

**T.C.
KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK
ANABİLİM DALI**

**YAPAY ZEKÂ TEKNİKLERİ İLE YERALTI SU
SEVİYESİNİN ZAMAN SERİSİ TAHMİNİ**

**Hazırlayan
Ramazan ŞENTÜRK**

**Danışman
Doç. Dr. Rifat KURBAN**

Yüksek Lisans Tezi

Eylül 2024, KAYSERİ

T.C.
KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK
ANABİLİM DALI

YAPAY ZEKÂ TEKNİKLERİ İLE YERALTI SU
SEVİYESİNİN ZAMAN SERİSİ TAHMİNİ
(Yüksek Lisans Tezi)

Hazırlayan
Ramazan ŞENTÜRK

Danışman
Doç. Dr. Rifat KURBAN

Bu çalışma, TÜBİTAK tarafından 2210-D proje kodu ile desteklenmektedir.

Eylül 2024, KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Ramazan ŞENTÜRK



T.C.

KAYSERİ ÜNİVERSİTESİ**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

Anabilim Dalı : Hesaplamalı Bilimler ve Mühendislik

Program Adı : Yüksek Lisans

Tez Başlığı : Yapay Zekâ Teknikleri ile Yeraltı Su Seviyesinin Zaman Serisi Tahmini

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 58 sayfalık kısmına ilişkin 27.07.2024 tarihinde Turnitin intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı: %0'dır.

Uygulanan filtrelemeler:

- 1- Giriş dâhil
- 2- Ana Bölümler dâhil
- 3- Sonuç dâhil
- 4- Alıntılar dâhil
- 5- Kapak hariç
- 6- Önsöz ve Teşekkür hariç
- 7- İçindekiler hariç
- 8- Kaynakça hariç
- 9- Özet hariç
- 10- Yedi (7) kelimedenden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 29.07.2024

Danışman: Doç. Dr. Rifat KURBAN

Öğrenci: Ramazan ŞENTÜRK

YÖNERGEYE UYGUNLUK

" Yapay Zekâ Teknikleri ile Yeraltı Su Seviyesinin Zaman Serisi Tahmini " adlı yüksek lisans tezi, Kayseri Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Hazırlayan

Ramazan ŞENTÜRK

Danışman

Doç. Dr. Rifat KURBAN

Hesaplamalı Bilimler ve Mühendislik ABD Başkanı

Prof. Dr. Ercan KARAKÖSE

KABUL VE ONAY TUTANAĞI

Doç. Dr. Rifat KURBAN danışmanlığında Ramazan ŞENTÜRK tarafından hazırlanan “Yapay Zekâ Teknikleri ile Yeraltı Su Seviyesinin Zaman Serisi Tahmini” adlı bu çalışma jürimiz tarafından Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Hesaplamalı Bilimler ve Mühendislik Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

23 /08/ 2024

JÜRİ:

Danışman	: Doç. Dr. Rifat KURBAN	İmza
Üye	: Prof. Dr. Ercan KARAKÖSE	İmza
Üye	: Dr. Öğr. Üyesi Murat TAŞYÜREK	İmza

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun tarih ve sayılı kararı ile onaylanmıştır.

..... / /

Doç. Dr. Ahmet Terzi

Enstitü Müdürü

ÖNSÖZ / TEŞEKKÜR

Öncelikle danışmanlığımı üstlenen, konu seçiminden çalışmanın yürütülmesine dek tecrübeleriyle tezi yönlendiren, tezin tamamlanması için yoğun destek veren sayın Doç. Dr. Rifat KURBAN'a, katkılarından ve desteklerinden dolayı çok teşekkür ederim.

Yüksek lisans eğitimim boyunca pozitif yaklaşımlarıyla bana akademik yolda yürüme şevki kazandıran, her konuda beni sabırla dinleyen ve destekleyen değerli eşim Sema AVCI ŞENTÜRK'e, tezin fikir sürecinde çok değerli vaktini bana ayırarak dikkat etmem gereken noktalarda kıymetli bilgilerini paylaştan Envest Enerji genel müdürü sayın Ahmet KÜTÜK'e, bu süreçte desteklerini esirgemeyen ortaklarım sayın Kadir Emre KIŞ, Necmettin KÜTÜK, İbrahim ÖZDİN ve Fatih KÜTÜK'e teşekkür ederim.

Tezime 2210-D proje kodu ile maddi destek veren TÜBİTAK'a teşekkür ederim.

Hayatım boyunca beni her zaman ve her konuda destekleyen, haklarını asla ödeyemeyeceğim canım annem, canım babam ve kardeşlerime, ayrıca bu süreçte birlikte vakit geçirdiğimiz tüm Teknik Bilimler Meslek Yüksek Okulu idari ve akademik personeline teşekkür ederim.

Ramazan ŞENTÜRK, Kayseri, 2024

YAPAY ZEKÂ TEKNİKLERİ İLE YERALTI SU SEVİYESİNİN ZAMAN SERİSİ TAHMİNİ

Ramazan ŞENTÜRK

Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü

Yüksek Lisans Tezi, Eylül 2024

Danışman: Doç. Dr. Rifat KURBAN

ÖZET

Yeraltı suyu kaynaklarının etkin yönetimi kritik öneme sahiptir ve son araştırmalar, yeraltı suyu seviyelerindeki düşüşlerin yeraltı suyu hidrolojisi üzerindeki etkisini vurgulayarak sürdürülebilir uygulamaların gerekliliğini ortaya koymaktadır. Bu tez çalışmasında, yapay zeka teknikleri kullanılarak yeraltı suyu seviyesinin zaman serileri tahmini gerçekleştirilmiştir. Kaggle'dan elde edilen AquiferAuser veri seti kullanılarak, beş farklı kuyunun yeraltı suyu seviyeleri analiz edilmiş ve tahminlerde bulunulmuştur. Çalışma kapsamında NAR-NN ve LSTM gibi yapay sinir ağı algoritmaları kullanılmış ve performansları RMSE değerleri üzerinden karşılaştırılmıştır. Sinir ağıları farklı eğitim algoritmaları ve parametrelerle test edilerek en uygun konfigürasyonlar belirlenmiştir. Zaman gecikmesi artarken NAR-NN performansı iyileşmiş ve LSTM performansı düşmüştür. NAR-NN modeli için Bayesian Regularization geri yayılım (trainbr) algoritması, Levenberg-Marquardt geri yayılım (trainlm) algoritmasına göre daha iyi sonuçlar sağlamıştır. LSTM modeli için ise, rmsprop eğitim algoritması adam algoritmasından daha başarılı bulunmuştur. NAR-NN modeli LSTM modeline kıyasla daha düşük RMSE değerleri elde ederek daha yüksek tahmin doğruluğu sergilemiştir. Bu durum, NAR-NN modelinin zaman serilerindeki karmaşık ve doğrusal olmayan ilişkileri daha etkin bir şekilde modelleme yeteneğine bağlanabilir.

Bu çalışma, yapay zeka modellerinin su yönetiminde önemli bir rol oynayabileceğini ve doğru model seçimi ile optimizasyonun bu süreçte kritik olduğunu göstermektedir. Yapay zeka modellerinin doğru tahminler yapabilmesi, su kaynaklarının daha verimli ve sürdürülebilir bir şekilde yönetilmesine katkı sağlayacaktır.

Anahtar Kelimeler: Yeraltı su seviyesi tahmini, Yapay sinir ağı, Doğrusal olmayan otoregresif sinir ağı, Uzun kısa süreli bellek

TIME SERIES PREDICTION OF GROUNDWATER LEVEL WITH ARTIFICIAL INTELLIGENCE TECHNIQUES

Ramazan ŞENTÜRK

Kayseri University, Institute of Graduate Education

M.Sc. Thesis, September 2024

Supervisor: Assoc. Prof. Dr. Rifat KURBAN

ABSTRACT

Effective management of groundwater resources is critical and recent research has highlighted the impact of declining groundwater levels on groundwater hydrology, highlighting the need for sustainable practices. In this thesis, groundwater level time series forecasting is performed using artificial intelligence techniques. Using the AquiferAuser dataset obtained from Kaggle, groundwater levels of five different wells were analyzed and predictions were made. Neural network algorithms such as NAR-NN and LSTM were used in the study and their performances were compared based on RMSE values. The neural networks were tested with different training algorithms and parameters to determine the optimal configurations. As the time delay increases, NAR-NN performance improves and LSTM performance decreases. For the NAR-NN model, the Bayesian Regularization backpropagation (trainbr) algorithm provided better results than the Levenberg-Marquardt backpropagation (trainlm) algorithm. For the LSTM model, the rmsprop training algorithm was found to be more successful than the man algorithm. The NAR-NN model exhibited higher prediction accuracy with lower RMSE values compared to the LSTM model. This can be attributed to the ability of the NAR-NN model to model complex and nonlinear relationships in time series more effectively.

This study shows that AI models can play an important role in water management and that proper model selection and optimization are critical in this process. The ability of artificial intelligence models to make accurate predictions will contribute to a more efficient and sustainable management of water resources.

Keywords: Groundwater level prediction, Artificial neural network, Nonlinear autoregressive neural network, Long short-term memory

İÇİNDEKİLER

YAPAY ZEKÂ TEKNİKLERİ İLE YERALTI SU SEVİYESİNİN ZAMAN SERİSİ TAHMİNİ

BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY TUTANAĞI.....	iv
ÖNSÖZ / TEŞEKKÜR	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ.....	xii
GİRİŞ	1

BİRİNCİ BÖLÜM

YERALTI SUYU VE ÖNEMİ

1.1	Yeraltı Suyu	2
1.2	Yeraltı Suyu Oluşumu ve Kaynakları	5
1.3	Yeraltı Suyunun Bilinçsiz Kullanımı ve Etkileri	7
1.4	Yeraltı Suyu ve İklim Değişikliği İlişkisi	7
1.5	Yeraltı Suyunun Korunması ve Sürdürülebilir Yönetimi	10
1.6	Yeraltı Suyu Verilerin Kaydedilmesi.....	13
1.7	Yeraltı Suyu Verilerini Kullanarak Tahminleme Çalışmaları	15

İKİNCİ BÖLÜM

MATERYAL VE METOD

2.1	Veri Seti ve Çalışma Alanı.....	17
2.2	Yöntemler.....	20
2.2.1	Yapay Sinir Ağları (YSA).....	20
2.2.2	Doğrusal Olmayan Otoregresif Sinir Ağı (NAR-NN)	25
2.2.3	Geri Yayılım (Backpropagation) Algoritması	25
2.2.4	Levenberg-Marquardt Geri Yayılım Algoritması	26
2.2.5	Bayesian Regülasyon Geri Yayılım Algoritması.....	26
2.2.6	Uzun Kısa Süreli Bellek (LSTM)	29

2.2.7	Kök-Ortalama-Kare Yayılmı (RMSprop) Algoritması.....	31
2.2.8	Uyarlanabilir Moment Tahmini (Adam) Algoritması.....	31
2.3	Ortalama Karekök Hatası (RMSE)	32

