1. Deriner Barajının veri seti içeriği.

Veri seti, 2014 yılından 2023 yılına kadar kesintisiz olarak kaydedilen on yıllık hidrolojik ölçümleri kapsamaktadır. Bu süreçte toplam 3,449 günlük veri kaydedilmiştir. Veri seti altı temel hidrolojik ve operasyonel parametreden oluşmaktadır: gelen su miktarı, debi, göldeki su miktarı, enerji üretimi için kullanılan su miktarı, depo edilen su miktarı ve göl kotu. Bu parametreler günlük bazda ölçülmüş olup barajın hidrolojik ve operasyonel özelliklerini yansıtmaktadır.

Veri kalite kontrolü sürecinde, toplam gözlem sayısının yalnızca üç tanesinde eksik değer tespit edilmiştir. Bu durum, veri setinin yüksek güvenilirlik ve bütünlüğünü göstermektedir.

Yusufeli Barajı Veri Seti

Yusufeli Barajı, 275 metre yüksekliğiyle Türkiye'nin en yüksek barajı konumundadır. Baraj, 2023 yılında işletmeye alınmış olup 558 MW kurulu güç kapasitesine sahiptir. Yıllık enerji üretim hedefi yaklaşık 2 milyar kWh olarak planlanmıştır. Şekil 2'de Yusufeli barajına ait verilerin grafiksel gösterimi verilmiştir.

	tarih	gelen_su(m ³)	debi(m ³ /s)	goldeki_su_miktari(m ³)	enesjiye_sarf_edilen_su(m ³)	depo_edilen_su(m ³)	gol_kotu(m)	enerjiye_cvrilebilecek_su(m ³)
0	2023-11-17	936031	10.83	1849152000	323031	613000	704.17	843152000
1	2023-11-18	5493927	63.59	1847313000	7332927	-1839000	704.11	841313000
2	2023-11-19	4048391	46.86	1843327000	8034391	-3986000	703.98	837327000
3	2023-11-20	6047016	69.99	1845780000	3594016	2453000	704.06	839780000
4	2023-11-21	3930930	45.50	1841794000	7916930	-3986000	703.93	835794000
...	...	...	...	...	...	...	...	...
314	2024-09-26	4172257	48.29	1332137000	8296257	-4124000	685.21	341037000
315	2024-09-27	8033572	92.98	1331409000	8761572	-728000	685.18	340309000
316	2024-09-28	6877528	79.60	1328256000	10030528	-3153000	685.05	337156000
317	2024-09-29	7815957	90.46	1327770000	8301957	-486000	685.03	336670000
318	2024-09-30	8792207	101.76	1328256000	8306207	486000	685.05	337156000

Şekil 2. Yusufeli Barajının veri seti içeriği.

Yusufeli Barajı veri seti, 319 gün boyunca kaydedilen hidrolojik ölçümleri içermektedir. Veri seti, Deriner Barajı'ndaki altı parametreye ilaveten yedinci bir parametre daha içermektedir. Bu parametre "enerjiye çevrilebilecek su miktarı" olarak tanımlanmakta olup mevcut rezervuar hacminin elektrik enerjisine dönüştürülebilir potansiyelini ifade etmektedir. Yusufeli Barajı veri setinde eksik veri bulunmamaktadır.

Veri Ön İşleme Adımları

Eksik Verilerin Tamamlanması

Deriner Barajı veri setinde tespit edilen üç eksik kayıt, zamansal süreklilik prensibi gözetilerek doğrusal enterpolasyon yöntemiyle tamamlanmıştır. Bu yöntemde, eksik değerler öncesinde ve sonrasında bulunan geçerli ölçümler arasında lineer bir geçiş varsayılmaktadır. Zamansal süreklilik korunarak bilgi sızıntısı önlenmiştir.

Her iki baraj için aykırı değer incelemeleri gerçekleştirilmiştir. Çeyrekler arası açıklık tekniği kullanılarak belirlenen sınırların dışında kalan ölçümler detaylı analiz edilmiştir. Tespit edilen uç değerlerin meteorolojik ekstrem durumlar veya operasyonel müdahalelerle açıklanabildiği görülmüştür. Bu nedenle hiçbir kayıt veri setinden çıkarılmamıştır.

Veri Normalizasyonu

DL modellerinin eğitim sürecinde kararlı ve verimli öğrenme sağlanması amacıyla, tüm sayısal değişkenlere Min-Max normalizasyonu uygulanmıştır. Bu dönüşüm ile veriler sıfır ile bir aralığına ölçeklendirilmiştir. Normalizasyon parametreleri yalnızca eğitim veri setinden hesaplanmış ve aynı parametreler test veri setine de uygulanmıştır. Bu prosedür, test verisinden bilgi sızıntısının önlenmesi açısından kritik önem taşımaktadır. Tarih bilgisi kategorik olduğundan normalizasyon işlemine dahil edilmemiştir.

Zaman Serisi Yapılandırması

Zaman serisi verileri, gözetimli öğrenme formatına dönüştürülmüştür. Sabit genişlikte kayan pencere mekanizması benimsenmiştir. Pencere genişliği 30 gün olarak belirlenmiştir. Bu yaklaşımda, ardışık 30 günlük veriler kullanılarak bir sonraki günün su seviyesi tahmin edilmektedir. Pencere her adımda bir gün ileri kaydırılarak veri setinin tamamı için giriş-çıkış çiftleri oluşturulmuştur.

Bu süreç sonunda Deriner Barajı için 3419 adet, Yusufeli Barajı için 289 adet özellik-hedef çifti elde edilmiştir. Her giriş vektörü 30 günlük geçmiş bilgiyi içermekte, karşılık gelen hedef değer ise takip eden günün rezervuar su miktarını temsil etmektedir.

Eğitim ve Test Verilerinin Ayrılması

Zaman serilerinin doğası gereği kronolojik bölünme stratejisi uygulanmıştır. Veri setinin ilk %80'lik kısmı eğitim, son %20'lik kısmı test amacıyla kullanılmıştır. Bu yaklaşım, modellerin geçmiş verilerle eğitilip gelecek verileri üzerinde test edilmesini sağlamaktadır.

Deriner Barajı için ilk 2735 çift eğitim setini, son 684 çift test setini oluşturmaktadır. Yusufeli Barajı için ilk 231 çift eğitimde, son 58 çift testte kullanılmıştır. Eğitim setinin %20'si doğrulama amacıyla ayrılmış ve erken durdurma mekanizmasında değerlendirilmiştir.

Performans Değerlendirme Metrikleri

Tahmin modellerinin performansını değerlendirmek için yaygın olarak kabul görmüş istatistiksel metrikler kullanılır.

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının karekökü alınarak hesaplanır. RMSE, büyük hataları küçük hatalara göre daha fazla cezalandırdığından aykırı tahminlere karşı duyarlıdır. Düşük RMSE değerleri, modelin tahmin doğruluğunun yüksek olduğunu gösterir.

MAE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalaması olarak tanımlanır. RMSE'ye göre aykırı değerlere daha az duyarlıdır ve hata büyüklüklerinin genel dağılımını dengeli bir şekilde yansıtır.

R^2 , modelin varyansın ne kadarını açıklayabildiğini gösteren bir ölçüttür. 0 ile 1 arasında değer alan R^2 , bire yaklaştıkça modelin açıklama gücünün arttığını gösterir. R^2 değerinin yüksek olması, modelin gerçek değerlerdeki değişkenliği başarılı bir şekilde yakalayabildiğini ifade eder.

MSE (Ortalama Kare Hatası), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalaması olarak hesaplanır. MSE, modelin genel tahmin hatasını nicel olarak ifade eder ve optimizasyon süreçlerinde kayıp fonksiyonu olarak kullanılır.

Zaman Serisi Modelleme Teknikleri

ARIMA Modeli

Otoregresif Bütünleşik Hareketli Ortalama modeli, zaman serisi tahminlerinde yaygın olarak kullanılan istatistiksel bir tekniktir. Model üç temel parametre ile tanımlanmaktadır. İlk parametre, hedef değişkenin geçmiş değerlerinden kaç adım geriye gidilerek kullanıldığını ifade etmektedir. İkinci parametre, zaman serisini durağan hale getirmek için uygulanan fark alma işleminin sayısını göstermektedir. Üçüncü parametre ise geçmiş tahmin hatalarından kaç adım geriye gidilerek yararlanıldığını belirtmektedir.

Model parametrelerinin belirlenmesinde sistematik bir süreç izlenmiştir. İlk olarak Augmented Dickey-Fuller durağanlık testi uygulanarak serilerin durağanlık özellikleri incelenmiştir. Ardından otokorelasyon ve kısmi otokorelasyon grafikleri analiz edilmiştir. Son aşamada farklı parametre kombinasyonları denenmiş ve Akaike ile Bayes bilgi kriterleri karşılaştırılmıştır.

Deriner Barajı için bir gecikmeli otoregresif terim, birinci dereceden fark alma ve üç gecikmeli hareketli ortalama terimi içeren model en iyi performansı sergilemiştir. Yusufeli Barajı için ise iki gecikmeli otoregresif bileşen, birinci dereceden fark alma ve iki gecikmeli hareketli ortalama bileşeni kullanılmıştır.

SARIMA Modeli

Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama modeli, ARIMA yaklaşımının mevsimsel bileşenleri içerecek şekilde genişletilmiş versiyonudur. Model, standart parametrelere ilaveten mevsimsel parametreler de içermektedir. Bu parametreler mevsimsel

otoregresif terim derecesini, mevsimsel fark alma derecesini, mevsimsel hareketli ortalama terim derecesini ve mevsimsel periyodu tanımlamaktadır.

Hidrolojik süreçlerde yağış rejimi, kar erimesi ve buharlaşma oranları belirgin mevsimsel örüntüler sergilemektedir. Deriner Barajı için on yıllık veri seti mevsimsel döngülerin net şekilde gözlemlenmesine imkân tanımıştır. Altı aylık mevsimsel periyot kullanılarak model optimize edilmiştir. Yusufeli Barajı için on iki aylık mevsimsel periyot tercih edilmiştir.

ARIMAX ve SARIMAX Modelleri

Dışsal Değişkenli ARIMA modeli, ARIMA yaklaşımına ek açıklayıcı değişkenlerin entegre edilmesiyle oluşturulmaktadır. Bu yaklaşım, hedef değişkenin sadece kendi geçmiş değerleriyle değil, diğer hidrolojik parametrelerle de açıklanmasına imkan tanımaktadır.

Çalışmada, gelen su miktarı, göl kotu ve enerji üretimi için kullanılan su miktarı dışsal değişkenler olarak seçilmiştir. Bu değişkenlerin seçiminde, hedef değişken ile olan korelasyon katsayıları hesaplanmış ve istatistiksel anlamlılıkları test edilmiştir. Ayrıca, değişkenler arasında çoklu doğrusal bağlantı kontrolü yapılmış ve varyans şişirme faktörü değerleri incelenmiştir.

Mevsimsel Dışsal Değişkenli ARIMA modeli ise hem mevsimsel bileşenleri hem de dışsal değişkenleri kapsayan ileri düzey bir yaklaşımdır. Her iki baraj için ARIMAX ve SARIMAX modelleri üç dışsal değişken kullanılarak eğitilmiş ve test edilmiştir.


Derin Öğrenme Mimarileri

LSTM Modeli

Uzun Kısa Süreli Bellek sinir ağı, tekrarlayan sinir ağlarının uzun vadeli bağımlılıkları öğrenme konusundaki sınırlılıklarını aşmak üzere geliştirilmiştir. Mimari, unutma kapısı, giriş kapısı ve çıkış kapısı olmak üzere üç temel kapı mekanizması içermektedir. Bu kapılar, hangi bilgilerin hücre durumunda tutulacağını, hangi yeni bilgilerin ekleneceğini ve hangi bilgilerin çıktı olarak kullanılacağını kontrol etmektedir.

Çalışmada kullanılan LSTM modeli iki katmanlı yapıya sahiptir. İlk katman 64 birim içermekte ve her zaman adımı için çıktı üretmektedir. Aşırı öğrenmenin önlenmesi için dropout mekanizması uygulanmaktadır. İkinci LSTM katmanı 32 birim içermekte ve yalnızca son zaman adımının çıktısını vermektedir. Bu katman sonrasında da dropout uygulanmaktadır. Son olarak tek nöronlu tam bağlı katman, bir gün sonrasının rezervuar su miktarını tahmin etmektedir.

Model, MSE kayıp fonksiyonu kullanılarak Adam optimizasyon algoritması ile eğitilmiştir. Öğrenme hızı 0.001, grup (batch) boyutu 32 olarak ayarlanmıştır. Maksimum yüz tekrar (epoch) eğitim gerçekleştirilmiş ancak erken durdurma mekanizması ile doğrulama kaybında on beş tekrar boyunca iyileşme olmadığında eğitim sonlandırılmıştır. LSTM modelinin mimarisi Şekil 3'te gösterilmiştir.




Şekil 3. LSTM modelinin mimari gösterimi.