ÜÇÜNCÜ BÖLÜM

DENEYLER

3.1	Simülasyon Çalışma Düzenegi	33
3.2	Sayısal Sonuçlar	33
3.3	Grafiksel Sonuçlar.....	48

DÖRDÜNCÜ BÖLÜM

SONUÇ VE TARTIŞMA

KAYNAKLAR.....	65
İNTİHAL RAPORU	79
ÖZGEÇMİŞ.....	81

TABLOLARIN LİSTESİ

Tablo 2.1. Aquifer Veri Setinden Alınan Verilerin Özellikleri.....	18
Tablo 3.1. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.....	33
Tablo 3.2. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.....	34
Tablo 3.3. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.	34
Tablo 3.4. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.	34
Tablo 3.5. LT2 Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.	35
Tablo 3.6. LT2 Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.	35
Tablo 3.7. LT2 Kuyusu LSTM rmsprop algoritması ve $t=1$ için RMSE sonuçları.....	35
Tablo 3.8. LT2 Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.....	36
Tablo 3.9. LT2 Kuyusu NAR-NN ve LSTM RMSE sonuçları.....	36
Tablo 3.10. SAL Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları..	36
Tablo 3.11. SAL Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları..	37
Tablo 3.12. SAL Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları...	37
Tablo 3.13. SAL Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları...	37
Tablo 3.14. SAL Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.....	38
Tablo 3.15. SAL Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.....	38
Tablo 3.16. SAL Kuyusu LSTM rmsprop algoritması ve $t=1$ için RMSE sonuçları.	38
Tablo 3.17. SAL Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.	39
Tablo 3.18. SAL Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.	39
Tablo 3.19. PAG Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.	39
Tablo 3.20. PAG Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.	40
Tablo 3.21. PAG Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları. .	40
Tablo 3.22. PAG Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları. .	40
Tablo 3.23. PAG Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.	41
Tablo 3.24. PAG Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.	41

Tablo 3.25. PAG Kuyusu LSTM rsmprop algoritması ve $t=1$ için RMSE sonuçları.....	41
Tablo 3.26. PAG Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.....	42
Tablo 3.27. PAG Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.....	42
Tablo 3.28. CoS Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları...	42
Tablo 3.29. CoS Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları...	43
Tablo 3.30. CoS Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları. ..	43
Tablo 3.31. CoS Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları. ..	43
Tablo 3.32. CoS Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.	44
Tablo 3.33. CoS Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.	44
Tablo 3.34. CoS Kuyusu LSTM rsmprop algoritması ve $t=1$ için RMSE sonuçları.....	44
Tablo 3.35. CoS Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.....	45
Tablo 3.36. CoS Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.....	45
Tablo 3.37. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.	45
Tablo 3.38. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.	46
Tablo 3.39. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.	46
Tablo 3.40. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.	46
Tablo 3.41. DIEC Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.....	47
Tablo 3.42. DIEC Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.....	47
Tablo 3.43. DIEC Kuyusu LSTM rsmprop algoritması ve $t=1$ için RMSE sonuçları. ..	47
Tablo 3.44. DIEC Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları. ..	48
Tablo 3.45. DIEC Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.	48

ŞEKİLLERİN LİSTESİ

Şekil 1.1. Su Döngüsünün Aşamaları (Su Döngüsü, 2024).....	2
Şekil 1.2. Ekolojik Döngü.....	4
Şekil 1.3. Akifer Yapısı	5
Şekil.1.4. İyonların Hareketlerini ve Kimyasal Reaksiyonlarını Etkileyen Süreçleri İçeren Hidrojeokimyasal Döngü Diyagramı	6
Şekil 1.5. Bilinçsiz Yeraltı Suyu Kullanımı Sonucu Konya’da Oluşan Obruklar	8
Şekil 1.6. İklim Değişikliğinin Su Kaynaklarına Etkisi.....	10
Şekil 1.7. Birleşmiş Milletler ’in 2030 Sürdürülebilir Kalkınma Hedefleri (Sürdürülebilir Kalkınma Hedefleri, 2024)	13
Şekil 2.1. Aquifer Veri Setinden Alınan LT2 Kuyusunun İşlenmemiş Verisi	18
Şekil 2.2. Aquifer Veri Setinden Alınan SAL Kuyusunun İşlenmemiş Verisi.....	18
Şekil 2.3. Aquifer Veri Setinden Alınan PAG Kuyusunun İşlenmemiş Verisi	19
Şekil 2.4. Aquifer Veri Setinden Alınan CoS Kuyusunun İşlenmemiş Verisi	19
Şekil 2.5. Aquifer Veri Setinden Alınan DIEC Kuyusunun İşlenmemiş Verisi.....	19
Şekil 2.6. Sinir Ağı Operasyonel Çerçevesi.....	20
Şekil 2.7. Yapay bir nöron modeli	21
Şekil 2.8. Sığ sinir ağı nöron modeli	23
Şekil 2.9. İleri beslemeli çok katmanlı sinir ağı nörom modeli	24
Şekil 2.10. NAR-NN Ağı çalışma diyagramı	25
Şekil 2.11. LSTM Mimarisi	30
Şekil 3.1. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	48
Şekil 3.2. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	49
Şekil 3.3. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	49

Şekil 3.4. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	50
Şekil 3.5. LT2 Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	50
Şekil 3.6. LT2 Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	50
Şekil 3.7. LT2 Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	51
Şekil 3.8. LT2Kuyusu LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	51
Şekil 3.9. SAL Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	51
Şekil 3.10. SAL Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	52
Şekil 3.11. SAL Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	52
Şekil 3.12. SAL Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	52
Şekil 3.13. SAL Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	53
Şekil 3.14. SAL Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	53
Şekil 3.15. SAL Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	53
Şekil 3.16. SAL Kuyusu LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	54
Şekil 3.17. PAG Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	54

Şekil 3.18. PAG Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	54
Şekil 3.19. PAG Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	55
Şekil 3.20. PAG Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	55
Şekil 3.21. PAG Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	55
Şekil 3.22. PAG Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	56
Şekil 3.23. PAG Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	56
Şekil 3.24. PAG LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	56
Şekil 3.25. COS Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	57
Şekil 3.26. COS Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	57
Şekil 3.27. COS Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	57
Şekil 3.28. COS Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	58
Şekil 3.29. COS Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	58
Şekil 3.30. COS Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	58
Şekil 3.31. COS Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	59

Şekil 3.32. COS LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	59
Şekil 3.33. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	59
Şekil 3.34. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	60
Şekil 3.35. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	60
Şekil 3.36. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	60
Şekil 3.37. DIEC Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	61
Şekil 3.38. DIEC Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	61
Şekil 3.39. DIEC Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.	61
Şekil 3.40. DIEC LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.	62

GİRİŞ

Su temin ve dağıtım sistemlerinin sürdürülebilir yönetimi, günümüzün su kaynakları yönetimi alanında önemli bir konudur. Özellikle yeraltı suyu seviyelerindeki düşüşler ve iklim değişikliği gibi faktörler, su kaynaklarının etkin ve verimli bir şekilde yönetilmesi gerekliliğini vurgulamaktadır. Bu bağlamda, zaman serileri tahmini, su kaynaklarının gelecekteki durumunu öngörerek su yönetimi stratejilerinin optimize edilmesine yardımcı olabilir. Bu tez çalışması, yapay zekâ teknikleri kullanarak yeraltı suyu seviyesinin zaman serileri ile tahminini ele almaktadır.

Günümüzde yapay zekâ ve makine öğrenimi algoritmaları, karmaşık ve büyük veri kümelerini analiz ederek anlamlı sonuçlar çıkarma konusunda oldukça başarılıdır. Su temin ve dağıtım sistemlerinde zaman serileri tahmini için kullanılan yapay sinir ağları ve uzun kısa süreli bellek (LSTM) modelleri, su seviyelerinin ve su talebinin gelecekteki değerlerini öngörmeye etkili araçlar olarak öne çıkmaktadır. Bu tezde, farklı yapay sinir ağı algoritmaları kullanılarak su temin ve dağıtım sistemlerindeki yeraltı suyu seviyelerinin tahmini yapılmış ve bu algoritmaların performansları karşılaştırılmıştır.

Bu çalışmada, Kaggle'dan elde edilen AquiferAuser veri seti kullanılarak beş farklı kuyunun yeraltı suyu seviyeleri analiz edilmiş ve tahminlerde bulunulmuştur. NAR-NN ve LSTM gibi yapay sinir ağı algoritmaları kullanılarak elde edilen sonuçlar, tahminlerin doğruluğunu artırmak için farklı eğitim algoritmaları ve parametrelerle test edilmiştir. Elde edilen bulgular, yapay zekâ modellerinin su yönetiminde önemli bir rol oynayabileceğini ve doğru model seçimi ile optimizasyonun bu süreçte kritik olduğunu göstermektedir. Bu tez, yapay zekâ tekniklerinin su temin ve dağıtım sistemlerinde etkin bir şekilde kullanılabileceğini ve bu alandaki çalışmaların su kaynaklarının daha verimli ve sürdürülebilir yönetimine katkı sağlayacağını vurgulamaktadır.

BİRİNCİ BÖLÜM

YERALTI SUYU VE ÖNEMİ

1.1 Yeraltı Suyu

Yeraltı suyu, özellikle su kıtlığı yaşanan ve geniş yeraltı su sistemlerine sahip bölgelerde, tamamlayıcı su kaynağı olarak işlev gören önemli bir kaynaktır (Wada vd., 2010). Yeraltı suyu kaynaklarının etkin yönetimi esastır ve son araştırmalar yeraltı suyu seviyelerindeki düşüşler, yeraltı suyu hidrolojisi üzerindeki etkisini vurgulayarak sürdürülebilir uygulamaların gerekliliğinin altını çizmiştir (Smerdon vd., 2009). Ayrıca, yeraltı suyu olanaklarının, zorluklarının ve potansiyel çözüm yollarının ilerlemesinde zamanın önemi görsel olarak ortaya konmuş ve yeraltı suyu sosyo-ekolojisinin incelikli bir şekilde anlaşılması gerekliliği vurgulanmıştır (Giordano, 2009). Şekil 1.1’de ekolojik su döngüsünün aşamaları gösterilmiştir. (*Su Döngüsü*, 2024)

Şekil 1.1. Su Döngüsünün Aşamaları



Hidrolojik döngünün önemli bir unsuru olan yeraltı suyu, özellikle su kıtlığı yaşanan ve geniş akifer sistemlerine sahip bölgelerde su kaynaklarının korunmasında çok önemli bir işleve sahiptir. Son zamanlarda yapılan çalışmalar, karmaşık arazilerde yeraltı suyu bağlantısının ve besin akışlarının yönetimi ve anlaşılmasına odaklanmıştır. Bu çalışmalar, bu süreçleri kavramsallaştırmak için modern jeofizik tekniklerin kullanılmasının gerekliliğini vurgulamaktadır. Ayrıca, antroposen çağında dünya çapındaki yeraltı suyu kaynaklarının uzun vadeli yaşayabilirliği ve yönetiminin incelenmesi, doğal kaynakların yönetimi ile dünya sistemlerinin bilimsel çalışması arasındaki karmaşık ilişkiyi vurgulayarak çoklu bakış açılarından analiz edilmiştir.