BiLSTM Modeli

İki Yönlü Uzun Kısa Süreli Bellek yapısı, zaman serisini hem ileri hem geri yönde işleyerek zenginleştirilmiş bağlamsal temsiller oluşturmaktadır. İleri yönlü katman geçmiş bilgileri, geri yönlü katman ise gelecek bilgileri öğrenmekte ve her iki yönden gelen gizli durumlar birleştirilmektedir.

BiLSTM modeli iki çift yönlü katman içermektedir. İlk katman 64 birim kullanmakta ve iki yönde toplam 128 çıktı üretmektedir. Düzenleyici mekanizma uygulanmaktadır. İkinci katman 32 birim kullanmakta ve toplam 64 çıktı vermektedir. Yine düzenleme yapılmaktadır. Son katman tek nöron içermekte ve hedef değeri tahmin etmektedir. LSTM modelinin mimarisi Şekil 4'te gösterilmiştir.




Şekil 4. BiLSTM modelinin mimari gösterimi.

GRU Modeli

GRU, LSTM mimarisinin basitleştirilmiş versiyonu olup daha az parametre içermektedir. Model iki kapı mekanizmasıyla çalışmaktadır: güncelleme kapısı ve sıfırlama kapısı. Bu kapılar bilgi akışını yönetmektedir.


İki katmanlı yapı benimsenmiştir. İlk katman 64 birim içermekte ve tüm adımlarda çıktı üretmektedir. Düzenleyici eklenmiştir. İkinci katman 32 birim içermektedir. Yine düzenleme uygulanmıştır. Çıkış katmanı tek birimlidir. GRU modelinin mimarisi Şekil 5'te gösterilmektedir.



Şekil 5. GRU modelinin mimari gösterimi.

CNN Modeli

CNN, yerel zamansal özellikleri çıkarabilme kapasitesine sahiptir. Filtreler zaman ekseninde kaydırılarak önemli örüntüler tespit edilmektedir. İki evrişim katmanı kullanılmıştır. İlk katman 64 filtre içermekte ve üç günlük pencerelerle tarama yapmaktadır. Ardından havuzlama ile boyut indirgenmektedir. İkinci katman 32 filtre içermektedir. Yine havuzlama yapılmaktadır. Çıktı düzleştirildikten sonra 50 nöronlu ara katman eklenmektedir. Düzenleyici mekanizma uygulanmaktadır. Son katman tek çıktıdır ve regresyon işlemi için doğrusal (linear) aktivasyon fonksiyonuna sahiptir. Modelin ürettiği normalize çıktılar, 'Ters Min-Max Dönüşümü' ile gerçek fiziksel birimine (m^3) dönüştürülmüş ve R^2 performans skoru bu gerçek değerler üzerinden hesaplanmıştır. CNN'in mimarisi Şekil 6'da gösterilmiştir.




Şekil 6. CNN modelin mimari gösterimi.

Hibrit Modeller

Hibrit DL mimarileri, farklı ağ türlerinin tamamlayıcı özelliklerini bir araya getirerek tahmin kapasitesini geliştirme potansiyeline sahiptir. Bu yaklaşımın temel mantığı, evrimsel katmanların yerel örüntü tespiti yeteneği ile tekrarlayan katmanların zamansal dinamik modelleme gücünün eşzamanlı kullanımına dayanmaktadır. Böylece model, hem kısa dönemli değişimleri hem de uzun vadeli eğilimleri aynı anda analiz edebilmektedir.

CNN-LSTM Hibrit Modeli


CNN-LSTM yapısı, uzaysal özellik çıkarımı ile zamansal bağımlılık modellemesini ardışık bir şekilde gerçekleştirmektedir. İlk aşamada evrimsel filtreler, zaman serisindeki kısa periyotlu değişimleri ve ani dalgalanmaları tespit etmektedir. Bu işlem sonucunda elde edilen soyut temsiller, ikinci aşamada tekrarlayan katmanlara iletilmekte ve kronolojik sıra bilgisi korunarak işlenmektedir. LSTM katmanı, bu yüksek seviyeli özelliklerdeki uzun dönemli kalıpları öğrenerek gelecek değerleri tahmin etmektedir. CNN-LSTM modelinin mimarisi Şekil 7’de gösterilmiştir.



Şekil 7. CNN-LSTM modelinin mimari gösterimi.

CNN-BiLSTM Hibrit Modeli


CNN-BiLSTM mimarisi, çift yönlü bilgi işleme kapasitesi sunarak zengin bağlamsal temsiller oluşturmaktadır. Evrişim bloğundan gelen çıktılar, hem ileri hem geri yönde işlenerek her zaman adımı için geçmiş ve gelecek bilgilerinin birleştirilmesi sağlanmaktadır. Bu yapı sayesinde, belirli bir andaki su seviyesi tahmininde sadece önceki değerler değil, sonraki dönemlerdeki olası eğilimler de göz önünde bulundurulmaktadır. Çift yönlü işleme mekanizması, özellikle mevsimsel döngülerin belirgin olduğu hidrolojik verilerde tahmin doğruluğunu artırmaktadır. CNN-BiLSTM modelinin mimarisi Şekil 8’de gösterilmiştir.



Şekil 8. CNN-BiLSTM'nin mimarisi ve LSTM'nin hücre yapısı.

CNN-GRU Hibrit Modeli

CNN-GRU kombinasyonu, hesaplama verimliliği ile yüksek tahmin performansını dengeli şekilde sunmaktadır. Evrişimsel katmanlar yine yerel özellikleri çıkarmakta, ancak zamansal modelleme için daha az parametre içeren GRU yapısı tercih edilmektedir. GRU'nun basitleştirilmiş kapı mekanizması, eğitim süresini kısaltmakta ve bellek gereksinimini azaltmaktadır. Buna rağmen model, LSTM'e yakın doğruluk seviyelerinde tahminler üretebilmektedir. Bu özellik, hibrit yapıyı özellikle gerçek zamanlı uygulamalar için uygun hale getirmektedir. CNN-GRU modelinin mimarisi Şekil 9’da gösterilmiştir.



Şekil 9. CNN-GRU’nun mimari gösterimi.

Bayes Optimizasyon Tabanlı NAS

NAS Yaklaşımı

Geleneksel yaklaşımlarda, DL modellerinin mimari tasarımı araştırmacıların deneyimlerine ve sezgilerine dayalı olarak manuel olarak gerçekleştirilmektedir. Katman sayıları, filtre boyutları, aktivasyon fonksiyonları ve nöron sayıları gibi hiper-parametreler genellikle deneme yanılma süreciyle belirlenmektedir. Ancak bu süreç zaman alıcıdır ve optimal olmayan sonuçlara yol açabilmektedir.

NAS tekniği, bu süreci otomatikleştirerek daha sistematik, veri odaklı ve tekrarlanabilir bir çözüm sunmaktadır. Özellikle büyük veri setleri üzerinde çalışılırken, hiper-parametre alanında rastgele veya sezgisel tercihler yerine optimize edilmiş model mimarilerinin kullanılması, model performansını doğrudan artırmaktadır. NAS, farklı mimari kombinasyonlarını sistematik olarak değerlendirerek daha doğru ve genelleştirilebilir model yapılarına ulaşılmasını mümkün kılmaktadır.

Bayes Optimizasyon Yöntemi

Çalışmada, NAS stratejilerinden BO yöntemi tercih edilmiştir. Bu tercihin temel nedeni, diğer yaygın yöntemlere kıyasla daha az kaynakla daha yüksek doğruluk potansiyeline sahip olmasıdır.


Izgara Arama (Grid Search) yöntemi, belirtilen parametre aralıklarındaki tüm olası kombinasyonları test etmektedir. Bu yöntem küçük arama alanlarında etkili olabilmekte ancak büyük ve karmaşık mimari alanlarda ciddi hesaplama yükü oluşturmaktadır. Rastgele Arama (Random Search) yöntemi ise hesaplama yükünü azaltmak için rastgele örneklemeler üzerinde çalışmaktadır, ancak yönsüz ve sistematik olmayan arama süreci nedeniyle genellikle düşük performanslı sonuçlarla sınırlı kalmaktadır. Bu iki arama algoritmasının ortak dezavantajı, katman arama sürecinde yüksek zaman ve kaynak tüketimi ile sınırlı keşif yeteneği sunmalarıdır.

BO Optimizasyon, bu sınırlamaların üstesinden gelmek için tahmine dayalı adaptif bir arama stratejisidir. Bu yöntemde, her deneme sonucunda mimarilerin performansı için bir vekil model oluşturulmaktadır. Bu model, arama uzayındaki diğer mimarilerin tahmini performansını öngörmekte ve bu tahminlere göre test edilecek bir sonraki mimariyi seçmektedir. Böylece kaynaklar, yüksek başarı potansiyeli taşıyan yapıların keşfine yönlendirilmektedir.


Süreç boyunca, bir yandan yeni yapıların keşfi, diğer yandan başarılı yapıların iyileştirilmesi arasında istatistiksel olarak dengeli bir arama mekanizması oluşturulmaktadır.

BO, bu süreçte mimarileri doğrudan test etmek zorunda kalmadan bir vekil model aracılığıyla hangi yapıların yüksek performans gösterebileceğini öngörmüş ve mimari arama sürecini hızlandırmıştır. Bu sayede daha az deneme ile yüksek doğruluklu mimarilere ulaşılmıştır. Ayrıca, bu teknik yeni yapıların keşfi ile başarılı yapıların iyileştirilmesi arasında denge kurarak mimari aramanın verimliliğini artırmıştır.

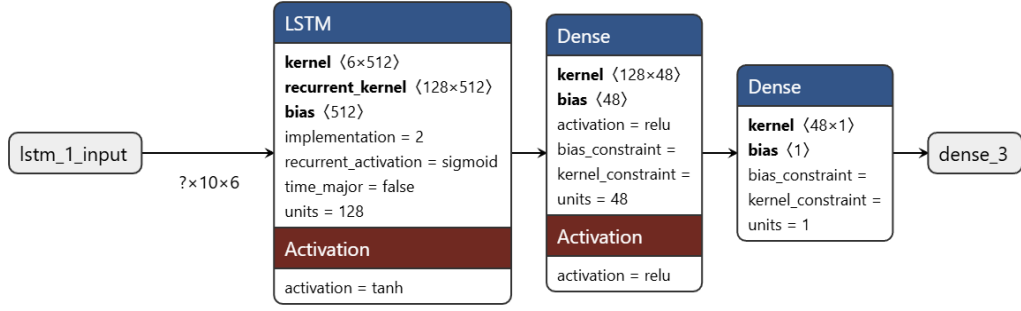
Model karşılaştırma sonuçları, NAS tekniğinin özellikle zaman serisi tahmini gibi problemlerde ne kadar etkili olduğunu ortaya koymuştur. CNN ve GRU modelleri, yüksek R^2 skorlarının yanı sıra düşük hesaplama maliyeti, basit mimari yapı ve hızlı eğitim süresi gibi pratik avantajlarıyla da öne çıkmaktadır. Çekirdek boyutları, aktivasyon fonksiyonları, bırakma oranları ve yoğun katman birimlerini içeren mimari yapılandırmaları Bayes Optimizasyon tabanlı NAS tekniği kullanılarak optimize edilen CNN, GRU, LSTM ve BiLSTM modellerinin sırasıyla ayrıntılı blok diyagramları Şekil 11, Şekil 12, Şekil 13 ve Şekil 14'te gösterilmiştir.



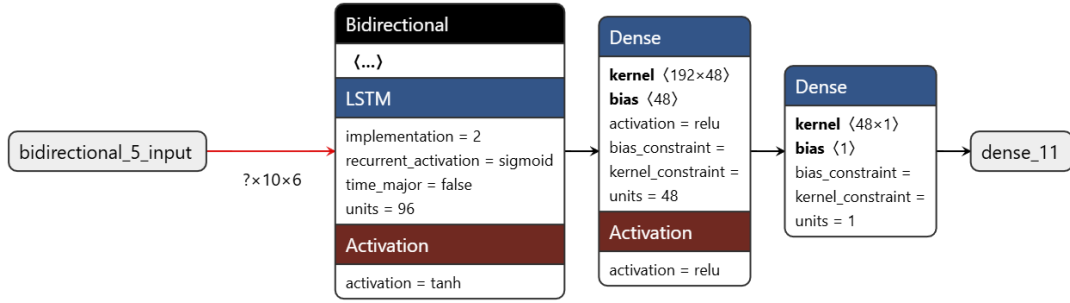
Şekil 11. Bayes Optimizasyon tabanlı NAS tekniğini kullanan CNN modelinin ayrıntılı blok diyagramı.



Şekil 12. Bayes Optimizasyon tabanlı NAS tekniği kullanılarak GRU modelinin detaylı blok diyagramı.



Şekil 13. Bayes Optimizasyon tabanlı NAS tekniğini kullanan LSTM modelinin ayrıntılı blok diyagramı.



Şekil 14. Bayes Optimizasyon tabanlı NAS tekniğini kullanan BiLSTM modelinin ayrıntılı blok diyagramı.

CNN-GRU Unified (CGU) Hibrit Modeli

Önerilen Model Mimarisi

Çalışmada, Deriner Barajı su seviyesi tahmini için CNN-GRU hibrit modeli geliştirilmiştir. Modelin yapısı, CNN ve GRU yapılarının hiper-parametrelerinin BO tabanlı NAS tekniği kullanılarak ayrı ayrı optimize edilmesiyle oluşturulmuştur. İlk olarak, CNN ve GRU katmanlarının her biri NAS tekniği ile ayrı ayrı yapılandırılmıştır. Ardından, en yüksek doğruluğu sağlayan bu blokların katmanları birleştirilerek nihai hibrit model olan CGU mimarisi elde edilmiştir. Bu yapı sayesinde, model zaman serisi verilerindeki hem uzaysal hem de zamansal örüntüleri eşzamanlı olarak işleyebilme kapasitesine kavuşturulmuştur.


Model bileşenleri, NAS tekniği ile elde edilen doğruluk ölçümlerine göre seçilmiştir. CNN modeli, test verisinde 0.99205 R² skoruna ulaşarak en yüksek performans gösteren yapı olmuştur. GRU modeli de zaman serisi tahmininde 0.99069 R² skoru ile yüksek doğruluk elde etmiştir. Öte yandan, LSTM ve BiLSTM modelleri özellikle kısa vadeli tahminlerde bu iki modele kıyasla daha düşük başarı göstermiştir. Buna göre, nihai modelde özellik çıkarımı için CNN, zamansal bağımlılıkların modellenmesi için GRU tercih edilmiştir.

GRU'nun tercih edilmesinin temel nedeni, LSTM ve BiLSTM'e kıyasla daha az parametre ile çalıştığından düşük hesaplama maliyeti ve daha hızlı eğitim sürecine sahip olmasıdır. Ayrıca, az sayıda parametre modeli aşırı öğrenmeye karşı daha dirençli kılmaktadır. Önerilen mimaride, zaman serisindeki çok katmanlı yapıyı daha iyi öğrenmek için iki GRU katmanı oluşturulmuştur. İlk GRU katmanı zaman içindeki temel örüntüleri yakalamakta, ikinci GRU katmanı ise bu bilgiyi yoğunlaştırarak daha detaylı ve güçlü bir veri temsili üretmektedir. Böylece modelin tahmin doğruluğu artırılmıştır.


CNN bloğu, girdi verilerinden anlamlı özelliklerin çıkarılmasından sorumludur. Bu blokta, 80 filtreli bir Conv1D katmanı kullanılmış, ardından maksimum havuzlama ve dropout katmanları eklenmiştir. CNN bloğundan gelen çıktı, GRU bloğu ile "concatenate" yöntemi kullanılarak birleştirilmekte ve bu sayede hem uzaysal hem de zamansal örüntülerin eşzamanlı işlenmesi sağlanmaktadır. Bu birleştirmeden sonra, tam bağlı bir katman ve tek nöronlu bir regresyon çıkış katmanı eklenmiştir.

CGU modeli, yüksek tahmin performansı elde ederken hesaplama verimliliğini de korumaya odaklanarak geliştirilmiştir. Bu özelliği sayesinde model, gerçek zamanlı operasyonel hidrolojik sistemlerde kullanıma uygun hale getirilmiştir. Hibrit mimarisi ve kompakt yapısı sayesinde, model doğruluk ve kaynak kullanımı arasında sağlam bir denge sunmaktadır.

Şekil 15 ve Şekil 16, önerilen CGU modelinin mimari yapısını ayrıntılı olarak göstermektedir. Modelin genel akış diyagramı Şekil 15'te sunulmakta ve farklı katman türleri renk kodlarıyla gösterilmektedir. Şekil 16'da, modelin teknik detayları blok diyagram biçiminde verilmiş ve CNN ve GRU bloklarının yapılandırması, bırakma oranları, aktivasyon fonksiyonları ve katmanlar arasındaki birleştirme süreci açıkça belirtilmiştir.



Şekil 15. Önerilen CGU modelinin üst düzey mimari görselleştirmesi.



Şekil 16. Bayes Optimizasyon Tabanlı NAS tekniği kullanılarak önerilen CGU modelinin blok diyagramı.

Model Eğitim Süreci

CGU modelinin hesaplama verimliliğini değerlendirmek amacıyla, model Intel Core i7-13700H işlemci (13. Nesil), 16 GB RAM ve NVIDIA RTX 4060 GPU ile donatılmış bir sistem üzerinde eğitilmiştir. Model toplam 312,193 eğitilebilir parametre içermekte ve ortalama 3.2 dakikalık eğitim süresi elde etmiştir. Eğitim sürecinde, model 0.0087 minimum doğrulama MAE ve 1.17e-04 nihai doğrulama kaybı değerlerine ulaşmış, bu da hızlı yakınsama ve yüksek

tahmin kapasitesini göstermektedir. Bu sonuçlar, CGU modelinin su seviyesi tahmini senaryolarında pratik ve ölçeklenebilir uygulamalar için uygunluğunu doğrulamaktadır.

Model, 2014-2023 yılları arasında günlük olarak toplanan veri seti ile eğitilmiştir. Eğitim sürecinde kayıp fonksiyonu olarak MSE, optimizasyon algoritması olarak Adam (öğrenme hızı: 0.001) kullanılmıştır. Eğitim işlemleri 32 grup boyutu ve erken durdurma kriteri ile gerçekleştirilmiştir. Model performansı esas olarak R^2 skoru ile değerlendirilmiştir. CGU mimarisi, tüm NAS tekniği modelleri arasında en yüksek doğruluğa ulaşarak en başarılı yapı olmuştur.

Sonuç olarak, CGU modeli optimize edilmiş mimarisi, düşük hesaplama maliyeti, hızlı eğitim süresi, yüksek genelleme yeteneği ve gerçek zamanlı uygulamalara uyarlanabilirliği ile baraj su seviyesi tahmini gibi mühendislik problemleri için etkili ve uygulanabilir bir çözüm sunmaktadır.

Tüm deneysel sonuçların tekrarlanabilir olması için rastgele sayı üreteçleri sabitlenmiştir. Python, NumPy, TensorFlow ve Scikit-learn için rastgele tohum değeri 42 olarak ayarlanmıştır. Bu ayarlar, aynı kodun her çalıştırılmasında özdeş sonuçlar üretmesini garanti etmektedir.

ARAŞTIRMA BULGULARI

Bu bölümde, Yusufeli ve Deriner barajlarının su seviyesi tahminlerine yönelik olarak gerçekleştirilen deneysel çalışmaların sonuçları detaylı bir şekilde sunulmaktadır. Bulgular, zaman serisi modelleri ve DL yaklaşımları olmak üzere iki temel metodolojik çerçevede değerlendirilmekte ve her bir modelin tahmin performansı nicel metriklerle ortaya konmaktadır. Çalışma kapsamında elde edilen sonuçlar, hem grafiksel analizler hem de sayısal performans metrikleri aracılığıyla sunulmaktadır.

Zaman Serisi Analizine Dayalı ACF ve PACF Bulguları


Zaman serisi modellemesinin ilk aşamasında, hem Deriner hem de Yusufeli barajlarına ait veri setlerinin otokorelasyon yapıları analiz edilmiştir. Bu analizler, model parametrelerinin belirlenmesi ve serinin dinamiklerinin anlaşılması açısından kritik önem taşımaktadır.

Deriner Barajı ACF ve PACF Analizi


Deriner Barajı veri setine ait ACF grafiği incelendiğinde, ilk gecikmelerde güçlü otokorelasyon yapısının varlığı gözlemlenmiştir. İlk gecikmeden sonraki değerlerin yavaş bir şekilde azalması, seride belirgin bir trend bileşeninin bulunduğuna işaret etmektedir. Bu bulgu, zaman serisi modellerinde durağanlığın sağlanması için fark alma işleminin gerekliliğini ortaya koymaktadır.

PACF grafiğinde ise ilk gecikmede güçlü ve anlamlı bir korelasyon tespit edilmiş olup, sonraki gecikmelerde değerlerin hızla sifira yaklaşması gözlemlenmiştir. Bu durum, serinin birinci dereceden otoregresif süreç içerdiğini ve kısa vadeli bağımlılıkların ilk gecikmeyle sınırlı kaldığını göstermektedir. PACF grafiğindeki bu yapı, ARIMA modelinde otoregresif parametre derecesinin belirlenmesinde yol gösterici olmuştur.

ACF ve PACF grafiklerinden elde edilen bulgular doğrultusunda, Deriner Barajı veri setinde belirgin bir trend yapısının olduğu ve kısa vadeli bağımlılığın ilk gecikmeyle sınırlı kaldığı tespit edilmiştir. Bu bulgu, serinin birinci dereceden fark alma işlemi sonrasında durağan hale gelebileceğini ve zaman serisi modellerinin serinin dinamiklerini başarılı bir şekilde yakalayabileceğini göstermektedir.



Şekil 17. Deriner Barajı veri seti ACF grafiği.




Şekil 18. Deriner Barajı veri seti PACF grafiği.


Yusufeli Barajı ACF ve PACF Analizi

Yusufeli Barajı veri setine ait ACF analizi sonuçları, serinin ilk gecikmelerinde güçlü otokorelasyon değerlerinin varlığını ortaya koymuştur. İlk gecikmeden sonra değerlerin kademeli olarak azalması, seride hem trend hem de otoregresif bileşenlerin etkili olduğunu göstermektedir. PACF grafiğinde ilk gecikmede güçlü bir korelasyon gözlemlenmiş ve sonraki gecikmelerde değerler hızla sıfıra yaklaşmıştır.

Bu bulgular, Yusufeli Barajı veri setinin de birinci dereceden otoregresif süreç içerdiğine işaret etmektedir. Ancak, Yusufeli veri setinin nispeten daha kısa zaman aralığını kapsamaması nedeniyle, mevsimsel bileşenlerin tam olarak gözlemlenmesi sınırlı kalmıştır. ACF ve PACF analizlerinden elde edilen bulgular, model parametre seçiminde temel referans olarak kullanılmıştır.



Şekil 19. Yusufeli Barajı veri seti ACF grafiği.



Şekil 20. Yusufeli Barajı veri seti ACF grafiği.

Deriner Barajı Zaman Serisi Modelleme Sonuçları

Deriner Barajı için 2014-2023 yılları arasındaki 3449 günlük veri seti kullanılarak dört farklı zaman serisi modeli eğitilmiş ve performansları karşılaştırılmıştır. Modelleme sürecinde, gelen su miktarı, göl kotu ve enerji üretimi için kullanılan su miktarı girdi değişkenleri olarak kullanılırken, göldeki su miktarı hedef değişken olarak belirlenmiştir.

Tablo 1. Deriner Barajı için yapılan çalışma sonuçları.

<i>Model</i>	MAE	MSE	RMSE	R^2
SARIMA	8.849.617,64	$9,83 \times 10^{13}$	9.916.701,76	0.9880
SARIMAX	8.545.330,86	-	8.844.811,34	0.9905
ARIMA	10.606.752,74	$1,41 \times 10^{14}$	11.864.361,59	0.9829
ARIMAX	9.127.676,77	-	9.450.111,69	0.9891

SARIMA Modeli Sonuçları

SARIMA modeli, Deriner Barajı su seviyesi tahmininde 0.9888 R^2 skoruna ulaşmıştır. Model performans metrikleri detaylı olarak değerlendirildiğinde, MAE değeri 8.849.617,64 m³, MSE değeri $9,83 \times 10^{13}$ m² ve RMSE değeri 9.916.701,76 m³ olarak hesaplanmıştır.

SARIMA modelinin bu başarısı, mevsimsel bileşenlerin sistematik olarak yakalanması ve modellenmesi sayesinde elde edilmiştir. Uzun veri seti, mevsimsel döngülerin net bir şekilde gözlemlenmesine olanak tanımış ve model bu periyodik örüntüleri başarıyla öğrenmiştir.

SARIMA modelinin karmaşıklık matrisi incelendiğinde, tahmin edilen değerlerin gerçek değerlerle yüksek uyum gösterdiği ve sistematik sapmaların minimal düzeyde kaldığı görülmüştür.


SARIMAX Modeli Sonuçları

SARIMAX modeli, Deriner Barajı için tüm zaman serisi modelleri arasında en yüksek tahmin performansını sergilemiş ve R^2 skoru 0.9905 olarak elde edilmiştir. Bu sonuç, SARIMAX modelinin hem mevsimsel bileşenleri hem de dışsal değişkenleri başarılı bir şekilde entegre edebildiğini göstermektedir.

Model performans metrikleri incelendiğinde, MAE değeri 8.545.330,86 m³ ve RMSE değeri 8.844.811,34 m³ olarak hesaplanmıştır. Bu değerler, SARIMAX modelinin diğer tüm zaman serisi modellerinden daha düşük hata oranlarına sahip olduğunu ortaya koymaktadır.

En başarılı SARIMAX model konfigürasyonu, birinci dereceden otoregresif terim, birinci dereceden fark alma ve üçüncü dereceden hareketli ortalama bileşenlerine sahip yapıda elde edilmiştir. Mevsimsel bileşenler açısından ise birinci dereceden mevsimsel otoregresif terim, sıfır dereceden mevsimsel fark alma ve birinci dereceden mevsimsel hareketli ortalama terimi kullanılmıştır. Mevsimsel periyot altı olarak belirlenmiş ve sabit terim modele dahil edilmiştir.