Yeraltı suyu, özellikle sulu tarımda olmak üzere kentsel su temini ve kırsal geçim kaynaklarının korunmasında kritik bir role sahip olan temel ve önemli bir doğal kaynaktır (Foster & Chilton, 2003). Yeraltı suyunun ekolojik önemi, özellikle ekolojik açıdan büyük ilgi çeken yeraltı suyu ve nehir suyu arasındaki etkileşimler açısından çevre üzerindeki etkisinde yatmaktadır (X vd., 2012). Ayrıca, petrolden etkilenen yerlerde arsenik gibi kirleticilerin yeraltı sularına deşarj edilmesi, yeraltı suyu rezervlerinin bütünlüğü konusunda endişelere yol açmıştır (Cozzarelli vd., 2015).

Ayrıca, yeraltı suyuna bağımlı olan bitki örtüsünün refahı yeraltı suyu sistemiyle yakından bağlantılıdır ve bu da çevresel kaynak yönetimi için yeraltı suyunun etkin bir şekilde yönetilmesinin önemini vurgulamaktadır (Eamus vd., 2006). Yeraltı suyu biyoçeşitliliğinin korunması, ekolojik dengenin sürdürülebilmesi için değerlendirilmesi ve korunmasına yönelik araştırmalar gerektiren temel bir özelliktir (Gibert & Culver, 2009). Buna ek olarak, yirmi yıllık bir süre zarfında yapılan bibliyometrik bir araştırma, yeraltı suyu araştırmalarının dünya çapındaki durumu hakkında faydalı bilgiler sağlamış ve yeraltı suyu üzerine yapılan çalışmaların geniş yelpazesini ve önemini vurgulamıştır (Niu vd., 2014).

Nemli iklim, su tablası derinliği ve yeraltı suyu şarj dinamikleri arasındaki bağlantı araştırılmış, iklim ve arazi kullanımının yeraltı suyu şarjı üzerindeki karmaşık etkisi ortaya çıkarılmıştır (Smerdon vd., 2008). Ayrıca, kıyı akiferlerinde deniz suyu girişi üzerindeki akış yönüne bağlı dağılımın pratik sonuçları, kıyı bölgelerindeki yeraltı suyu yönetimi için önemli sonuçlar doğurmaktadır (Fahs vd., 2022). Buna ek olarak, araştırmacılar yeraltı suyundaki sülfatın kaynağını ve dağılımını araştırarak belirli

akiferlerdeki suyun kalitesini etkileyen kimyasal süreçler hakkında bilgi sağlamıştır (Long vd., 2021).

Çalışma, yeraltı suyunun kullanımını ve bunun taşkın kontrolü ve su kaynakları yönetimi açısından sonuçlarını incelemiş, belirli alanlarda yeraltı suyuna alternatif olarak yüzey suyu kullanma olasılığını vurgulamıştır (Purnawan vd., 2022). Bununla birlikte, küresel yeraltı suyu sürdürülebilirliği zorlu bir görev olmaya devam etmekte ve yeraltı suyunun yönetimi için kapsamlı ve sürdürülebilir bir strateji gerektirmektedir (Gleeson, 2020). Qi ve arkadaşları (2021) tarafından yürütülen bir çalışmada, tuzlanmadan etkilenen yerlerdeki yeraltı sularının ekolojik eşiği incelenmiştir. Bu çalışmanın amacı, yeraltı suyu ile ilgili araştırmaları geliştirmek ve su kaynakları planlarının oluşturulması için değerli bilgiler sağlamaktır (Qi vd., 2021).

Şekil 1.2’de, Fotor yapay zeka aracı ile oluşturulan görselde, yeraltı suyu araştırmaları ekoloji, çevre ve sürdürülebilirlik gibi çeşitli yönleri vurgulanmaya çalışılmıştır. Bu araştırma, insan faaliyetleri, arazi kullanımı ve yeraltı suyu dinamiklerini etkileyen doğal süreçler arasındaki karmaşık ilişkiyi araştırmaktadır. Yeraltı sularının sürdürülebilir yönetimi, tarım, kentsel kaynaklar ve ekolojik denge gibi çeşitli sektörler için kritik bir kaynak olması nedeniyle şimdiki ve gelecek nesiller için çok önemlidir.


Şekil 1.2. *Ekolojik Döngü*



1.2 Yeraltı Suyu Oluşumu ve Kaynakları

Önemli ve vazgeçilmez bir doğal kaynak olan yeraltı suyu, çok sayıda süreçle yaratılır ve çok sayıda engelle karşılaşır. Yeraltı suyunun yeniden doldurulması, yeraltı suyunun yaratılmasında çok önemli bir bileşendir (Vries & Simmers, 2002). Bu süreç karmaşıktır ve hidrojeokimyasal özellikler, Şekil 1.3’de görüldüğü gibi jeolojik oluşumlar ve insan faaliyetleri gibi çeşitli unsurlardan etkilenir (S. Wang vd., 2021). Sığ yeraltı sularındaki yüksek florür miktarları çoğunlukla buharlaşma konsantrasyonu, sızıntı yoluyla zenginleşme ve insan kaynaklı kirlilik gibi mekanizmalardan kaynaklanmaktadır (Gao vd., 2020). Ayrıca, iklim değişikliği ve insan faaliyetlerinin yeraltı sularının yenilenmesi ve hidrolojik süreçler üzerindeki yansımaları, yeraltı suyu kaynaklarının uzun vadeli yaşayabilirliği için bir risk oluşturmaktadır (Tolera & Chung, 2021; Wossenyeleh vd., 2020). Yeraltı suyunun oluşumunda rol oynayan mekanizmalar hakkında bilgi edinmek, bu değerli kaynağı yönetmeyi ve korumayı amaçlayan stratejilerin başarılı bir şekilde uygulanması için çok önemlidir.

Şekil 1.3. Akifer Yapısı




-  Yüksek hidrolik iletkenliğe sahip akifer
-  Düşük hidrolik iletkenliğe sahip geçirimsiz birim
-  Çok düşük hidrolik iletkenliğe sahip temel kaya
-  Yeraltı suyunun akım yönü

Buna ek olarak, yeraltı suyunun kalitesi hidrojeokimyasal özellikler, jeolojik oluşumlar ve insan faaliyetleri gibi bir dizi unsurdan etkilenir (Gao vd., 2020; S. Wang vd., 2021). Madencilik bölgelerindeki yeraltı suyunun hidrojeokimyasal özelliklerinin ve oluşum mekanizmalarının incelenmesi, jeolojik yapıların yeraltı suyunun kalitesi üzerindeki önemli etkisini vurgulayan bir örnektir (S. Wang vd., 2021). Ayrıca, sulu tarımın yeraltı suyu şarjının tuzluluğu üzerindeki etkisi, yarı kurak alanlarda önemli bir sürdürülebilirlik sorunu olarak kabul edilmiş ve bu sorunun üstesinden gelmek için kapsamlı yönetim tekniklerinin gerekliliğini vurgulamıştır (Foster vd., 2018). Bu bulgular, yeraltı suyu yaratma süreçleri ile yeraltı suyunun kalitesi arasındaki karmaşık bağlantıyı vurgulamakta ve yeraltı suyu yönetimine yönelik kapsamlı yaklaşımlara duyulan ihtiyacı ortaya koymaktadır.

Özetlemek gerekirse, yeraltı suyunun oluşumu, Şekil 1.4'deki gibi hidrojeokimyasal özellikler, jeolojik yapılar ve insan faaliyetleri de dahil olmak üzere çok sayıda faktörden etkilenen karmaşık bir süreçtir. Yüksek florür seviyeleri, tuzluluk sorunları ve iklim değişikliğinin etkisi gibi yeraltı suyu oluşumuyla ilgili zorlukları ele almak için kapsamlı araştırma ve yönetim teknikleri gereklidir. Bu önlemler, bu temel kaynağın sürdürülebilir kullanımını sağlamak için gereklidir. Yeraltı suyunun oluşumu ile ilgili mekanizmaların ve zorlukların kapsamlı bir şekilde anlaşılması, bu değerli kaynağın yönetilmesi ve korunmasına yönelik stratejilerin başarılı bir şekilde uygulanması için gereklidir.

Şekil 1.4. *İyonların Hareketlerini ve Kimyasal Reaksiyonlarını Etkileyen Süreçleri İçeren Hidrojeokimyasal Döngü Diyagramı*



1.3 Yeraltı Suyunun Bilinçsiz Kullanımı ve Etkileri

Yeraltı sularının bilinçsiz kullanımı çevre ve türler üzerinde derin etkiler yaratabilir. Tarımda bitki büyüme düzenleyicilerinin uygunsuz ve bilinçsiz kullanımı çevre için zararlı sonuçlara yol açabilir. Bu düzenleyiciler, tarımsal uygulamalar sırasında toprağa karışma ve ardından yeraltı sularına sızarak tehdit oluşturma potansiyeline sahiptir (Ismail, 2022). Buna ek olarak, kullanılmış ürünlerin yanlışlıkla çevreye atılması çevre kirliliğini artırarak kaynakların hızla tükenmesine ve kirlilik seviyelerinin yükselmesine neden olur (Achylov & Kaygin, 2022). Ayrıca, tarımda gübre ve pestisitlerin yanlışlıkla uygulanması, yeraltı sularında NO_3 , SO_4 , As, F ve U gibi bazı elementlerin seviyelerinin yükselmesine yol açan yerel kirliliklerle ilişkilendirilmiştir (Başibüyük vd., 2020; Erşahin & Bilgili, 2023).

Farkında olmadan yeraltı suyu kullanımının sonuçları, çevresel etkilerin ötesinde karar verme süreçlerine kadar uzanmaktadır. Çalışmalar, bilinçsiz bilişin bireylerin karmaşık ortamlarda davranışsal karar verme süreçlerini geliştirebileceğini ve seçimlerinden duydukları memnuniyeti artırabileceğini göstermiştir (Hu vd., 2018). Dahası, araştırmalar, bilinçsiz işlemenin, kararların sağlanan tüm bilgilerin kısa ve değerlendirici bir genel bakışına dayanabileceği durumlarda özellikle avantajlı olduğunu göstermiştir (Queen & Hess, 2010). Bununla birlikte, nanopartiküllerin yanlışlıkla emilmesi gibi zararlı sonuçlara yol açabileceğinden, bilinçsiz biliş ile bağlantılı olası tehlikeleri kabul etmek çok önemlidir. Bu durum, kentsel ve endüstriyel atıklar su ekosistemine girdiğinde ve trofik zincirler boyunca biriktiğinde ortaya çıkabilir (Zhang vd., 2022).