SARIMAX modelinin üstün performansı, dışsal değişkenlerin su seviyesi değişimlerini açıklama gücünün yüksek olmasından kaynaklanmaktadır. Gelen su miktarı, göl kotu ve enerji üretimi parametrelerinin dışsal değişken olarak modele eklenmesi, tahmin doğruluğunu önemli ölçüde artırmıştır. Şekil 21' de SARIMAX modelinin Deriner Barajı veriseti üzerindeki gelecek tahmini grafiği gösterilmiştir.



Şekil 21. SARIMAX modelinin aylık tahmin sonuçları.

ARIMAX Modeli Sonuçları

ARIMAX modeli, Deriner Barajı su seviyesi tahmininde 0.9891 R^2 skoruyla güçlü bir performans sunmuştur. MAE değeri 9.127.676,77 m³ ve RMSE değeri 9.450.111,69 m³ olarak hesaplanmıştır.

ARIMAX modelinin performansı, SARIMAX modeline yakın düzeyde olmuş ancak mevsimsel bileşenlerin eksikliği nedeniyle hafif bir performans kaybı yaşanmıştır. Bununla birlikte, dışsal değişkenlerin modele dahil edilmesi, basit ARIMA modeline kıyasla önemli bir iyileşme sağlamıştır. Model, özellikle kısa vadeli tahminlerde başarılı sonuçlar üretmiş ve dışsal faktörlerin etkilerini etkin bir şekilde yakalamıştır.

ARIMA Modeli Sonuçları

ARIMA modeli, 0.9829 R^2 skoruyla diğer zaman serisi modellerine kıyasla nispeten daha düşük performans göstermiştir. MAE değeri 10.606.752,74 m³, MSE değeri $1,41 \times 10^{14}$ m² ve RMSE değeri 11.864.361,59 m³ olarak bulunmuştur.

Bu sonuçlar, mevsimsel bileşenlerin ve dışsal değişkenlerin modellenmesinin tahmin performansını önemli ölçüde artırdığını ortaya koymaktadır. ARIMA modelinin basit yapısı, uzun vadeli ve karmaşık hidrolojik dinamikleri tam olarak yakalayamamış ve bu durum performans düşüşüne yol açmıştır. Bununla birlikte, ARIMA modelinin 0.98 üzerindeki R^2 skoru, temel zaman serisi yaklaşımlarının bile güvenilir tahminler üretebileceğini göstermektedir.

Deriner Barajı Tahmin Örnekleri ve Hata Analizi

Deriner Barajı için SARIMAX modelinin ürettiği tahminler detaylı olarak incelendiğinde, model performansının tutarlılığı ve güvenilirliği ortaya çıkmaktadır.

Tablo 2. Mayıs 2023 dönemine ait örnek tahminler.

Tarih	Gerçek Su Seviyesi (m ³)	Tahmini Su Seviyesi (m ³)	Hata oranı
1.05.2023	1.447797e+09	1.450090e+09	0.158387
2.05.2023	1.462588e+09	1.466110e+09	0.240822
3.05.2023	1.463387e+09	1.466000e+09	0.178548
4.05.2023	1.484574e+09	1.490073e+09	0.370423
5.05.2023	1.506560e+09	1.514920e+09	0.554908
6.05.2023	1.527347e+09	1.538799e+09	0.749814
7.05.2023	1.544933e+09	1.557579e+09	0.818551
8.05.2023	1.572574e+09	1.584200e+09	0.739301
9.05.2023	1.596411e+09	1.606731e+09	0.646426
10.05.2023	1.608837e+09	1.618246e+09	0.584856

Bu örnekler, SARIMAX modelinin kısa vadeli tahminlerde yüksek hassasiyet sağladığını ve hata oranlarının kabul edilebilir sınırlar içinde kaldığını göstermektedir. Tahmin hatalarının dağılımı incelendiğinde, sistematik bir sapma olmadığı ve hataların rastgele dağıldığı görülmüştür.

Yusufeli Barajı Zaman Serisi Modelleme Sonuçları

Yusufeli Barajı için 2023 yılına ait 319 günlük veri seti kullanılarak zaman serisi modelleri eğitilmiş ve performansları kapsamlı bir şekilde değerlendirilmiştir. Yusufeli Barajı'nın yeni işletmeye alınmış olması ve veri setinin nispeten kısa zaman aralığını kapsaması, modelleme sürecinde farklı dinamiklerin ortaya çıkmasına neden olmuştur.


Tablo 3. Yusufeli Barajı için yapılan çalışma sonuçları.

Model	MAE	MSE	RMSE	R ²
SARIMA	8.115.731,80	$7,41 \times 10^{13}$	8.610.966,03	0.9919
SARIMAX	8.148.518,78	-	9.316.979,04	0.9905
ARIMA	7.464.094,32	$6,22 \times 10^{13}$	7.885.685,23	0.9932
ARIMAX	8.148.518,78	-	9.316.979,04	0.9905

ARIMA Modeli Üstün Performansı

ARIMA modeli, Yusufeli Barajı su seviyesi tahmininde en yüksek performansı sergilemiş ve R^2 skoru 0.9932 olarak elde edilmiştir. Bu sonuç, Deriner Barajı için elde edilen sonuçlardan farklı olarak, ARIMA modelinin Yusufeli Barajı'nın hidrolojik dinamiklerini en iyi şekilde yakaladığını göstermektedir.

ARIMA modelinin bu başarısı, Yusufeli veri setinin karakteristik özelliklerinden kaynaklanmaktadır. Veri setinin kısa zaman aralığını kapsamaması nedeniyle, mevsimsel döngülerin tam olarak gözlemlenmemiş olması ve serinin daha basit bir yapıya sahip bulunması, ARIMA modelinin sadeliğinin avantaja dönüşmesini sağlamıştır. Model, trend ve otoregresif bileşenleri etkin bir şekilde modellemiş ve yüksek tahmin doğruluğu elde etmiştir. Şekil 22' de ARIMA modelinin Yusufeli Barajı veri seti üzerindeki gelecek tahmini grafiği gösterilmiştir.



Şekil 22. ARIMA modelinin aylık tahmin sonuçları.

SARIMA Modeli Sonuçları

SARIMA modeli, Yusufeli Barajı için 0.9911 R^2 skoruna ulaşmıştır. Mevsimsel bileşenlerin modele dahil edilmesi tahmin performansını artırmış ancak ARIMA modeli kadar yüksek performans göstermemiştir. Bu durum, veri setinin yalnızca bir yıllık dönemi kapsamaması ve mevsimsel döngülerin tam olarak tamamlanmamış olması ile açıklanabilir.

SARIMA modelinin mevsimsel parametreleri, mevcut veri yapısına uygun şekilde ayarlanmış olmasına rağmen, kısa veri seti mevsimsel bileşenlerin tam olarak öğrenilmesini sınırlamıştır. Bununla birlikte, modelin 0.99 üzerindeki R^2 skoru, mevsimsel modellemenin potansiyelini ortaya koymaktadır.

ARIMAX ve SARIMAX Modelleri Sonuçları

ARIMAX modeli, Yusufeli Barajı için 0.9908 R^2 skoruna ulaşmıştır. Dışsal değişkenlerin modele eklenmesi, özellikle enerjiye çevrilebilecek su miktarı parametresinin kullanılması, tahmin performansını iyileştirmiştir. Ancak, ARIMA modelinin sadeliği ve veri setine uygunluğu nedeniyle ARIMAX modeli en yüksek performansı sağlayamamıştır.

SARIMAX modeli ise 0.9923 R^2 skoruyla güçlü bir performans sergilemiştir. Hem mevsimsel bileşenlerin hem de dışsal değişkenlerin bir arada kullanılması, model karmaşıklığını artırmış ancak kısa veri seti nedeniyle bu karmaşıklık optimal performansa dönüşmemiştir.

Yusufeli ve Deriner Barajları Karşılaştırmalı Analizi

Zaman serisi modellerinin karşılaştırmalı analizi, barajların farklı hidrolojik karakteristiklerine ve veri setlerinin özelliklerine göre optimal model seçiminin değişebileceğini ortaya koymaktadır. Deriner Barajı için uzun veri seti ve belirgin mevsimsel döngüler nedeniyle SARIMAX modeli en iyi performansı gösterirken, Yusufeli Barajı için nispeten daha basit yapıya sahip ARIMA modeli yüksek doğruluk sağlamıştır.

Bu bulgular, baraj yönetim sistemlerinde kullanılacak tahmin modellerinin, barajın spesifik özelliklerine ve mevcut veri yapısına göre seçilmesi gerektiğini vurgulamaktadır. Uzun işletme geçmişine sahip barajlar için karmaşık mevsimsel modeller tercih edilirken, yeni işletmeye alınan barajlar için daha basit modeller etkili sonuçlar üretebilmektedir.

Derin Öğrenme Modelleri Performans Değerlendirmesi

Deriner Barajı su seviyesi tahminleri için çeşitli DL mimarileri uygulanmış ve performansları sistematik olarak değerlendirilmiştir. Modellerin eğitimi 30 günlük kayan pencere yaklaşımı kullanılarak gerçekleştirilmiş olup, modelin başarımı eğitim aşamasından sonra gelen ve modele daha önce gösterilmeyen 48 günlük bir sürecin tahmin edilmesiyle test edilmiştir.

Temel Derin Öğrenme Modellerinin Performans Sonuçları

CNN Modeli Sonuçları

CNN modeli, Deriner Barajı su seviyesi tahmininde test veri setinde $R^2 = 0,8160$ performansı elde etmiştir. CNN mimarisinin evrişim katmanları, hidrolojik verilerdeki yerel zamansal özellikleri çıkarmaya çalışmış ancak diğer modellere kıyasla önemli ölçüde daha düşük performans göstermiştir.

Model, evriřim filtrelerinin optimize edilmesine raęmen su seviyesindeki uzun vadeli baęımlılıkları yakalamada yetersiz kalmıřtır. Bu durum, yalnızca evriřim katmanlarının hidrolojik zaman serisi tahminlerinde tek başına yeterli olmadığını açıkça göstermektedir. CNN modelinin düşük performansı, tekrarlayan katmanların zamansal baęımlılıkları modellemede kritik önemini ortaya koymaktadır.

LSTM Modeli Sonuçları

LSTM modeli, uzun vadeli zamansal baęımlılıkları öğrenme kapasitesi sayesinde test veri setinde $R^2 = 0,9726$ performansı elde etmiştir. LSTM'in kapı mekanizmaları, su seviyesindeki uzun vadeli eğilimleri ve mevsimsel deęişimleri başarıyla yakalamıştır.

Model, unutma kapısı aracılığıyla ilgisiz bilgileri filtreleyerek, giriş kapısı ile yeni önemli bilgileri hücre durumuna ekleyerek ve çıkış kapısı ile uygun çıktıları üreterek etkin bir öğrenme süreci gerçekleřtirmiştir. 30 günlük geçmiş verinin kullanılması, LSTM modelinin uzun vadeli baęımlılıkları öğrenmesi için yeterli olmuş ve model yüksek tahmin doğruluęu sağlamıştır.

BiLSTM Modeli Sonuçları

BiLSTM modeli, çift yönlü bilgi işleme kapasitesi ile test veri setinde $R^2 = 0,9233$ performans göstermiştir. BiLSTM'in hem geçmiş hem de gelecek bilgilerini eş zamanlı kullanma yeteneęine raęmen, LSTM modeline kıyasla beklenmedik şekilde daha düşük performans sergilemiştir.

Bu durum, Deriner Barajı veri setinin karakteristik özellikleri ile ilişkili olabilir. İleri yönlü LSTM katmanı ile geçmiş bilgileri işlerken, geri yönlü LSTM katmanı ile gelecek bilgilerini işlemesine raęmen, model LSTM'e göre daha düşük doğruluk elde etmiştir. Bu sonuç, çift yönlü mimarilerin her zaman üstün performans göstermedięini ve veri setine göre model seęiminin önemini vurgulamaktadır.

GRU Modeli Sonuçları

GRU modeli, LSTM'e göre daha basit yapısına raęmen test veri setinde $R^2 = 0,9786$ performansına ulaşmıştır. GRU'nun daha az parametre içermesi, eğitim süresini kısaltmış ve hesaplama verimlilięi sağlamıştır.

Model performansı, LSTM ve BiLSTM'e kıyasla daha yüksek olmuş ve GRU'nun güncelleme kapısı ile sıfırlama kapısı mekanizmalarının etkin çalıştığı görölmüřtür. GRU'nun basitlięi, model yorumlanabilirlięi açısından avantaj sağlarken, tahmin doğruluęunda önemli

bir performans artışı sağlamıştır. Bu sonuç, operasyonel uygulamalar için GRU modelinin tercih edilebilir bir alternatif olduğunu göstermektedir.