Sonuç olarak, yeraltı suyunun yanlışlıkla kullanılmasının çevre, tarım ve karar alma prosedürleri üzerinde kapsamlı etkileri olabilir. Bilinçsiz yeraltı suyu kullanımının olası çevresel ve sağlık sonuçlarına ilişkin bilginin artırılması ve bu etkileri hafifletmek için sürdürülebilir ve dikkatli yöntemlerin savunulması önemlidir.

1.4 Yeraltı Suyu ve İklim Değişikliği İlişkisi

Hidrolojik döngünün önemli bir unsuru olan yeraltı suları, iklim değişikliğinin etkilerine karşı savunmasızdır. İklim değişikliğinin yeraltı suyu kaynakları üzerindeki potansiyel etkilerine ilişkin artan endişe, son yıllarda önemli ölçüde dikkat çekmiştir. Çalışmalar, iklim değişikliğinin yeraltı suyu sistemlerini, yeraltı suyunun yenilenmesini değiştirmek, yeraltı su rezervuarlarının davranışını etkilemek ve su tablasının derinliğinde dalgalanmalara neden olmak gibi çeşitli mekanizmalar yoluyla etkilediğini göstermiştir

(Costantini vd., 2023; Hamidi vd., 2021; Wu vd., 2020). İklim değişikliği ile küresel mücadele ışığında, iklim değişikliği ve yeraltı suyu kaynakları arasındaki karmaşık bağlantıları anlamak çok önemlidir. Bu anlayış, su kaynaklarını yönetmek ve değişen iklime uyum sağlamak için etkili yöntemler uygulamak açısından hayati önem taşımaktadır (Landes vd., 2014; Meyer, 2017).

İklim değişikliğinin yeraltı suyu sistemleri üzerindeki etkisi büyük ilgi gören bir konudur. Çalışmalar, yeraltı suyu sistemlerinin iklim değişikliğine karşı küresel duyarlılığına ilişkin mevcut anlayışımızın sınırlı olduğunu göstermiştir. Ayrıca, yeraltı suyundan iklim sistemine olan geri bildirimlerde geniş bir çeşitlilik vardır (Cuthbert vd., 2019; Goderniaux vd., 2011). Ayrıca tahminler, artan sıcaklıkların Hindistan gibi ve ülkemizde Konya bölgelerinde yeraltı sularının tükenme hızını daha da kötüleştiğini Şekil 1.5'deki gibi obruklar oluştuğunu göstermekte ve iklim değişikliğinin yeraltı suyu rezervleri üzerindeki etkisinin kapsamlı bir değerlendirmesinin yapılmasının önemini vurgulamaktadır (Bhattarai, 2023). Ayrıca, Bangladeş'teki Rangpur bölgesi gibi kuraklığa duyarlı yerlerdeki yeraltı suyu rezervlerinin azalması, iklim değişikliği ve muson düzenleri nedeniyle yeraltı suyu seviyelerinin yer ve zaman içindeki dalgalanmasını vurgulamaktadır (Monir vd., 2022).

Şekil 1.5. Bilinçsiz Yeraltı Suyu Kullanımı Sonucu Konya'da Oluşan Obruklar



İklim değışikliđinin yeraltı suyu kaynakları üzerindeki sonuçları, su hareketinin dinamiklerinin ötesine geçerek çevre ve toplumla ilgili diđer unsurları da kapsamaktadır. Tayland'daki aşğı Chao Phraya havzasında iklim değışikliđinin tarımsal gelir üzerindeki potansiyel etkilerini incelemek için, özellikle yeraltı suyu sürdürülebilirliđi üzerindeki etkiye odaklanan bir araştırma yapılmıştır. Bu araştırma iklim değışikliđi, yeraltı suyu kaynakları ve tarımsal geçim kaynaklarının karşılıklı bağımlılıđını vurgulamaktadır (Balasubramanian & Saravanakumar, 2021; Tanachaichoksirikun vd., 2018). İklim değışikliđinin yeraltı suyu kaynakları üzerinde yarattıđı karmaşık sorunlarla etkin bir şekilde mücadele etmek için bilimsel bilgi, politika önlemleri ve toplum katılımını birleştiren kapsamlı bir yaklaşım benimsemek gerekmektedir. Bu yaklaşım, bu hayati su kaynađının uzun vadeli ve sürdürülebilir yönetimini sađlamak için çok önemlidir (Meyer, 2017).

Dünya çapında öngörülen değışikliklerin yeraltı suyu sistemlerini etkilemesi beklendiđinden, iklim değışikliđinin yeraltı suyu kaynakları üzerindeki etkileri giderek artan bir endişe konusu haline gelmiştir (Green vd., 2011). Libya, Mısır ve Sudan'daki Nubian Akiferi'nin gösterdiđi gibi, yenilenebilir yeraltı suyu kaynaklarının iklim değışikliđinin etkilerine karşı duyarlılıđının anlaşılması, verimli su kaynakları yönetimi için çok önemlidir (Döll, 2009). Bununla birlikte, iklim değışikliđi ve yeraltı suyu sistemleri arasındaki karmaşık etkileşim, yani Hindistan gibi bölgelerdeki yeraltı suyu tükenme oranlarının yoğunlaşması hala iyi anlaşılammıştır (Bhattarai, 2023; Thomas & Famiglietti, 2019).

İnsan faaliyetleri, iklim değışikliđi ve yeraltı suyu kaynakları arasındaki ilişki, gelecekteki iklim senaryoları altında Kuzey Çin Ovası'nın sulanan tarım bölgesinde yeraltı suyu seviyelerindeki insan kaynaklı değışiklikleri tahmin etme yeteneđinin yetersiz olmasının da gösterdiđi gibi, çok önemli bir çalışma alanıdır (Chen vd., 2023). Dahası, iklim kaynaklı yeraltı suyu tükenmesinin tespiti, iklimsel değışkenliđin hem doğrudan hem de dolaylı sonuçlarının etkilerini sıklıkla göz ardı ederek kısıtlanmıştır (Thomas & Famiglietti, 2019). İklim değışikliđi ve yeraltı suyu kalitesi arasında bağlantı kurmak için, karmaşık ve ölçülmesi zor etki mekanizmalarını vurgulayan dünya çapında önemli tahminler üretmek için kapsamlı veri kümeleri gereklidir (McDonough vd., 2020; S. J. Wang vd., 2021). İklim değışikliđi, Şekil 1.6'daki gibi insanlık için büyük bir küresel

endişe kaynağı olarak giderek daha fazla öne çıkmaktadır. Kuzey Tayland'da hem yüzey suyunun hem de yeraltı suyunun yenilenmesini etkilemektedir (Petpongpan vd., 2020).

Şekil 1.6. *İklim Değişikliğinin Su Kaynaklarına Etkisi*



İklim değişikliğinin yeraltı sularının uzun vadede yaşayabilirliği üzerindeki etkisi önemli ve acil bir konudur. Bu durum, Tayland'daki Yukarı Chao Phraya Nehri havzasında ve Mississippi Embayment'ta yeraltı suyu rezervlerinde beklenen azalma ile kanıtlanmaktadır (Ouyang vd., 2021; Pratoomchai vd., 2014). Ayrıca, Bangladeş'teki Rangpur bölgesi gibi kuraklığa eğilimli bölgelerdeki yeraltı suyu seviyelerinin azalması, iklim değişikliğinin yeraltı suyu kaynakları üzerinde yarattığı karmaşık zorlukların acilen ele alınması gerektiğini vurgulamaktadır (Monir vd., 2022). İklim değişikliğinin olumsuz sonuçlarını ele almak ve sürdürülebilir entegre su yönetimi stratejilerinin uygulanmasını sağlamak için etkin yönetişimin sağlanması şarttır. Bu, iklim değişikliği nedeniyle risk altında olan yeraltı suyu kaynaklarının etkin bir şekilde yönetilmesi için özellikle önemlidir (Yagbasan, 2016).

1.5 Yeraltı Suyunun Korunması ve Sürdürülebilir Yönetimi

Yeraltı sularının korunması ve uzun vadede yaşayabilirliği, bu önemli kaynağın gelecek kuşaklar için erişilebilirliğini garanti altına almak için gereklidir. Sulamaya yönelik önemli talep ve artan nüfus göz önüne alındığında, yeraltı suyu seviyelerini (YAS) doğru bir şekilde tahmin etmek için yeraltı suyu sistemlerine ilişkin kavrayışımızı geliştirmek zorunludur (Malakar vd., 2022). Bunu anlamak, yeraltı suyu kaynaklarının sürdürülebilir

yönetimi için çok önemlidir. Ayrıca, yeraltı suyunun sürdürülebilirliğini sağlamak için kapsamlı ve her şeyi kapsayan bir yapının, güvenli verim, yenilenebilirlik, tükenme veya stres gibi geleneksel kavramlara kıyasla yönetim ve yönetim için daha büyük öneme sahip olduğu vurgulanmıştır (Gleeson vd., 2022). Bu durum, birden fazla unsurun karmaşık etkileşimini göz önünde bulundurarak, yeraltı suyu kaynaklarının uzun vadeli yaşayabilirliğini sağlamak için daha kapsamlı bir stratejiye yönelik temel bir bakış açısı değişikliğinin gerekliliğini vurgulamaktadır.

Etkili yeraltı suyu yönetimi ve yönetimi, bu doğal kaynağın korunması ve uzun vadede yaşayabilirliği için elzemdir. Yeraltı sularının mülkiyeti genellikle hükümetlere aittir ve yönetimi koruma, sürdürülebilir kullanım ve herkes için suya eşit erişim sağlamayı amaçlayan politikalarla yönetilir (Aeschbach–Hertig & Gleeson, 2012). Ayrıca, koruma stratejilerinin başarılı bir şekilde yürütülmesi, yeraltı suyunun korunmasının uzun vadeli uygulanabilirliğini etkileyen yönetim bileşenlerinin ve özelliklerinin kapsamlı bir şekilde anlaşılmasını gerektirmektedir (Mirnezami vd., 2019). Bu durum, yeraltı suyu kaynaklarının uzun vadeli ve sorumlu kullanımını garanti altına almak için güçlü yönetim çerçevelerine ve düzenlemelerine duyulan ihtiyacı vurgulamaktadır. Buna ek olarak, yeraltı suyu yönetiminin inceliklerini ve sürdürülebilirlikle ilişkisini araştırmanın bir yolu olarak yeraltı suyu düzenlemelerini tasarlamak için bilim odaklı bir strateji önerilmiştir (Gleeson vd., 2022). Bu yaklaşım, yeraltı sularının korunması ve sürdürülebilirliği ile ilgili karmaşık zorlukların üstesinden gelmek için doğa ve sosyal bilimlerde uzmanlaşmış bilim insanları arasında çok disiplinli iş birliğinin gerekliliğini vurgulamaktadır.

Yeraltı suyu kaynaklarının etkin yönetimi, aşırı kullanım ve tükenmeden kaynaklanan sorunların üstesinden gelmek için çok önemlidir. Araştırmalar, menfaat sahibi bireyler tarafından yönetilen ve düzenleyici denetimle desteklenen koruma girişimlerinin uygulanmasının, aşırı yüklü akiferlerde sürdürülebilirliği sağlamak için bir araç olarak hizmet edebileceğini göstermiştir (Deines vd., 2019). Buna ek olarak, yeraltı suyu pompalamasının azaltılması ve suyun yönünün değiştirilmesi gibi insan müdahalelerinin yeraltı suyu depolamasının dengelenmesinde ve uzun vadeli sürdürülebilirliğin garanti altına alınmasındaki etkinliği kabul edilmiştir (Yang vd., 2022). Bu bulgular, sürdürülebilir yeraltı suyu yönetimini sağlamak için proaktif önlemler ve müdahaleler almanın önemini vurgulamaktadır. Özetle, bu gözlemlerin birleşimi, yeraltı suyu

kaynaklarının korunması ve sürdürülmesi için kapsamlı ve çok disiplinli bir stratejinin benimsenmesi gerekliliğini vurgulamaktadır. Bu yaklaşım, yönetim, yönetim ve ilgili tüm tarafların aktif katılımı gibi unsurları içermelidir.

Birleşmiş Milletler'in 2030 Sürdürülebilir Kalkınma Gündemi, 169 hedef ve izleme için birçok göstergenin eşlik ettiği 17 sürdürülebilir kalkınma hedeflerinden (SKH) oluşmaktadır. Bu hedefler, sürdürülebilir kalkınmanın ekonomik, çevresel ve sosyal yönlerini ele almayı amaçlamaktadır (Salvia vd., 2019). SKH'lerin gerçekleştirilmesi, çok uluslu işletmelerin katılımına bağlıdır (Zanten & Tulder, 2018). Yeraltı suyu kaynakları ve su kalitesiyle ilgili sürdürülebilir kalkınma hedeflerine ulaşılması, SKH'lerin birbirine bağımlılığını ve bunlarla mücadele etmek için kapsamlı stratejilerin gerekliliğini vurgulayan birçok yerde çok önemli bir konudur (Alexakis, 2021). Birleşmiş Milletler Genel Kurulu, 2000 yılında Milenyum Kalkınma Hedeflerinin onaylanmasından etkilenen bir dizi SKH ortaya koymuştur. Bu SKH'ler, sürdürülebilir kalkınmanın üç ayağını dengeli ve birbiriyle ilişkili bir şekilde kapsamakta ve hedeflerin kapsamlı doğasını vurgulamaktadır (Medeiros, 2020).

Yeraltı sularının korunması, Birleşmiş Milletler tarafından belirlenen hedeflere ulaşılması için elzemdir. Çiftçilerin hayvan dışkısı için çevre dostu bertaraf tesisleri inşa etme konusunda teşvik edilmemesi, yeraltı sularının korunmasının önünde önemli bir engel teşkil etmekte ve dolayısıyla Şekil 1.7'deki SKH 6: "temiz su ve sanitasyon" hedefine ulaşılmasını tehlikeye atmaktadır (Deng vd., 2022). Yeraltı suları, SKH 2 ve 6 ile uyumlu olarak ekosistemlerin sağlığının korunması, gıda güvenliğinin sağlanması ve güvenli içme suyuna erişimin sağlanmasında çok önemli bir role sahiptir (Reinecke vd., 2023). Ayrıca, yeraltı sularının kirliliğe karşı korunması ve paydaşlara yönelik eğitim ve farkındalık girişimlerinin yürütülmesi, SKH doğrudan katkıda bulunarak gelecek için çok önemli girişimlerdir (Indika vd., 2022). SKH hedeflerine başarılı bir şekilde ulaşılması, yeraltı suyunun mevcudiyeti, kalitesi ve erişilebilirliği gibi avantajlı yönlerine bağlıdır. Ancak, başarılı bir şekilde yönetilmediği takdirde, bu hususların hem toplum hem de doğal çevre üzerinde olumsuz etkileri olabilir (Petitta vd., 2023).

Sonuç olarak, yeraltı sularının korunması, özellikle temiz su ve sanitasyonun sağlanması, ekosistem refahının korunması ve sürdürülebilir su yönetiminin uygulanmasıyla ilgili olanlar olmak üzere çeşitli SKH ulaşılmasıyla yakından bağlantılıdır. SKH'lerin birbirine bağımlılığı, yeraltı sularının korunması ve sürdürülebilir kalkınmanın

desteklenmesindeki rolünün ele alınması için kapsamlı ve koordineli stratejilerin gerekliliğini vurgulamaktadır.

Şekil 1.7. Birleşmiş Milletler 'in 2030 Sürdürülebilir Kalkınma Hedefleri (Sürdürülebilir Kalkınma Hedefleri, 2024)



1.6 Yeraltı Suyu Verilerin Kaydedilmesi

Yeraltı suyu verilerinin kaydedilmesi, hidrojeolojik incelemelerin ve çevresel gözetimin önemli bir bileşenidir. Yeraltı suyu sistemlerinin çeşitli özelliklerini ve kapsamlı veri toplama gerekliliğini yansıtan yeraltı suyu verilerini gözlemlemek ve belgelemek için çok çeşitli teknikler ve metodolojiler oluşturulmuştur. Masood ve diğerleri yeraltı suyunun izlenmesine yönelik yöntemlerin kapsamlı bir incelemesini sunmaktadır. Bu yöntemleri üç ayrı kategoride sınıflandırarak, yeraltı suyu verilerini toplamak için çeşitli metodolojiler kullanmanın önemini vurgulamaktadırlar (Masood vd., 2022). Yeraltı suyu izleme, Malenda ve Penn'in Denver Havzası'ndaki ana kaya akiferlerindeki yeraltı suyu seviyelerini araştırırken örneklediği gibi, yeraltı suyu seviyelerini düzenli olarak ölçmek ve kaydetmek için tipik olarak basınç transdüserleri kullanır (Malenda & Penn, 2020). Buna ek olarak, Parvin ve arkadaşları yeraltı suyu seviyelerindeki bölgesel örüntüyü ve zamansal değişimleri incelemek için kuyu log verilerini kullanarak yeraltı suyu

dinamiklerini anlamak için uzun vadeli veri toplamanın önemini vurgulamıştır (Parvin vd., 2011).

Doğru su seviyesi ölçümü, sulama, taşkın tahmini ve çevresel izleme dahil olmak üzere bir dizi önemli kullanım için gereklidir. Su seviyelerini ölçmek için limnigraflar, basınç sensörleri, ultrasonik sensörler ve görüntü tabanlı yöntemler gibi çeşitli yaklaşımlar ve teknolojiler geliştirilmiştir. Gençdoğan ve arkadaşları bir sulama kanalındaki su seviyelerini ve akış oranlarını limnigraflar, basınç sensörleri ve ultrasonik sensörler kullanarak değerlendirmiştir. Bu çeşitli teknolojilerden elde edilen ortalama okumaları vurgulamışlardır (Gençdoğan vd., 2023). Ayrıca, Eltner ve diğerleri mevcut tekniklerin kısıtlamalarına işaret ederek otomatik su seviyesi ölçümünün gerekliliğini vurgulamıştır (Eltner vd., 2018). Buna ek olarak, Chetpattananondh ve arkadaşları kendi kendini kalibre edebilen inter dijital kapasitif sensör kullanarak su seviyelerini ölçmek için bir yöntem önermiştir (Chetpattananondh vd., 2014). Ayrıca, Li ve arkadaşları ultra küçük bir basınç sensörü kullanarak bir fluviyograf geliştirerek modern teknolojinin su seviyesi ölçüm cihazlarına dahil edilebileceğini göstermiştir (Li vd., 2019). Gösterilen örnekler, çağdaş su seviyesi ölçüm yöntemlerinde limnigrafların çok çeşitli kullanım alanlarını göstermekte ve hidrolojik araştırma ve yönetimdeki önemini vurgulamaktadır. Bu yöntemler, ölçümlerin doğruluğunu ve güvenilirliğini artırmaya odaklanmaktadır. Yapılan çalışmalar, su seviyelerini değerlendirmek için kullanılabilecek, her biri kendine özgü fayda ve dezavantajlara sahip çeşitli metodoloji ve teknolojileri sergilemekte ve böylece bu önemli konunun ilerlemesine katkıda bulunmaktadır.

Yeraltı sularının sürekli ve kapsamlı bir şekilde izlenmesinin önemi, Kim ve Lekic tarafından da vurgulanmakta ve yüzey suyu kaynaklarının aksine, dünya çapında birçok bölgede yeraltı sularının yetersiz yönetim odağına ve yetersiz izlenmesine dikkat çekilmektedir (Kim & Lekic, 2019). Lee ve arkadaşları tarafından yürütülen çalışma, yeraltı suyu verilerinin halka erişilebilirliğini vurgulayarak, açık veri kurallarının yeraltı suyu bilgilerinin şeffaflığını ve kullanılabilirliğini ilerletmedeki öneminin altını çizmektedir (Lee vd., 2021). Ayrıca, kritik bölgenin yeraltı suyuna verdiği kapsamlı tepkiyi doğru bir şekilde ölçmek için birden fazla veri akışı kullanmanın ve uzun vadeli kayıtlar tutmanın gerekliliğini vurgulayın. Bu, sınırlı finansal kaynakların neden olduğu yetersiz veya kesintili uzun vadeli veri kayıtlarının yarattığı zorlukların altını çizmektedir (Singha & Navarre-Sitchler, 2021).

Knierim ve diğerleri, yeraltı suyu verilerinin toplanmasıyla ilgili engelleri ve karmaşıklıkları incelemektedir. Belirli sahalarda yeraltı suyu kullanımının kesin kayıtlarının geliştirilmesindeki sınırlamaları vurgulamakta ve yeraltı suyu kullanımının ve kullanılabilirliğinin doğru bir şekilde tahmin edilmesinin önemini vurgulamaktadırlar (Knierim vd., 2017). Buna ek olarak, Holland ve arkadaşları tarafından yürütülen çalışma, yeraltı suyu çıkarımı için sofistike sensör ağlarının oluşturulması ve doğrulanmasına odaklanmaktadır. Bu çalışma, yeraltı suyunun izlenmesine yönelik teknolojilerin ve metodolojinin geliştirilmesine yönelik devam eden çabaların altını çizmektedir (Holland vd., 2022). Referanslar, farklı metodolojiler, zorluklar ve yeraltı suyu dinamiklerini anlamak için sürekli ve kapsamlı izlemenin önemi de dahil olmak üzere yeraltı suyu verilerini kaydetmenin çeşitli yönlerini vurgulamaktadır (Knierim vd., 2017).