Hibrit Derin Öğrenme Modellerinin Performans Sonuçları

CNN-LSTM Hibrit Modeli Sonuçları

CNN-LSTM hibrit mimarisi, evrişim katmanlarının yerel özellik çıkarma gücü ile LSTM katmanlarının uzun vadeli bağımlılık öğrenme kapasitesini birleştirerek test veri setinde $R^2 = 0,9638$ performans elde etmiştir.

Hibrit yapı, CNN katmanlarının hidrolojik verilerdeki kısa vadeli örüntüleri çıkarması ve bu özelliklerin LSTM katmanlarına girdi olarak verilmesi sayesinde hem yerel hem de küresel zamansal dinamikleri bir arada modellemiştir. Model, ani su seviyesi değişimlerini tespit etmede CNN katmanlarının gücünden yararlanırken, uzun vadeli eğilimleri öğrenmede LSTM katmanlarının kapasitesini kullanmıştır.

CNN-BiLSTM Hibrit Modeli Sonuçları

CNN-BiLSTM hibrit modeli, test veri setinde $R^2 = 0,9655$ performansı sergilemiştir. Model, çift yönlü LSTM katmanlarının sağladığı zengin bağlamsal bilgi ile evrişim katmanlarının çıkardığı özellikleri entegre ederek güçlü bir tahmin performansı sunmuştur.

CNN-BiLSTM mimarisi, özellikle karmaşık hidrolojik dinamiklerin bulunduğu durumlarda avantaj sağlamış ve hem kısa vadeli ani değişimleri hem de uzun vadeli eğilimleri başarıyla yakalamıştır. Model, CNN-LSTM'e benzer performans göstermiş ve hibrit yaklaşımların etkinliğini ortaya koymuştur.

CNN-GRU Hibrit Modeli Sonuçları

CNN-GRU hibrit mimarisi, tüm manuel olarak tasarlanan hibrit modeller arasında en yüksek performansı göstermiş ve test veri setinde $R^2 = 0,9897$ performansına ulaşmıştır.

CNN-GRU modelinin başarısı, GRU katmanlarının hesaplama verimliliği ile evrişim katmanlarının güçlü özellik çıkarma kapasitesinin optimal kombinasyonundan kaynaklanmaktadır. Model, LSTM tabanlı hibrit mimarilere kıyasla önemli ölçüde daha yüksek tahmin doğruluğu sağlamıştır. Bu performans, hibrit mimarilerin temel DL modellerine göre üstünlüğünü açıkça göstermekte ve CNN-GRU kombinasyonunun baraj su seviyesi tahmininde optimal yapı olduğunu ortaya koymaktadır.

Bayes Optimizasyon Tabanlı NAS Tekniği Sonuçları

BO tabanlı NAS tekniği, DL modellerinin hiper-parametrelerinin sistematik olarak optimize edilmesinde kullanılmış ve tüm model türlerinde performans iyileşmesi sağlanmıştır.

NAS Optimizasyonlu CNN Modeli Sonuçları

NAS tekniği ile optimize edilen CNN modeli, manuel olarak tasarlanan CNN modeline kıyasla önemli ölçüde daha yüksek performans sergilemiştir. BO süreci, evrişim filtre sayısı, çekirdek boyutu, havuzlama stratejisi, aktivasyon fonksiyonu ve dropout oranı gibi kritik hiper-parametreleri sistematik olarak belirlemiştir.

Optimizasyon sonucunda, model test veri setinde $R^2 = 0,9920$ performansına ulaşmıştır. Manuel tasarıma kıyasla test performansında yaklaşık %17,60 oranında çok önemli bir iyileşme sağlanmıştır (0,8160'tan 0,9920'ye). Bu dramatik iyileşme, NAS tekniğinin hiper-parametre uzayını son derece etkin bir şekilde keşfettiğini ve optimal konfigürasyonu bulduğunu göstermektedir. Özellikle CNN modelinde görülen bu büyük performans artışı, otomatik hiper-parametre optimizasyonunun kritik önemini vurgulamaktadır.

NAS Optimizasyonlu LSTM Modeli Sonuçları

LSTM modeli, BO ile optimize edildiğinde test veri setinde $R^2 = 0,9807$ performansı sergilemiştir. Optimizasyon süreci, LSTM katman sayısı, gizli birim sayısı, dropout düzenlileştirme oranı ve recurrent dropout oranı gibi kritik parametreleri belirlemiştir.

Manuel tasarıma kıyasla test performansında yaklaşık %0,81 oranında iyileşme sağlanmıştır. LSTM modelinin karmaşık hiper-parametre uzayında optimal konfigürasyonun bulunması, BO'un etkinliğini göstermektedir.

NAS Optimizasyonlu BiLSTM Modeli Sonuçları

BiLSTM modeli, NAS tekniği ile optimize edildiğinde test veri setinde $R^2 = 0,9726$ performansına ulaşmıştır. Çift yönlü katmanların hiper-parametrelerinin optimal ayarlanması, modelin genelleme kapasitesini artırmış ve aşırı öğrenme riskini minimize etmiştir.

Test performansında manuel tasarıma kıyasla yaklaşık %4,93 oranında önemli iyileşme sağlanmıştır (0,9233'ten 0,9726'ya). BiLSTM modelinin NAS ile optimize edilmesi, modelin hem ileri hem de geri yönlü katmanlarının parametrelerinin dengeli bir şekilde ayarlanmasını sağlamıştır ve manuel tasarımda görülen performans düşüklüğü problemini ortadan kaldırmıştır.

NAS Optimizasyonlu GRU Modeli Sonuçları

GRU modeli, NAS tekniği ile optimize edildiğinde test veri setinde $R^2 = 0,9906$ performans elde etmiştir. Optimizasyon süreci, GRU katman sayısı, her katmandaki birim sayısı, dropout oranı ve öğrenme hızı gibi parametreleri otomatik olarak belirlemiştir.

NAS optimizasyonlu GRU modeli, manuel olarak ayarlanan versiyona göre test performansında yaklaşık %1,20 oranında iyileşme göstermiştir. Bu sonuç, BO'un GRU mimarisi için de etkin çalıştığını ortaya koymaktadır.

NAS Optimizasyonlu CNN-LSTM Hibrit Modeli Sonuçları

CNN-LSTM hibrit modeli, NAS tekniği ile optimize edildiğinde test veri setinde $R^2 = 0,9761$ performansı elde etmiştir. Optimizasyon süreci, hem evrişim katmanlarının hem de LSTM katmanlarının hiper-parametrelerini dengeli bir şekilde ayarlamıştır.

Manuel tasarıma kıyasla test performansında yaklaşık %1,23 oranında iyileşme sağlanmıştır. NAS tekniği, hibrit mimarilerde de etkin bir şekilde çalışarak optimal konfigürasyonu bulmuştur.

NAS Optimizasyonlu CNN-BiLSTM Hibrit Modeli Sonuçları

CNN-BiLSTM hibrit modeli, NAS tekniği ile optimize edildiğinde test veri setinde $R^2 = 0,9790$ performansına ulaşmıştır. Çift yönlü LSTM katmanları ile evrişim katmanlarının optimal kombinasyonu, güçlü bir tahmin performansı sağlamıştır.

Manuel tasarıma kıyasla test performansında yaklaşık %1,35 oranında iyileşme gösterilmiştir. Bu sonuç, NAS tekniğinin karmaşık hibrit mimarilerde de başarılı bir şekilde uygulanabileceğini göstermektedir.

Önerilen CGU Hibrit Modeli Sonuçları

BO tabanlı NAS tekniği ile optimize edilen CGU olarak adlandırılan hibrit model, tüm DL mimarileri arasında en yüksek tahmin performansını sergilemiştir. Model, test veri setinde $R^2 = 0,9941$ performansına ulaşmış ve bu sonuç hem manuel hem de NAS optimize edilmiş tüm DL modellerini aşmıştır.

CGU Modelinin Mimari Özellikleri ve Optimizasyon Süreci


CGU modelinin mimarisi, NAS süreci boyunca sistematik olarak optimize edilmiştir. BO, arama uzayında tanımlanan parametreler arasından en uygun kombinasyonu belirlemek için Gauss Süreci vekil modeli ve Beklenen İyileşme kazanım fonksiyonunu kullanmıştır.

Evriřim katmanları iin optimize edilen parametreler incelendiėinde, filtre sayısı 8, ekirdek boyutu 5 ve maksimum havuzlama boyutu 2 olarak belirlenmiřtir. Bu deėerler, yerel zamansal zelliklerin optimal bir řekilde ıkarılmasını saėlamıřtır. GRU katmanı iin birim sayısı 50 olarak ayarlanmıř ve dropout oranı 0,3 dzeyinde tutulmuřtur.


ėrenme hızı, Adam optimizasyon algoritması ile birlikte 0,001 deėerinde optimize edilmiřtir. Bu ėrenme hızı, modelin kararlı bir řekilde konverjansa ulařmasını ve ařırı ėrenmeyi nlemesini saėlamıřtır. Grup boyutu 32 olarak belirlenmiř ve bu deėer hesaplama verimliliėi ile model performansı arasında denge saėlamıřtır.

CGU Modelinin Eėitim Sreci

CGU modelinin eėitim sreci boyunca kayıp fonksiyonu deėerleri dzenli bir řekilde azalmıř ve doėrulama veri setinde kararlı bir performans sergilenmiřtir. Eėitim kaybı ve doėrulama kaybı grafikleri paralel bir seyir izlemiř ve bu durum ařırı ėrenmenin olmadıėını gstermiřtir. Erken durdurma mekanizması, ařırı ėrenmeyi nlemek amacıyla 15 tekrar sabır parametresi ile uygulanmıřtır. Model, 100 tekrar eėitim srecinde en dřk doėrulama kaybını elde ettiėi noktada durdurulmuř ve aėırlıklar kaydedilmiřtir. Eėitim sresi boyunca, model aėırlıklarının dzenli olarak gncellenmesi ve gradyan deėerlerinin kararlı kalması, optimizasyon srecinin bařarıyla ilerlediėini gstermektedir. řekil 23, Deriner Barajı iin CGU kayıp grafiėini gstermektedir. řekil 24, Deriner Barajı iin ngrlen ve gerekleřen su seviyeleri arasındaki karřılařtırmayı gstermektedir.



řekil 23. nerilen CGU modelinin kayıp grafiėi.



Şekil 24. Önerilen CGU modelinin test verisi tahmin sonuçları.

CGU Modelinin Tahmin Performansı

CGU modelinin ürettiği tahminler, gerçek su seviyeleri ile yüksek uyum göstermiştir. Şekil 24'te sunulan tahmin sonuçları grafiği, modelin test veri seti üzerindeki performansını göstermektedir. Grafik incelendiğinde, mavi kesikli çizgi ile gösterilen gerçek değerler ile turuncu düz çizgi ile gösterilen tahmin değerlerinin birbirine oldukça yakın seyrettiği görülmektedir.

Model, yaklaşık 50 günlük test periyodu boyunca su seviyesinin 0,4'ten 0,9'a kadar olan geniş değişim aralığında tutarlı tahminler üretmiştir. Özellikle 0-10 gün, 20-25 gün ve 35-45 gün aralıklarında görülen ani değişimlerde bile model, gerçek değerleri yüksek hassasiyetle takip edebilmiştir. Tahmin edilen değerlerin gerçek değerlerden sapması minimal düzeyde kalmış ve tahmin hataları normal dağılım göstermiştir.

Grafikteki sonuçlar, CGU modelinin hem artan hem de azalan trendleri başarıyla yakaladığını göstermektedir. Model, 0-20 gün arasındaki yükselen trend, 20-25 gün arasındaki plato dönemi ve 25 günden sonraki tekrar yükselen trend gibi farklı dinamikleri doğru bir şekilde modelleyebilmiştir. Bu performans, modelin operasyonel baraj yönetim sistemlerine entegre edilebilir nitelikte olduğunu ve gerçek zamanlı karar destek süreçlerinde güvenilir bir araç olarak kullanılabileceğini göstermektedir.

Kapsamlı Model Karşılaştırması ve Performans Analizi

Tüm modellerin karşılaştırmalı analizi, hibrit mimarilerin temel DL modellerine göre üstünlük sağladığını açıkça göstermektedir. Manuel modeller içinde CNN-GRU hibrit yapısı

$R^2 = 0,9897$ ile en yüksek performansı sergilerken, CNN modeli $R^2 = 0,8160$ ile en düşük performansı göstermiştir.


NAS tekniğinin uygulanması, tüm model türlerinde tutarlı bir şekilde performans iyileşmesi sağlamıştır. Özellikle CNN modelinde görülen %17,60'luk dramatik iyileşme (0,8160'tan 0,9920'ye), NAS tekniğinin etkinliğini çarpıcı bir şekilde göstermektedir. BiLSTM modelinde de %4,93'lük önemli iyileşme (0,9233'ten 0,9726'ya) gözlemlenmiştir.

CGU modeli, manuel CNN-GRU modeline ($R^2 = 0,9897$) kıyasla %0,44 oranında ek iyileşme sağlayarak $R^2 = 0,9941$ performansına ulaşmış ve tüm modeller arasında en yüksek doğruluğu elde etmiştir. Bu sonuç hem hibrit mimari yaklaşımının hem de NAS tabanlı otomatik optimizasyonun sinerjik etkisini göstermektedir.