1.7 Yeraltı Suyu Verilerini Kullanarak Tahminleme Çalışmaları

Yeraltı suyu verilerinin değerlendirilmesi, özellikle su kıtlığı yaşanan bölgelerde su kaynakları yönetiminin önemli bir bileşenidir. Yeraltı suyu çekimine ilişkin rakamlar sıklıkla eskimekte ve jeopolitik sınırlar arasında tutarsız metodolojiler kullanılarak değerlendirilmektedir (Richey vd., 2015). Bu uyumsuzluğun varlığı, yeraltı suyu depolamasındaki dalgalanmaları anlamak için kesin ve güncel tahmin yöntemlerine duyulan ihtiyacın altını çizmektedir. Bazı araştırmalar, birden fazla bilgi kaynağı kullanarak Hindistan Ganj Havzası gibi belirli alanlarda yeraltı suyu depolama tükenmesinin tahminine öncelik vermiştir (Sreekanth vd., 2023). Bu metodolojiler, yeraltı suyu depolama tahminlerinin hassasiyetini artırmak için çeşitli veri kaynaklarını bir araya getirmenin önemini göstermektedir.

Asoka ve diğerleri tarafından yapılan çalışma, muson yağışlarının ve pompajın Hindistan'daki yeraltı suyu depolamasındaki değişimleri ne ölçüde etkilediğini incelemiştir (Asoka vd., 2017). Çalışma, yeraltı suyu dinamiklerindeki doğal ve insani etkiler arasındaki karmaşık etkileşimi vurgulamaktadır. Bu durum, hem iklimsel faktörleri hem de insan eylemlerini dikkate alan kapsayıcı tahmin tekniklerinin gerekliliğini vurgulamaktadır. Ayrıca, Maréchal ve diğerleri (2006) yarı kurak bölgelerde sulu tarım yapılan yeraltı suyu havzalarında spesifik verim ve doğal şarjın hesaplanmasını araştırmıştır (Maréchal vd., 2006). Elde ettikleri bulgular, yeraltı suyu seviyelerini tahmin ederken arazi kullanımı ve insan müdahalelerini dikkate almanın önemini vurgulamaktadır.

Ayrıca araştırmacılar, yeraltı suyu tükenmesinin atmosferik karbondioksit seviyeleri üzerindeki etkilerini inceleyerek yeraltı suyu dinamiklerinin hidrolojik değerlendirmelerin ötesine geçen kapsamlı sonuçlarını vurgulamışlardır (Wood & Hyndman, 2017). Bu durum, yeraltı suyu tükenmesinin çevresel ve iklimsel sonuçlarını değerlendirmek için hassas tahmin yöntemlerinin önemini vurgulamaktadır. Yeraltı suyu şarj tahmini, doğrusal olmayan transfer fonksiyonu gürültü modelleri gibi tekniklerin uygulanmasıyla kolaylaştırılmıştır ve yeraltı suyu tahmini için erişilebilen çok çeşitli metodolojik yaklaşımları göstermektedir (Collenteur vd., 2021).

Buna ek olarak, çalışmada bölgesel yeraltı suyu şarjını tahmin etmek için izleyici tekniklerinin ve hidrolojik bütçe yöntemlerinin kullanımı vurgulanmaktadır. Bu durum, yeraltı suyu tahminlerinin inceliklerini ele almak için kullanılan yaklaşımların çeşitliliğini göstermektedir (Manghi vd., 2009; Yin vd., 2009). Çeşitli stratejilerin varlığı, yeraltı suyu dinamiklerini uygun şekilde değerlendirmek için kapsamlı ve entegre yaklaşımlar kullanmanın önemini vurgulamaktadır. Buna ek olarak, yeraltı suyu potansiyelinin haritalanması için veri madenciliği algoritmalarının ve uzaktan algılama verilerinin uygulanması, yeraltı suyu kaynaklarının tahmin edilmesinde sofistike teknolojilerin kullanıldığını vurgulamaktadır (Lee vd., 2019). Ayrıca Şentürk ve diğerleri tarafından yapılan bir çalışmada, yapay zeka ile LT2 kuyusunun verileri ile doğrusal olmayan otoregresif sinir ağı kullanarak ileriye dönük yeraltı suyu tahminlemesi yapmışlardır (Şentürk vd., 2023).

Özetlemek gerekirse, yeraltı suyu verilerinin değerlendirilmesi, çeşitli veri kaynaklarının, metodolojik yaklaşımların ve hem doğal hem de insani faktörlerin dikkate alınmasını gerektiren karmaşık bir girişimdir. İncelenen araştırmalar, yeraltı suyu dinamiklerinin karmaşıklığının üstesinden gelmek ve iyi bilgilendirilmiş su kaynakları yönetimini kolaylaştırmak için kesin ve kapsayıcı tahmin yöntemlerinin gerekliliğini vurgulamaktadır.

İKİNCİ BÖLÜM



MATERYAL VE METOD

2.1 Veri Seti ve Çalışma Alanı


Kaggle'dan elde edilen AquiferAuser veri setinden LT2, SAL, PAG, CoS ve DIEC kuyularının kaydedilen yeraltı su seviyelerini kullanarak simülasyon çalışmaları gerçekleştirilmiştir (Acea Smart Water Analytics, 2023). Tablo 1.1'de veri seti olarak kullanılan kuyuların data özellikleri ve Şekil 2.1 ile Şekil 2.5 arasındaki şekillerde zamana bağlı su seviyelerinin değişimleri gösterilmiştir. Bu su kütlesi kuzey ve güney olmak üzere iki alt sistemden oluşmaktadır ve birincisi diğerinin davranışını kısmen etkilemektedir. Kuzey alt sistemi bir su tablası akiferi iken, güney alt sistemi bir artezyen yeraltı suyu sistemidir. Kuzey sektöründeki seviyeler SAL, PAG, CoS ve DIEC kuyuları tarafından gösterilirken, güney sektöründeki seviyeler LT2 kuyusu tarafından gösterilmektedir. Test ve eğitim için kullanılacak olan verilerin ayrıştırılmasında ön işlem olarak eksik veriler bulunmuş ve bu veriler en yakın komşular ile enterpolasyon işlemi yapılmıştır. Enterpolasyon sonucunda oluşan datadan boş olan veriler ayıklanarak deneyde kullanılacak olan veri seti oluşturulmuştur.

Tablo 2.1. *Aquifer Veri Setinden Alınan Verilerin Özellikleri*


	Başlangıç Tarihi	Bitiş Tarihi	Veri Uzunluğu	Veri Sıklığı
Depth_to_Groundwater_LT2	01.01.2006	30.06.2020	5476	Günlük
Depth_to_Groundwater_SAL	06.04.2007	30.06.2020	4835	Günlük
Depth_to_Groundwater_PAG	01.01.2009	30.06.2020	4199	Günlük
Depth_to_Groundwater_CoS	29.06.2006	30.06.2020	3336	Günlük
Depth_to_Groundwater_DIEC	02.01.2011	30.06.2020	3468	Günlük

Şekil 2.1. *Aquifer Veri Setinden Alınan LT2 Kuyusunun İşlenmemiş Verisi***Şekil 2.2.** *Aquifer Veri Setinden Alınan SAL Kuyusunun İşlenmemiş Verisi*


Şekil 2.3. *Aquifer Veri Setinden Alınan PAG Kuyusunun İşlenmemiş Verisi*



Şekil 2.4. *Aquifer Veri Setinden Alınan CoS Kuyusunun İşlenmemiş Verisi*



Şekil 2.5. *Aquifer Veri Setinden Alınan DIEC Kuyusunun İşlenmemiş Verisi*



2.2 Yöntemler

2.2.1 Yapay Sinir Ağları (YSA)

YSA, insan beyninin öğrenme sürecini taklit ederek öğrenme, hafıza ve genelleme yoluyla edinilen bilgiyi kullanmamızı sağlar. Bilgisayar yazılımı, mevcut verilerden yeni veriler üretmek gibi temel faaliyetlerin yürütüldüğü yerdir. Sinir ağı, biyolojik nöronlardan oluşan bir sistem veya yapay nöronlardan veya düğümlerden oluşan yapay bir ağıdır (Hopfield, 1982). Dolayısıyla, bir sinir ağı biyolojik nöronlardan oluşan biyolojik bir sinir ağı veya yapay zeka konularını ele almak için kullanılan yapay bir sinir ağı olabilir. Biyolojik nöron bağlantıları, yapay sinir ağlarında düğümler arasındaki ağırlıklar olarak temsil edilir. Pozitif ağırlık etkinleştirici bir bağlantıyı gösterirken, negatif değerler bastırıcı bağlantıları ifade eder. Tüm girdiler bir ağırlık kullanılarak birleştirilir ve toplanır. Bu faaliyetin adı doğrusal kombinasyondur. Bir aktivasyon fonksiyonu nihai olarak çıktının büyüklüğünü düzenler. Kabul edilebilir bir çıktı aralığı genellikle 0 ila 1 aralığına düşer veya alternatif olarak -1 ila 1 arasında değişebilir.

Yapay ağlar, öngörücü modelleme, uyarlanabilir kontrol ve bir veri seti üzerinde eğitim içeren uygulamalar için kullanılır. Otodidaktizm, karmaşık ve görünüşte farklı verilerden içgörülerini sentezleyebilen birbirine bağlı sistemler içinde ortaya çıkabilir.

Şekil 2.6. Sinir Ağı Modeli




Bilim insanları, insan beyninin olağanüstü niteliklerini taklit eden matematiksel modeller oluşturmak için beynin nörolojik ve fiziksel yapısını temel olarak kullanmışlardır. İnsan

beyninin işleyişini simüle etmek için yapay nöron ve yapay ağ modelleri önerilmiştir (Sağiroğlu vd., 2003). Böylece yapay sinir ağları (YSA) olarak bilinen yeni bir araştırma alanı ortaya çıkmıştır. Yapay sinir ağı (YSA), belirli bir amacı gerçekleştirmek için insan beyninin ve nöronlarının yapısını taklit eden bir sistemdir. Şekil 2.6'da bir Yapay Sinir Ağı'nın (YSA) temel blok diyagramı gösterilmektedir.

Katmanlı yapay sinir ağı (YSA) mimarisi, çeşitli topolojilerde düzenlenmiş birbirine bağlı nöronlara sahiptir. Bileşenler insan sinir sisteminden ilham alır. Sinir ağları, belirli bir amacı gerçekleştirmek için nöronlar arasındaki bağlantıların çarpan veya katsayı değerlerini maksimize ederek eğitilebilir. Şekil 1.7'de bir nöron modeli gösterilmektedir. Bir sinir düğümü giriş değerleri, ağırlıklar, toplama işlemi, transfer fonksiyonu ve çıkış değerinden oluşur. Bir Yapay Sinir Ağı (YSA), insan beyni gibi paralel bir işlemci olarak işlev görür. Bilgi edinebilir, depolayabilir ve bileşenleri arasındaki ağırlıklı bağlantılar aracılığıyla genellemeler yapabilir. Öğrenme süreci, istenen hedefe ulaşmak amacıyla ağırlıkları ayarlamak için öğrenme algoritmalarının kullanılmasını gerektirir.

Şekil 2.7. Yapay bir nöron modeli



Şekil 2.7, n'nin girdi sayısını, p'nin girdi değerlerini, w'nin girdileri ve nöronu birbirine bağlayan ağırlık çarpanını, b'nin nöronun önyargısını, f'nin transfer fonksiyonunu ve a'nın çıktı değerini temsil ettiği bir sinir ağını göstermektedir. Girdiler başlangıçta ağırlıklarla çarpılır ve daha sonra toplanır. Bias değeri çevirilere uygulanır ve çıktı transfer

fonksiyonundan geçirilerek belirlenir. Transfer fonksiyonu doğrusal ya da doğrusal olmayan olabilir. Bu paradigma, girdi ve çıktı arasında matematiksel bir fonksiyon bağlantısı kurar. Nörondan istenen çıktıyı elde etmek için w ve b değerleri ayarlanmalıdır. Yapay sinir ağı nöron modelinin matematiksel gösterimi Aslantas & Kurban tarafından verilmiştir (Aslantaş & Kurban, 2007).


$$a = f\left(\sum_{i=1}^n w_i p_i + b\right) \quad (1)$$

Sığ sinir ağları, bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşan temel bir yapay sinir ağı türüdür. Giriş katmanı modelin dış ortamdan veri almasını sağlar ve bu verileri gizli katmana aktarır. Gizli katman, modelin öğrendikçe bilgiyi temsil etme yeteneğini geliştirmek için girdi verilerini manipüle eder. Her gizli katman, girdi verilerinin ağırlıklı toplamalarını alan ve bunları bir aktivasyon fonksiyonu kullanarak işleyen belirli sayıda nöron hücresinden oluşur. Çıktı katmanı, gizli seviyeler tarafından işlenen bilgileri kullanarak sonuçlar üretir. Tek katmanlı olan bu sinir ağları, yapay sinir ağı araştırmalarında bir çalışma odağıdır. Bu ağlar örüntü tanıma ve makine öğrenimi gibi çeşitli uygulamalarda başarı göstermiştir (Schmidhuber, 2015). Sığ sinir ağları, minimum katman sayısı nedeniyle derin sinir ağlarına göre hesaplama açısından verimli ve eğitilmesi daha kolaydır. Sığ sinir ağları, herhangi bir düzgün fonksiyonu taklit etme yeteneğine sahiptir ve bu da onların ifade potansiyelini göstermektedir (Becker & Zhang, 2020). Sığ sinir ağlarının avantajları vardır, ancak derin sinir ağlarına kıyasla temsil kabiliyeti sınırlıdır, çünkü derin ağlar sığ ağların yapamadığı durumları verimli bir şekilde temsil edebilir (Jia vd., 2020). Sonuçlar, gerçek dünya sorunlarının üstesinden gelmek için sığ sinir ağları kullanmanın pratik önemini vurgulamaktadır. Sığ ve derin sinir ağları arasında karar verirken, görevin özel gereksinimlerini göz önünde bulundurmak çok önemlidir. Sığ ağlar bazı durumlarda temsil gücü ve hesaplama verimliliği açısından avantajlar sunabilirken, derin ağlar diğerlerinde karmaşık özellikleri yakalamak için daha uygun olabilir (Guo vd., 2019). Tek bir gizli katmanla karakterize edilen sığ sinir ağları, hesaplama verimliliği ve ifade yetenekleri sağlayarak onları çok çeşitli uygulamalar için uygun hale getirir. Belirli görevlerde ve pratik alanlarda etkinlik göstermiş olsalar da sığ bir sinir ağının en iyi seçenek olup olmadığına karar vermek için sorunun ihtiyaçlarını kapsamlı bir şekilde değerlendirmek önemlidir. Sığ ve derin sinir ağlarının

ödünleşimlerini anlamak, çeşitli durumlarda benzersiz güçlerinden yararlanmak için çok önemlidir.

Sığ bir sinir ağının temel yapısını Şekil 2.8.'deki gibi gösterilebilir. Diyagramdaki her daire veya düğüm bir nöron hücrelerini temsil eder ve oklar her bir nöron hücrelerinden gelen girdi verilerinin ve çıktıların akışını gösterir. Giriş katmanı genellikle şeklin sol tarafına yerleştirilir, arada gizli katman bulunur ve çıkış katmanı sağ tarafta yer alır. Her düğüm, katman içindeki bir nöron hücrelerini sembolize eder ve oklar üzerindeki ağırlıklar, girdiler ve hücreler arasındaki bağlantıların yoğunluğunu gösterir. Bu grafik yardımı, sığ sinir ağlarının temel yapısının ve unsurlarının daha net anlaşılmasını kolaylaştırmaktadır.

Şekil 2.8. Sığ sinir ağı nöron modeli




İleri Beslemeli Çok Katmanlı Algılayıcı (MLP), çeşitli uygulamalarda yaygın olarak kullanılan bir yapay sinir ağıdır. MLP, verimliliği ve etkinliği nedeniyle akış modellemesinde sıklıkla kullanılmaktadır (Nowak & Sobota, 2015). Ayrıca, kalite tahmin

modellerinde, Çok Katmanlı Algılayıcı (MLP) hassas tahmin modelleri oluşturmak için duygu analizi ile birlikte kullanılmıştır (Mondal vd., 2016). MLP, mesleki maruziyet ve tümör biyobelirteçleri gibi çeşitli alanlarda uyarlanabilirliğini göstererek kanser tespitinde kullanılmıştır (Seidel vd., 2014). MLP, tahmin mimarilerinde, özellikle de yağmurla beslenen sektörlerde yağış tahmininde evrensel bir yaklaşımıcı olarak kabul edilmektedir (Khidir vd., 2013). MLP'nin önemi, kesin kısa vadeli tahminler yapmak için geri yayılım eğitim algoritmalarıyla birlikte kullanıldığı rüzgar hızı tahmininde gösterilmiştir (Zucatelli vd., 2019). Recursive Deterministic Perceptron (RDP), MLP'nin esnekliğini ve çeşitli biçimlerini sergileyen ileri beslemeli çok katmanlı sinir ağının bir uzantısı olarak kabul edilmektedir.

MLP'nin etkinliği, farklı parametrelerin kareler toplamı hatası üzerindeki etkisini değerlendirerek sinir ağı yapılarını optimize etmede gösterilmiştir (Castro vd., 2017). MLP, özellikle çevre sorunlarıyla mücadelede kirlilik tespiti ve kategorizasyonuna uygunluğu açısından değerlendirilmiştir (Denisov, 2017). MLP, mimarisi ve basit metodolojisi sayesinde kalp hastalığı tespitinde tıbbi karar destek sistemleri için önde gelen bir denetimli yapay sinir ağı modeli olarak kabul edilmektedir.

Şekil 2.9'da blok diyagramı gösterilen İleri Beslemeli Çok Katmanlı Algılayıcı (MLP), akış modellemesinden tıbbi karar destek sistemlerine kadar çeşitli uygulamalarda esnekliğini ve verimliliğini göstererek çeşitli alanlarda yaygın olarak kullanılmaktadır.

Şekil 2.9. İleri beslemeli çok katmanlı sinir ağı nörom modeli




2.2.2 Doğrusal Olmayan Otoregresif Sinir Ağı (NAR-NN)

Zaman serisi uygulamaları tipik olarak yüksek değişkenlik ve kısa süreli geçici dönemlerle karakterize edilir. Bu gerçek, zaman serilerinin doğrusal bir model kullanılarak modellenmesini zorlaştırmaktadır, bu nedenle doğrusal olmayan bir yaklaşım önerilmelidir. NAR-NN, zaman serisi tahmininde kullanılan ayrık, doğrusal olmayan, otoregresif bir modeli tanımlar (López vd., 2012; Nyanteh vd., 2013). NAR-NN sistem denklemi aşağıdaki gibidir (İbrahim vd., 2016).

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + \varepsilon(t) \quad (2)$$

Bu formül, bir NAR ağının, serinin p geçmiş değerlerini kullanarak bir veri serisinin y zamanındaki değerini, $y(t)$, tahmin etmek için nasıl kullanıldığını açıklar. $h()$ fonksiyonu önceden bilinmemektedir ve bir sinir ağını eğitmenin amacı, ağın optimizasyonu yoluyla fonksiyona yaklaşımdır. Son olarak, $\varepsilon(t)$ terimi y serisinin t zamanındaki yaklaşık hatasını temsil eder. Şekil 2.10'da bir NAR-NN temel blok diyagramı gösterilmektedir.

Şekil 2.10. NAR-NN Ağı çalışma diyagramı



2.2.3 Geri Yayılım (Backpropagation) Algoritması

Geriye yayılım, bilgisayar bilimleri, yapay zeka ve makine öğrenimi gibi alanlarda yaygın olarak uygulanan yapay sinir ağlarının eğitimi için önemli bir algoritmadır. Yaklaşım, hatayı çıkış katmanından giriş katmanına doğru geriye doğru yayarak bir sinir ağının

parametrelerini değiştirmeyi gerektirir. Bu, ağıın zaman içinde öğrenme yoluyla performansını artırmasını sağlar (Miguez vd., 2014). Geriye yayılma algoritması, eğitim etkinliğini artırmak için sıklıkla doğrusal olmayan en küçük kareler için Marquardt algoritması gibi ek optimizasyon yöntemleriyle eşleştirilir (Hagan & Menhaj, 1994).

Ayrıca, geri yayılım görüntü tanıma, hastalık tespiti ve tahmin modelleri gibi çeşitli alanlarda kullanılmıştır. İnsansız hava araçları için hedef tanımda uygulanmış ve gerçek dünya senaryolarına uyarlanabilirliğini göstermiştir (Jia & Duan, 2017). Geriye yayılım, hastalık tespitinde, yani diabetes mellitus olasılığının %80,91 doğruluk oranıyla tahmin edilmesinde cesaret verici sonuçlar göstermiştir (Anggoro & Hajiati, 2023).

Algoritmanın uyarlanabilirliği ve etkinliği, derin geri yayılım ağlarını kullanarak güç dağıtım ağlarının müdahaleci olmayan yük izlemesi için kullanımında gösterilmiştir (Ma & Yin, 2021). Veri tahmini alanında, geri yayılım sinir ağı, belirli bir model kullanılarak kahve fiyatını %88,2 doğrulukla tahmin etmek için kullanılmıştır (Wahyudi vd., 2022).

Genel olarak, geri yayılım algoritması, hastalık tespiti, görüntü tanıma ve veri tahmini gibi çok çeşitli alanlarda kullanılan yapay sinir ağlarını eğitmek için esnek ve verimli bir yöntemdir.