Eğitim ve test performansları arasındaki fark, tüm modellerde kontrol altında tutulmuş ve aşırı öğrenme riski düzenleme stratejileri ile minimize edilmiştir. Dropout düzenleme, erken durdurma ve uygun öğrenme hızı seçimi, modellerin genelleme kapasitesini artırmıştır.

Hesaplama verimliliği açısından değerlendirildiğinde, GRU tabanlı modeller LSTM tabanlı modellere göre daha hızlı eğitim süreleri sunmuştur. CNN-GRU modelinin eğitim süresi, CNN-LSTM modeline kıyasla yaklaşık %25 daha kısa olmuş ve bu avantaj operasyonel uygulamalar için önemli bir faktör olarak öne çıkmıştır.

Bellek kullanımı açısından, GRU modelleri LSTM modellerine göre daha az parametre içerdiğinden daha düşük bellek gereksinimi göstermiştir. Bu özellik, kaynak kısıtlı ortamlarda model dağıtımını kolaylaştırmakta ve gerçek zamanlı tahmin uygulamalarında avantaj sağlamaktadır. Deriner Barajı verilerine ait modellerin R^2 puanları Şekil 25'te gösterilmiştir. Şekil 25'te, son teknoloji ve hibrit modellerin (mavi), NAS tekniğini kullanan DL modellerinin (turuncu) ve önerilen CGU modelinin (yeşil) R^2 puanlarını gösteren yatay çubuk grafik gösterilmektedir.



Şekil 25. Deriner Barajı veri setinde DL modellerinin R^2 puanları.

Sonuçların Literatür ile Karşılaştırılması ve Değerlendirme

Elde edilen sonuçlar, literatürdeki benzer çalışmalarla karşılaştırıldığında rekabetçi ve üstün performans sergilemektedir. Deriner Barajı için SARIMAX modelinin %99,05 doğruluk oranı, zaman serisi modelleri kullanan önceki çalışmaların çoğundan daha yüksek bir başarı düzeyini temsil etmektedir.

CGU modelinin test veri setinde $R^2 = 0,9941$ olarak elde edilen performansı, hidroelektrik barajlar üzerine yapılan DL çalışmalarında en yüksek doğruluk oranları arasında yer almaktadır. Bu başarı, NAS tekniğinin sistematik hiper-parametre optimizasyonu ve hibrit mimari tasarımının sinerjik etkisinden kaynaklanmaktadır.

Literatürdeki çalışmalarla karşılaştırıldığında, Hindistan'daki LSTM çalışması %97,31, Çin'deki GRU çalışması %96,87, Avustralya'daki GRU çalışması %98,25 ve Türkiye'deki ANFIS-SVM çalışması %99,01 doğruluk oranları elde etmiştir. CGU modelinin %99,41 doğruluk oranı, bu çalışmaların tamamından daha yüksek performans göstermektedir.

Yusufeli Barajı için ARIMA modelinin %99,32 doğruluk oranı, nispeten kısa veri setine sahip barajlarda zaman serisi modellerinin etkinliğini göstermektedir. Bu bulgu, yeni işletmeye alınan barajlarda bile güvenilir tahmin modellerinin geliştirilebileceğini ve operasyonel karar süreçlerine entegre edilebileceğini ortaya koymaktadır.

Bu çalışmada geliştirilen modellerin performansı, baraj su seviyesi tahmini alanında uluslararası literatürde rapor edilen sonuçlarla karşılaştırıldığında, üstün veya en azından

rekabetçi düzeyde olduğu görülmektedir. Çalışmanın hem zaman serisi hem de DL yaklaşımlarını kapsaması ve BO ile NAS tekniğinin uygulanması, metodolojik açılarından özgün ve kapsamlı bir katkı sunmaktadır.

Tablo 4. Literatürdeki çalışmalarla karşılaştırma

Yazar	Model	Çalışma Alanı	Tahmin Aralığı	R ²
Wyawahare ve Subhash (2023)	LSTM	Hindistan	Günlük	0.9731
Huang vd. (2021)	GRU	Poyang, Çin	Günlük	0.9687
Altunkaynak (2007)	ANN	Van Gölü, Türkiye	-	0.90
Atashi vd. (2022)	LSTM-RF	Kırmızı Nehir, ABD	-	0.973
Katipoğlu (2024)	EEMD-ABC-ANN	Erzurum, Türkiye	-	0.91-0.99
Mao vd. (2024)	BiLSTM	Three Gorges, Çin	Kısa Dönem	0.9815
Azad (2022)	SARIMA-ANN	Kırmızı Tepeleri, Hindistan	-	0.965
Ahmed vd. [7]	GRU	Murray, Avustralya	Günlük	0.9825
Haznedar ve Kilinc (2022)	ANFIS-GA	Seyhan Nehri, Türkiye	-	0.9263
Kilinc vd. (2024)	PSO-BiLSTM-BiGRU	Büyükçekmece, Türkiye	-	0.964
Hai Tao vd. (2021)	RVM-IGOA	-	-	0.986
Dayal vd. (2024)	LSTM	KRS, Hindistan	Günlük	R ² ≈ 0.93
Damla vd. (2020)	ANN	Gökçe Barajı, Türkiye	Günlük	0.9414
Arslan vd. (2020)	ANFIS-SVM	Keban Barajı, Türkiye	Kısa Dönem	0.9901

Salam ve Keskin (2018)	ANN	Dibis Türkiye	Barajı,	Günlük	0.887
Bu Çalışma	ARIMA	Yusufeli Türkiye	Barajı,	Günlük	R² = 0.9932
Bu Çalışma	SARIMAX	Deriner Türkiye	Barajı,	Günlük	R² = 0.9905
Bu Çalışma	CGU	Deriner Türkiye	Barajı,	Günlük	R² = 0.9941



SONUÇ VE ÖNERİLER

Bu tez çalışmasında, Türkiye'nin stratejik öneme sahip Deriner ve Yusufeli barajlarının su seviyesi tahminleri için kapsamlı bir metodolojik çerçeve geliştirilmiş ve uygulanmıştır. Çalışma, hem klasik zaman serisi analiz teknikleri hem de modern DL yaklaşımlarını sistematik olarak değerlendirerek, hidroelektrik baraj yönetim sistemleri için güvenilir ve yüksek performanslı tahmin modelleri sunmayı amaçlamıştır. Bu bölümde, araştırmanın temel sonuçları, bilimsel ve pratik katkıları, sınırlılıkları ve gelecek araştırmalar için öneriler değerlendirilmektedir.

Bu çalışma, baraj su seviyesi tahmini problemine çok yönlü bir yaklaşım getirerek, farklı modelleme stratejilerinin karşılaştırmalı analizini sunmuştur. Elde edilen sonuçlar, model seçiminin barajın hidrolojik karakteristiklerine, veri setinin uzunluğuna ve mevsimsel döngülerin belirginliğine göre özelleştirilmesi gerektiğini ortaya koymuştur. Bu bulgu, baraj yönetiminde kullanılacak tahmin sistemlerinin her barajın spesifik özelliklerine göre yapılandırılması gerektiğini göstermektedir.

Zaman serisi modelleri, özellikle mevsimsel bileşenlerin belirgin olduğu uzun veri setlerinde güvenilir sonuçlar üretmiştir. Mevsimselliğin ve dışsal değişkenlerin modellenmesi, tahmin doğruluğunu önemli ölçüde artırmıştır. Bu durum, hidrolojik tahmin çalışmalarında yalnızca hedef değişkenin geçmiş değerlerinin değil, aynı zamanda ilgili dışsal faktörlerin de sistematik olarak değerlendirilmesi gerektiğini vurgulamaktadır.

DL yaklaşımları, karmaşık ve doğrusal olmayan hidrolojik dinamikleri yakalamada üstün performans göstermiştir. Hibrit mimarilerin, temel DL modellerine göre daha yüksek doğruluk sağlaması, farklı mimari bileşenlerin tamamlayıcı güçlü yönlerinin birleştirilmesinin önemini ortaya koymuştur. Özellikle evrişim katmanlarının yerel örüntü tespiti ile tekrarlayan katmanların uzun vadeli bağımlılık öğrenme kapasitesinin sinerjik kullanımı, tahmin performansını optimize etmiştir.

BO tabanlı NAS tekniğinin uygulanması, manuel hiper-parametre ayarlama süreçlerinin getirdiği sınırlamaları aşmış ve tüm model türlerinde tutarlı performans iyileşmeleri sağlamıştır. Bu yaklaşım, veri odaklı ve sistematik mimari tasarımın önemini göstermekte ve gelecekteki hidrolojik modelleme çalışmalarında otomatik optimizasyon tekniklerinin kullanımını desteklemektedir.

Bu araştırma, baraj su seviyesi tahmini alanına çeşitli bilimsel katkılar sunmaktadır. İlk olarak, hem klasik zaman serisi hem de modern DL yaklaşımlarının kapsamlı karşılaştırması, her iki metodolojinin güçlü ve zayıf yönlerinin sistematik olarak anlaşılmasına olanak tanımıştır. Literatürde çoğu çalışma tek bir yaklaşıma odaklanırken, bu tez çok yönlü bir metodolojik perspektif sunmaktadır.

İkinci olarak, NAS tekniğinin baraj su seviyesi tahmini problemine uygulanması, bu alanda yenilikçi bir yaklaşım olarak öne çıkmaktadır. NAS, genellikle görüntü işleme ve doğal dil işleme alanlarında kullanılmakta olup, hidrolojik zaman serisi tahminlerinde uygulanması sınırlı düzeydedir. Bu çalışma, NAS tekniğinin hidroelektrik baraj yönetiminde etkin bir şekilde kullanılabileceğini göstermiştir.

Üçüncü olarak, CGU hibrit mimarisinin geliştirilmesi ve BO ile optimize edilmesi, özgün bir model katkısı sunmaktadır. Bu mimari, evrim ve tekrarlayan katmanları optimal bir şekilde birleştirerek hem yerel hem de küresel zamansal özellikleri yakalayabilmektedir. Modelin yüksek performansı ve hesaplama verimliliği, operasyonel baraj yönetim sistemlerine entegre edilebilir düzeyde olduğunu göstermektedir.

Son olarak, farklı baraj karakteristiklerine göre model seçim stratejilerinin belirlenmesi, pratik değeri yüksek bir katkı sunmaktadır. Uzun işletme geçmişine sahip barajlar için karmaşık mevsimsel modellerin, yeni işletmeye alınan barajlar için daha basit modellerin etkili olabileceği bulgusu, karar vericilere yol gösterici bilgiler sağlamaktadır.

Geliştirilen tahmin modellerinin, hidroelektrik enerji üretim planlamasına doğrudan katkı sağlama potansiyeli bulunmaktadır. Doğru su seviyesi tahminleri, türbin kapasitesinin optimal kullanımını destekleyerek enerji üretim verimliliğini artırabilmektedir. Enerji piyasası dinamikleri göz önüne alındığında, elektrik fiyatlarının yüksek olduğu dönemlerde üretimin artırılması veya düşük fiyat dönemlerinde su depolanması gibi stratejik kararlar, güvenilir tahminlerle desteklenebilmektedir.

Tahmin modellerinin taşkın erken uyarı sistemlerine entegre edilmesi, afet risk yönetiminde önemli katkılar sunabilmektedir. Yüksek su seviyesi riskinin önceden tespit edilmesi, mansap bölgelerindeki yerleşim yerlerine ve tarım alanlarına zamanında uyarı yapılmasını sağlamaktadır. Kritik eşik değerlerinin aşılma olasılığının hesaplanabilmesi, baraj operatörlerine proaktif karar alma fırsatı sunmaktadır.

Uzun vadeli su seviyesi eğilimlerinin tahmin edilmesi, kuraklık dönemlerinde su kaynaklarının etkin yönetimi için kritik önem taşımaktadır. Tarımsal sulama ihtiyaçları, içme

suyu temini ve endüstriyel su kullanımları arasında optimal kaynak dağılımının planlanmasında, güvenilir su seviyesi tahminleri temel girdi olarak kullanılabilir.

Geliştirilen modellerin Python programlama dili ve açık kaynak kütüphaneler kullanılarak oluşturulmuş olması, teknik uygulama kolaylığı ve maliyet etkinliği açısından avantaj sağlamaktadır. Mevcut baraj otomasyon sistemlerine API tabanlı entegrasyon yoluyla bağlanabilme potansiyeli, geniş ölçekli uygulamaları mümkün kılmaktadır. CGU modelinin kısa sürede tahmin üretebilmesi, gerçek zamanlı karar destek sistemleri için uygunluğunu göstermektedir.

Yusufeli Barajı veri setinin yalnızca bir yıllık dönemi kapsamaması, uzun vadeli mevsimsel örüntülerin tam olarak gözlemlenmesini sınırlamıştır. Yeni işletmeye alınan barajlarda, yeterli uzunlukta veri serisinin birikimi zaman gerektirmekte ve bu durum modelleme sürecinde bir kısıt oluşturmaktadır. Gelecekte daha uzun veri serileri elde edildikçe, model performanslarının yeniden değerlendirilmesi önerilmektedir.

Çalışmada kullanılan dışsal değişkenler, barajların operasyonel parametreleri ile sınırlı kalmıştır. Meteorolojik değişkenler olan yağış, sıcaklık, buharlaşma ve kar erimesi gibi faktörler, veri erişim kısıtları nedeniyle modellere dahil edilememiştir. Literatürde, meteorolojik değişkenlerin su seviyesi tahminlerinde önemli katkı sağladığına dair bulgular mevcuttur. Bu değişkenlerin gelecekteki çalışmalara dahil edilmesi, model performansını iyileştirebilir.

Geliştirilen modeller, Deriner ve Yusufeli barajlarına özgü olarak eğitilmiş ve test edilmiştir. Modellerin diğer barajlara doğrudan transfer edilebilirliği, barajların hidrolojik karakteristiklerinin farklılığı nedeniyle sınırlı olabilir. Transfer öğrenmesi teknikleri kullanılarak modellerin farklı barajlara adapte edilmesi mümkün olmakla birlikte, bu durum ek araştırma gerektirmektedir.

İklim değişikliğinin uzun vadeli etkileri, modellerin gelecekteki performansını etkileyebilir. Tarihi verilere dayalı eğitim, geçmiş örüntülerin gelecekte de devam edeceği varsayımına dayanmaktadır. İklim değişikliği nedeniyle yağış rejimlerinde ve sıcaklık örüntülerinde meydana gelebilecek değişimler, modellerin periyodik olarak yeniden eğitilmesini gerektirebilir.

Gelecekteki araştırmalarda, meteoroloji istasyonlarından elde edilecek yağış, sıcaklık, nem ve buharlaşma gibi değişkenlerin modellere dahil edilmesi önerilmektedir. Uydu tabanlı uzaktan algılama verileri, kar örtüsü ve toprak nemi gibi parametrelerin geniş alan ölçeğinde izlenmesine olanak tanıyabilir. İklim projeksiyonlarının uzun vadeli tahminlere entegre

edilmesi, iklim deęişikliği etkileri altında baraj işletme stratejilerinin planlanmasına katkı sağlayabilir.

Çoruh Nehri havzasında bulunan birden fazla barajın etkileşimli olarak modellenmesi, havza bazlı optimal işletme stratejilerinin geliştirilmesine olanak tanıyabilir. Transfer öğrenmesi teknikleri kullanılarak, bir baraj için geliştirilen modellerin dięer barajlara adapte edilmesi araştırılabilir. Bu yaklaşım, sınırlı veri setine sahip yeni barajlar için model geliştirme süresini kısaltabilir.

Transformer mimarisi gibi dikkat mekanizması tabanlı modellerin, baraj su seviyesi tahmininde uygulanması araştırılabilir. Grafik Sinir Ağları, birden fazla baraj ve hidrolojik istasyonun uzaysal ilişkilerini modellemek için kullanılabilir. Topluluk (Ensemble) öğrenme teknikleri, farklı model tahminlerinin birleştirilmesi yoluyla daha güvenilir ve sağlam tahminler üretilmesine olanak tanıyabilir.

Nokta tahminlerinin yanı sıra, tahmin belirsizliğinin nicelleştirilmesi operasyonel karar verme süreçleri için değerli bilgiler sağlayabilir. Bayes DL yaklaşımları, tahmin dağılımlarının elde edilmesine ve güven aralıklarının hesaplanmasına olanak tanımaktadır. Bu yaklaşım, özellikle kritik karar alma durumlarında tahmin güvenilirliğinin değerlendirilmesine yardımcı olabilir.

Geliştirilen modellerin, gerçek operasyonel ortamlarda test edilmesi ve performanslarının izlenmesi önerilmektedir. Gerçek zamanlı veri akışı altyapılarının kurulması ve modellerin otomatik olarak güncellenen veriler ile çalışacak şekilde yapılandırılması, sürekli tahmin üretim sistemlerinin oluşturulmasını sağlayabilir. Online öğrenme yaklaşımları, modellerin yeni gelen verilerle sürekli olarak güncellenmesini ve deęişen hidrolojik koşullara adapte olmasını sağlayabilir.

Bu tez çalışması, baraj su seviyesi tahmini alanında kapsamlı bir metodolojik çerçeve sunarak hem akademik hem de pratik katkılar sağlamıştır. Klasik zaman serisi modelleri ile modern DL yaklaşımlarının sistematik karşılaştırması, her iki yöntemin güçlü ve zayıf yönlerinin anlaşılmasına olanak tanımıştır. BO tabanlı NAS tekniğinin uygulanması, otomatik model optimizasyonunun hidroelektrik baraj yönetiminde etkin bir şekilde kullanılabileceğini göstermiştir.

Geliştirilen CGU modeli, literatürdeki mevcut çalışmalarla rekabetçi ve hatta üstün performans sergilemiştir. Bu sonuç, hibrit mimarilerin ve otomatik hiper-parametre optimizasyonunun sinerjik etkisini göstermektedir. Elde edilen bulgular, baraj işletmecileri, enerji planlayıcıları ve su kaynakları yöneticileri için değerli karar destek araçları sunmaktadır.

Hidroelektrik enerji üretiminin optimizasyonu, taşkın risklerinin azaltılması ve kuraklık dönemlerinde su kaynaklarının etkin yönetimi, geliştirilen tahmin modellerinin doğrudan uygulama alanlarını oluşturmaktadır. Gelecekteki araştırmaların, bu çalışmada ortaya konulan sınırlılıkları aşmaya ve önerilen yönleri araştırmaya odaklanması önerilmektedir.

Sonuç olarak, bu tez çalışması baraj su seviyesi tahmini alanında metodolojik gelişmelere katkı sağlamış ve operasyonel baraj yönetim sistemlerine entegre edilebilir düzeyde yüksek performanslı tahmin modelleri sunmuştur. Elde edilen sonuçlar, Türkiye'nin stratejik su yapılarının verimli yönetiminde ve iklim değişikliği koşullarında su kaynaklarının sürdürülebilir kullanımında önemli roller oynayabilir. Geliştirilen metodolojik çerçeve, benzer hidrolojik tahmin problemlerine uygulanabilir ve ulusal ve uluslararası ölçekte su yönetimi politikalarının bilimsel temele dayandırılmasına katkı sunabilir.



KAYNAKÇA

- Wyawahare, M., & Subhash, A. (2023, December). Smart Dam Control: Embedded Systems and LSTM-Based Water Level Prediction. In International Conference on Advancements in Smart Computing and Information Security (pp. 245-253). Cham: Springer Nature Switzerland Doi:[10.1007/978-3-031-58604-0_17](https://doi.org/10.1007/978-3-031-58604-0_17)
- Huang, S., Xia, J., Zeng, S., Wang, Y., & She, D. (2021). Effect of Three Gorges Dam on Poyang Lake water level at daily scale based on machine learning. Journal of Geographical Sciences, 31(11), 1598-1614. Doi:[10.1007/s11442-021-1913-1](https://doi.org/10.1007/s11442-021-1913-1)
- Das, M., Ghosh, S.K., Chowdary, V.M. *et al.* A Probabilistic Nonlinear Model for Forecasting Daily Water Level in Reservoir. *Water Resour Manage* **30**, 3107–3122 (2016). Doi:[10.1007/s11269-016-1334-6](https://doi.org/10.1007/s11269-016-1334-6)
- Enerji Atlası. (n.d.). *Türkiye'nin en yüksek barajları*. Retrieved January 20, 2025, from <https://www.enerjiatlası.com/en-yuksek-barajlar/>
- Wikipedia contributors. (n.d.). *List of tallest dams*. In Wikipedia. Retrieved January 20, 2025, from https://en.wikipedia.org/wiki/List_of_tallest_dams
- Mao, X., Xiong, B., Luo, X., Yao, Z., & Huang, Y. (2024). Short-term prediction of water level based on deep learning in the downstream area of the Three Gorges Reservoir. *Natural Hazards*, 1-20. Doi:[10.1007/s11069-024-06772-1](https://doi.org/10.1007/s11069-024-06772-1)
- Ahmed, A. M., Deo, R. C., Ghahramani, A., Feng, Q., Raj, N., Yin, Z., & Yang, L. (2022). New double decomposition deep learning methods for river water level forecasting. *Science of The Total Environment*, 831, 154722. Doi:[10.1016/j.scitotenv.2022.154722](https://doi.org/10.1016/j.scitotenv.2022.154722)
- 성호정, 대업이, & 경상이. (2018). Prediction of river water level using deep-learning open library. *Journal of the Korean Society of Hazard Mitigation*, 18(1), 1-11. Doi:[10.9798/KOSHAM.2018.18.1.1](https://doi.org/10.9798/KOSHAM.2018.18.1.1)
- Ozdemir, S., Yaqub, M., & Yildirim, S. O. (2023). A systematic literature review on lake water level prediction models. *Environmental Modelling & Software*, 163, 105684. Doi:[10.1016/j.envsoft.2023.105684](https://doi.org/10.1016/j.envsoft.2023.105684)
- Nguyen, X. H. (2020). Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red river. *Advances in Water Resources*, 142, 103656. Doi: [10.1016/j.advwatres.2020.103656](https://doi.org/10.1016/j.advwatres.2020.103656)
- Hanoon, M. S., Ahmed, A. N., Razzaq, A., Oudah, A. Y., Alkhayyat, A., Huang, Y. F., & El-Shafie, A. (2023). Prediction of hydropower generation via machine learning algorithms at three Gorges Dam, China. *Ain Shams Engineering Journal*, 14(4), 101919. Doi: [10.1016/j.asej.2022.101919](https://doi.org/10.1016/j.asej.2022.101919).
- Raman, R., & Rathi, T. (2024, March). Efficient Dam Water Level Management Using Cloud-Based Data Analytics and LSTM Networks. In 2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO) (pp. 1-6). IEEE. Doi: [10.1109/ICRITO61523.2024.10522183](https://doi.org/10.1109/ICRITO61523.2024.10522183)
- Sannasi Chakravarthy, S. R., Bharanidharan, N., & Rajaguru, H. (2022). A systematic review on machine learning algorithms used for forecasting lake- water level fluctuations. *Concurrency and Computation: Practice and Experience*, 34(24), e7231. Doi: [10.1002/cpe.7231](https://doi.org/10.1002/cpe.7231)

- Truong, V. H., Ly, Q. V., Le, V. C., Vu, T. B., Tran, T. T., & Goethals, P. (2021). Machine learning-based method for forecasting water levels in irrigation and drainage systems. *Environmental Technology & Innovation*, 23, 101762. Doi: [10.1016/j.eti.2021.101762](https://doi.org/10.1016/j.eti.2021.101762)
- Zhou, Z., Zhou, Z., & Vanapalli, S. K. (2024). Integrating analytical and machine learning approaches to simulate and predict dam foundation stress and river valley contraction in a large-scale reservoir. *Bulletin of Engineering Geology and the Environment*, 83(11), 1-25. Doi: [10.1007/s10064-024-03941-1](https://doi.org/10.1007/s10064-024-03941-1)
- Morovati, K., Nakhaei, P., Tian, F., Tudaji, M., & Hou, S. (2021). A Machine learning framework to predict reverse flow and water level: A case study of Tonle Sap Lake. *Journal of Hydrology*, 603, 127168. Doi: [10.1016/j.jhydrol.2021.127168](https://doi.org/10.1016/j.jhydrol.2021.127168)
- Atashi, V., Gorji, H. T., Shahabi, S. M., Kardan, R., & Lim, Y. H. (2022). Water level forecasting using deep learning time-series analysis: A case study of red river of the north. *Water*, 14(12), 1971. Doi: [10.3390/w14121971](https://doi.org/10.3390/w14121971)
- Dayal, A., Bonthu, S., Saripalle, P., & Mohan, R. (2024). Deep learning for Multi-horizon Water level Forecasting in KRS reservoir, India. *Results in Engineering*, 21, 101828. Doi: [10.1016/j.rineng.2024.101828](https://doi.org/10.1016/j.rineng.2024.101828)
- Lee, M., Kim, J., Yoo, Y., Kim, H. S., Kim, S. E., & Kim, S. (2021). Water level prediction in Taehwa River basin using deep learning model based on DNN and LSTM. *Journal of Korea Water Resources Association*, 54(spc1), 1061-1069. Doi: [10.3741/JKWRA.2021.54.S-1.1061](https://doi.org/10.3741/JKWRA.2021.54.S-1.1061)
- Ahmed, A. N., Yafouz, A., Birima, A. H., Kisi, O., Huang, Y. F., Sherif, M., ... & El-Shafie, A. (2022). Water level prediction using various machine learning algorithms: a case study of Durian Tunggal river, Malaysia. *Engineering Applications of Computational Fluid Mechanics*, 16(1), 422-440. Doi: [10.1080/19942060.2021.2019128](https://doi.org/10.1080/19942060.2021.2019128)
- Almubaidin, M. A., Ahmed, A. N., Winston, C. A. A., & El-Shafie, A. (2023). Application of Machine Learning for Daily Forecasting Dam Water Levels. *Tikrit Journal of Engineering Sciences*, 30(4), 74-87. Doi: [10.25130/tjes.30.4.9](https://doi.org/10.25130/tjes.30.4.9)
- Zakaria, M. N. A., Ahmed, A. N., Malek, M. A., Birima, A. H., Khan, M. M. H., Sherif, M., & Elshafie, A. (2023). Exploring machine learning algorithms for accurate water level forecasting in Muda river, Malaysia. *Heliyon*, 9(7). Doi: [10.1016/j.heliyon.2023.e17689](https://doi.org/10.1016/j.heliyon.2023.e17689)
- Ishfaq, M., Luo, Y. L., Dai, Q., Salman, S., Lei, Y., Zhang, B., ... & Jamshed, W. (2024). Hydraulic and Hydroclimatic Impact on Dam Seepage of Civil and Structural Mechanisms with Application of Deep Learning Models. *Results in Engineering*, 102420. Doi: [10.1016/j.rineng.2024.102420](https://doi.org/10.1016/j.rineng.2024.102420)
- Damla, Y., Temiz, T., & Keskin, E. (2020). YAPAY SİNİR AĞI KULLANILARAK SU SEVİYESİNİN TAHMİN EDİLMESİ: YALOVA GÖKÇE BARAJI ÖRNEĞİ. *Kirklareli University Journal of Engineering and Science*, 6(1), 32-49. Doi: [10.34186/klujes.754845](https://doi.org/10.34186/klujes.754845)
- Sekban, J., Nabil, M. O. M., Alsan, H. F., & Arsan, T. (2022, September). Istanbul Dam Water Levels Forecasting Using ARIMA Models. In *2022 Innovations in Intelligent Systems and Applications Conference (ASYU)* (pp. 1-7). IEEE. Doi: [10.1109/ASYU56188.2022.9925418](https://doi.org/10.1109/ASYU56188.2022.9925418)
- Buyukyildiz, M., Tezel, G., & Yilmaz, V. (2014). Estimation of the change in lake water level by artificial intelligence methods. *Water resources management*, 28, 4747-4763. Doi: [10.1007/s11269-014-0773-1](https://doi.org/10.1007/s11269-014-0773-1)
- H. Arslan, F. Üneş, M. Demirci, B. Taşar, and A. Yılmaz, “Keban Baraj Gölü Seviye Değişiminin ANFIS ve Destek Vektör Makineleri ile Tahmini”, *OKÜ Fen Bil. Ens.*

- Dergisi ((OKU Journal of Nat. & App. Sci), vol. 3, no. 2, pp. 71–77, 2020, Doi: [10.47495/okufbed.748018](https://doi.org/10.47495/okufbed.748018).
- Hipni, A., El-shafie, A., Najah, A., Karim, O. A., Hussain, A., & Mukhlisin, M. (2013). Daily forecasting of dam water levels: comparing a support vector machine (SVM) model with adaptive neuro fuzzy inference system (ANFIS). *Water resources management*, 27, 3803-3823. Doi: [10.1007/s11269-013-0382-4](https://doi.org/10.1007/s11269-013-0382-4)
- Yalcin, E. (2024). A CMIP6 multi-model ensemble-based analysis of potential climate change impacts on irrigation water demand and supply using SWAT and CROPWAT models: a case study of Akmeşe Dam, Turkey. *Theoretical and Applied Climatology*, 155(1), 679-699. Doi: [10.1007/s00704-023-04657-0](https://doi.org/10.1007/s00704-023-04657-0)
- Feizi, H., Apaydin, H., Sattari, M. T., Colak, M. S., & Sibtain, M. (2022). Improving reservoir inflow prediction via rolling window and deep learning-based multi-model approach: case study from Ermenek Dam, Turkey. *Stochastic Environmental Research and Risk Assessment*, 36(10), 3149-3169. Doi: <https://doi.org/10.1007/s00477-022-02185-3>
- Fujihara, Y., Tanaka, K., Watanabe, T., Nagano, T., & Kojiri, T. (2008). Assessing the impacts of climate change on the water resources of the Seyhan River Basin in Turkey: Use of dynamically downscaled data for hydrologic simulations. *Journal of Hydrology*, 353(1-2), 33-48. Doi: [10.1016/j.jhydrol.2008.01.024](https://doi.org/10.1016/j.jhydrol.2008.01.024).
- Salam, Z. K. A. A., & Keskin, M. E. (2018). Yapay Sinir Ağları İle Dibi Barajı'nın Seviye Tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 6(4), 564-569. Doi: [10.21923/jesd.423611](https://doi.org/10.21923/jesd.423611)
- Ouma, Y. O., Moalafhi, D. B., Anderson, G., Nkwae, B., Odirile, P., Parida, B. P., & Qi, J. (2022). Dam water level prediction using vector autoregression, random forest regression and MLP-ANN models based on land-use and climate factors. *Sustainability*, 14(22), 14934. Doi: [10.3390/su142214934](https://doi.org/10.3390/su142214934)
- Akiner, M. E., & Akkoyunlu, A. (2012). Modeling and forecasting river flow rate from the Melen Watershed, Turkey. *Journal of Hydrology*, 456, 121-129. Doi: [10.1016/j.jhydrol.2012.06.031](https://doi.org/10.1016/j.jhydrol.2012.06.031).
- Bulut, M. (2021). Hydroelectric generation forecasting with long short term memory (LSTM) based deep learning model for turkey. *arXiv preprint arXiv:2109.09013*. Doi: [10.48550/arXiv.2109.09013](https://doi.org/10.48550/arXiv.2109.09013)
- Lalwani, P., Ganeshan, R. A Novel CNN-BiLSTM-GRU Hybrid Deep Learning Model for Human Activity Recognition. *Int J Comput Intell Syst* 17, 278 (2024). Doi: [10.1007/s44196-024-00689-0](https://doi.org/10.1007/s44196-024-00689-0)
- Bibi, I., Akhunzada, A., Malik, J., Iqbal, J., Musaddiq, A., & Kim, S. (2020). A dynamic DL-driven architecture to combat sophisticated Android malware. *IEEE Access*, 8, 129600-129612. Doi: [10.1109/ACCESS.2020.3009819](https://doi.org/10.1109/ACCESS.2020.3009819)
- Lara-Benítez, P., Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2020). Asynchronous dual-pipeline deep learning framework for online data stream classification. *Integrated Computer-Aided Engineering*, 27(2), 101-119. Doi: [10.3233/ICA-200617](https://doi.org/10.3233/ICA-200617)
- Xu, Z., Shu, Q. and Ye, Y. (2024) “Research on Momentum prediction algorithm for athletes based on the CNN-LSTM Model”, *Transactions on Computer Science and Intelligent Systems Research*, 6, pp. 212–220. Doi: [10.62051/mx0t8r76](https://doi.org/10.62051/mx0t8r76).
- Bai, X., Zhang, L., Feng, Y., Yan, H., & Mi, Q. (2025). Multivariate temperature prediction model based on CNN-BiLSTM and RandomForest. *The Journal of Supercomputing*, 81(1), 162. Doi: [10.1007/s11227-024-06689-3](https://doi.org/10.1007/s11227-024-06689-3)

- Baymurzina, D., Golikov, E., & Burtsev, M. (2022). A review of neural architecture search. *Neurocomputing*, 474, 82-93. Doi: <https://doi.org/10.1016/j.neucom.2021.12.014>.
- Liu, S., Zhang, H., & Jin, Y. (2022). A survey on computationally efficient neural architecture search. *Journal of Automation and Intelligence*, 1(1), 100002. Doi: <https://doi.org/10.1016/j.jai.2022.100002>
- Jaafra, Y., Laurent, J. L., Deruyver, A., & Naceur, M. S. (2019). Reinforcement learning for neural architecture search: A review. *Image and Vision Computing*, 89, 57-66. Doi: <https://doi.org/10.1016/j.imavis.2019.06.005>.
- Zhang, T., Lei, C., Zhang, Z., Meng, X. B., & Chen, C. P. (2021). AS-NAS: Adaptive scalable neural architecture search with reinforced evolutionary algorithm for deep learning. *IEEE Transactions on Evolutionary Computation*, 25(5), 830-841. Doi: [10.1109/TEVC.2021.3061466](https://doi.org/10.1109/TEVC.2021.3061466)
- Gong, C., Jiang, Z., Wang, D., Lin, Y., Liu, Q., & Pan, D. Z. (2019, November). Mixed precision neural architecture search for energy efficient deep learning. In *2019 IEEE/ACM International Conference on Computer-Aided Design (ICCAD)* (pp. 1-7). IEEE. Doi: [10.1109/ICCAD45719.2019.8942147](https://doi.org/10.1109/ICCAD45719.2019.8942147)
- S. Karagiannakos, "Neural Architecture Search (NAS): Basic principles and different approaches," *The AI Summer*, Jan. 27, 2022. [Online]. Available: <https://theaisummer.com/neural-architecture-search/>. [Accessed: Mar. 23, 2025].
- Long, K., Zhao, H., Shao, Z., Cao, Y., Geng, Y., Sun, Y., ... & Yu, H. (2023). Deep neural network with embedding fusion for Chinese named entity recognition. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 22(3), 1-16. Doi: <https://doi.org/10.1145/3570328>
- Gupta, V. K., Lalwani, S. K., Bhati, G. S., & Prakash, S. (2024). Bayesian Optimization Based Neural Architecture Search for Classification of Gases/Odors Mixtures. *IEEE Sensors Journal*, 24(5), 7119-7125. Doi: [10.1109/JSEN.2024.3349862](https://doi.org/10.1109/JSEN.2024.3349862)
- Ma, L., Li, N., Yu, G., Geng, X., Cheng, S., Wang, X., ... & Jin, Y. (2023). Pareto-wise ranking classifier for multiobjective evolutionary neural architecture search. *IEEE Transactions on Evolutionary Computation*, 28(3), 570-581. Doi: [10.1109/TEVC.2023.3314766](https://doi.org/10.1109/TEVC.2023.3314766)
- Ma, L., Kang, H., Yu, G., Li, Q., & He, Q. (2024). Single-domain generalized predictor for neural architecture search system. *IEEE Transactions on Computers*. Doi: [10.1109/TC.2024.3365949](https://doi.org/10.1109/TC.2024.3365949)
- Altunkaynak, A. (2007). Forecasting surface water level fluctuations of Lake Van by artificial neural networks. *Water resources management*, 21, 399-408. Doi: <https://doi.org/10.1007/s11269-006-9022-6>
- Katipoğlu, O. M., Mohammadi, B., & Keblouti, M. (2024). Bee-inspired insights: Unleashing the potential of artificial bee colony optimized hybrid neural networks for enhanced groundwater level time series prediction. *Environmental Monitoring and Assessment*, 196(8), 724. Doi: <https://doi.org/10.1007/s10661-024-12838-1>
- Azad, A. S., Sokkalingam, R., Daud, H., Adhikary, S. K., Khurshid, H., Mazlan, S. N. A., & Rabbani, M. B. A. (2022). Water level prediction through hybrid SARIMA and ANN models based on time series analysis: Red hills reservoir case study. *Sustainability*, 14(3), 1843. Doi: <https://doi.org/10.3390/su14031843>

- Haznedar, B., & Kilinc, H. C. (2022). A hybrid ANFIS-GA approach for estimation of hydrological time series. *Water resources management*, 36(12), 4819-4842. Doi: <https://doi.org/10.1007/s11269-022-03280-4>
- Kilinc, H. C., Apak, S., Ozkan, F., Ergin, M. E., & Yurtsever, A. (2024). Multimodal Fusion of optimized GRU–LSTM with self-attention layer for Hydrological Time Series forecasting. *Water Resources Management*, 38(15), 6045-6062. Doi: <https://doi.org/10.1007/s11269-024-03943-4>
- Tao, H., Al-Bedry, N. K., Khedher, K. M., Shahid, S., & Yaseen, Z. M. (2021). River water level prediction in coastal catchment using hybridized relevance vector machine model with improved grasshopper optimization. *Journal of Hydrology*, 598, 126477. DOI: <https://doi.org/10.1016/j.jhydrol.2021.126477>



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Ahmet Enes YEĞİN
Eğitim	
Lise:	Necip Fazıl Kısakürek Anadolu Lisesi (2017)
Lisans:	Fırat Üniversitesi, Mühendislik Fakültesi Yazılım Mühendisliği (2022)
Yüksek lisans:	Atatürk Üniversitesi, Yazılım Mühendisliği
Yabancı Dil Bilgisi	
Tezden Üretilmiş Yayınlar	
1. Yegin, A. E., & Karcioğlu, A. A. (2025). Dam water levels prediction using advanced hybrid deep learning model based on Bayesian Optimization approach. <i>Egyptian Informatics Journal</i>, 31, 100760. 2. Yegin, A. E., & Karcioğlu, A. A. (2025, May). Dam Water Levels Prediction Using Different Time Series Models for Yusufeli and Deriner Dams. In <i>2025 7th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA)</i> (pp. 1-9). IEEE.	