2.2.4 Levenberg-Marquardt Geri Yayılım Algoritması

Levenberg-Marquardt geri yayılım algoritması, verimliliği ve etkinliği nedeniyle yapay sinir ağlarının (YSA) eğitimi için yaygın olarak kullanılan bir tekniktir. Bu yöntem, Gauss-Newton yöntemi ile en dik iniş algoritmasının avantajlarını birleştiren, daha hızlı yakınsama ve gelişmiş performans sağlayan bir optimizasyon tekniğidir (He vd., 2001). Algoritma, hava durumu modellemesinde, enerji hasat sistemlerinde, toprak sıvılaşma duyarlılığı tahmininde, beyin-bilgisayar arayüzlerinde, ısı eşanjörü arıza tahmininde, zaman serisi tahmininde ve köprü ayakları etrafındaki yerel oyulma derinliği tahmininde etkili bir şekilde kullanılmıştır.

Araştırmalar, Levenberg-Marquardt yönteminin eğitim doğruluğu ve yakınsama özellikleri açısından esnek geri yayılım ve hata düzeltme algoritmaları da dahil olmak üzere diğer geri yayılım algoritmalarından daha etkili olduğunu göstermiştir (Muhammad & Vaino, 2019). Ayrıca, eğitim senaryolarının çoğunda geleneksel geri yayılım algoritmasından daha hızlı ve daha etkili olduğu belgelenmiştir (Özkan vd., 2011). Ayrıca, aktör-eleştirel öğrenme yöntemlerinde, Levenberg-Marquardt algoritmasının

eleştirel ağ mimarisine dahil edilmesinin yakınsama hızını artırdığı öne sürülmüştür (Ni vd., 2011).

Fizikte Levenberg-Marquardt geri yayılım tekniği, kritik Rayleigh sayılarının dağılımını tahmin etmek ve yapay sinir ağları aracılığıyla doğrusal kararlılık analizi için kullanılmaktadır (Reddy vd., 2022). Ayrıca, RADAR görüntülerinden yansıtma parametrelerini mükemmel regresyon değerleri ve doğrulukla çıkarmak için kullanılmıştır (Kumar & Anuradha, 2018).

Algoritma, esnek geri yayılım da dahil olmak üzere çeşitli eğitim algoritmalarıyla karşılaştırılmış ve belirli durumlarda üstün sınıflandırma performansına sahip olduğu belirlenmiştir (Cömert & Kocamaz, 2017). Ayrıca, eğitim için sonlu elemanlar sinir ağı ile birleştirilerek çeşitli ağ yapılarına uyarlanabilirliği gösterilmiştir (Reynaldi vd., 2012).

Levenberg-Marquardt geri yayılım sinir ağı, enerji ile ilgili amaçlarla binalardaki güç kullanımını tahmin etmek için optimize edilmiş ve kullanılmıştır (Ye & Kim, 2018). Sistem, yerel minimumlarla ilgili sorunların üstesinden gelmek ve hızlı yakınsama elde etmek için Cuckoo Search algoritması kullanılarak dahil edilmiş ve optimize edilmiştir (Nawi vd., 2013).

Levenberg-Marquardt geri yayılım algoritması, farklı alanlardaki yapay sinir ağlarını eğitmek için güçlü ve uyarlanabilir bir tekniktir ve verimliliğini, etkinliğini ve geniş kullanımını göstermektedir.

YSA için kullanılan baskın öğrenme algoritması Levenberg-Marquardt geri yayılım tekniğidir. Bu eğitim fonksiyonu sıklıkla en hızlı geri yayılım algoritmasıdır. Bu algoritma ikinci dereceden tahminleri gerçekleştirmek için kullanılmaktadır (Ruiz vd., 2016).

Hessian matrisinin hesaplanmasını gerektirmeden türevi hesaplaması nedeniyle eğitim hızı yüksektir. Performans fonksiyonu, ileri beslemeli ağ eğitiminde görüldüğü gibi kareler toplamı şeklindeyse, Hessian matrisi Denklem (3)'deki gibi tahmin edilebilir ve gradyan Denklem (4)'te açıklandığı gibi hesaplanabilir.

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (3)$$

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (4)$$

Denklem (3) ve (4), $\mathbf{J}'$ 'yi ağ hatalarının ağırlıklara ve biaslara göre birinci türevlerini içeren Jacobian matrisi ve $\mathbf{e}'$ 'yi tüm eğitim örneklerindeki ağ hatalarını temsil eden bir vektör olarak tanımlar. Jacobian matrisi, Hessian matrisinin bir yaklaşımını sağlamak için geleneksel bir geriye yayılma yaklaşımı kullanılmıştır. Bu yöntem Hessian matrisini hesaplamaktan daha az karmaşıktır. Levenberg-Marquardt algoritması bu yöntemi Denklem (5)'te özetlenen Newton benzeri güncellemede kullanır.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (5)$$

2.2.5 Bayesian Regülasyon Geri Yayılım Algoritması

Bayesian regülasyon geri yayılım algoritması, YSA alanında güçlü bir araçtır. Bu teknik, ortalama karesel hatayı (MSE) azaltmak yerine karesel hataların ve karesel ağırlıkların ağırlıklı toplamını en aza indirerek klasik Levenberg-Marquardt (LM) algoritmasından ayrılır (Fang vd., 2020). Bayes düzenlemesi geri yayılım tekniği, kapsamlı çapraz doğrulama ihtiyacını azaltarak ve genelleme performansını artırarak bu ayırmadan yararlanır (Golpour vd., 2021). Ayrıca, yol güvenliği için kaza tahmin modelleri, fotovoltaik sistemlerde maksimum güç noktası takibi ve deneysel verilere dayalı toprak sürtünme açısının tahmini gibi farklı alanlarda etkili bir şekilde kullanılmıştır.

Bayes düzenlemesi geri yayılım algoritması, düzlemsel bir kanaldaki sıvı peristaltik hareketinin incelenmesi, çevresel ekonomik sistemlerin modellenmesi ve geri dönüştürülmüş agregalarla kendiliğinden yerleşen betonun yarıma çekme mukavemetinin tahmin edilmesi gibi çeşitli uygulamalarda etkinliğini göstermiştir. Ayrıca, doğrusal/doğrusal olmayan pantograf gecikmeli diferansiyel denklemlerin başlangıç değer problemlerini ele almak, kimyasal bileşimi kullanarak hayvan yeminin besin içeriğini değerlendirmek ve soyma açısının bir kertenkele spatulasının soyma kuvveti üzerindeki etkisini tahmin etmek için uygulanmıştır (Gouravaraju, 2020; Khan vd., 2020; Nikmatya vd., 2022).

Bayesian Regularization geri yayılım algoritması, eğitim binalarında soğutma enerjisi tüketimini tahmin etmek, drone navigasyonu için yörüngeleri segmentlere ayırmak ve iyonik sıvılarda karbondioksit çözünürlüğünü tahmin etmek gibi farklı uygulamalar için yapay sinir ağlarını eğitmek için kullanılmıştır. Bu yaklaşımın kararlılığı ve doğruluğu, sinir ağı modellemesinde gelişmiş performans potansiyeli gösteren klasik geri yayılım algoritmalarıyla olumlu bir şekilde karşılaştırılmıştır (Roy vd., 2021).

Karşılaştırmalı çalışmalar, Bayesian Regülasyon geri yayılım yönteminin doğruluk ve genelleme performansı açısından Levenberg-Marquardt gibi alternatif eğitim algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur (Kumar & Sodhi, 2022). Mesleki popülasyonlar için gerçek zamanlı maruziyet değerlendirme modellerinde kullanılmış, üstün sonuçlar vermiş ve maruziyet modellerini tahmin etme potansiyelini göstermiştir (Sarigiannis vd., 2009).


Bayesian regülasyon geri yayılım tekniği, yapay sinir ağlarında güçlü ve uyarlanabilir bir araçtır ve çeşitli uygulamalarda gelişmiş genelleme performansı, kararlılık ve doğruluk gibi faydalar sağlar.

2.2.6 Uzun Kısa Süreli Bellek (LSTM)

LSTM, sıralı verilerin modellenmesi için uygulanan yinelemeli sinir ağı (RNN) yaklaşımının özel bir türü olarak 1990 yılların sonunda geliştirilmiştir (Hochreiter & Schmidhuber, 1997). YSA metodolojisinde, girdi veri setindeki her bir veri noktası, bir önceki çıktı değeri dikkate alınarak sistematik olarak analiz edilir. Bu mimarinin geçmiş zaman dilimlerinden öğrenmeyi içerdiği iddialarına rağmen, gradyanın kaybolması / patlaması sorunu nedeniyle bunun ulaşılamaz olduğu belirtilmiştir (Gönül, 2015). Bu sorunun üstesinden gelmek için uzun süreli bilgiyi hatırlayabilen LSTM mimarisi geliştirilmiştir.

YSA, insan beyninin yapısından sonra modellenen, verileri öğrenme ve analiz etme yeteneğine sahip algılayıcılardır (Şentürk & Şentürk, 2016). Kısıyıcı ve diğerleri tarafından belirtildiği üzere, YSA başarısı mimarisine ve öğrenme algoritmasına bağlıdır (Kıyıcı vd., 2022). YSA, insan beyninin öğrenme süreçlerini taklit ederek yeni veriler oluşturan, geçmiş bilgileri hatırlamak ve bilgi parçaları arasında bağlantılar kurarak sonuçlar çıkarmak için insanın öğrenme özelliklerini kullanan bir bilgisayar yazılımıdır (Akalin & Demirbaş, 2022). YSA, insan beyninin nöro-fizyolojik yapısını matematiksel olarak taklit ederek işlevlerini simüle etmek için tasarlanmış bilgisayar sistemleridir (Yetiz vd., 2021).

Şekil 2.11. LSTM Mimarisi



LSTM mimarisi, Şekil 2.11.'de gösterildiği gibi birbirini tekrar eden sıralı bloklardan oluşur. Genel olarak LSTM yapısında unut, girdi ve çıktı olmak üzere 3 farklı katmandan oluşur. LSTM mimarisinde öncelikle girdi olarak X_t ve h_{t-1} bilgileri kullanılarak hangi bilgilerin silineceğine karar verilir. Bu işlemler unut katmanında f_t denklem 6 kullanılarak yapılır ve aktivasyon fonksiyonu olarak sigmoid kullanılır.

$$f_t = \sigma(W_{f,x} * X_t + W_{f,h} * h_{t-1} + b_f) \quad (6)$$

İkinci adımda yeni bilgilerin belirleneceği girdi katmanı devreye girer ve öncelikle i_t denklem 7 kullanılarak sigmoid fonksiyonu ile bilgiler güncellenir. Ardından denklem 8 ile yeni bilgiyi oluşturacak aday bilgiler $\tanh$ fonksiyonu tarafından belirlenir.

$$i_t = \sigma(W_{i,x} * X_t + W_{i,h} * h_{t-1} + b_i) \quad (7)$$

$$g_t = \tanh(W_{c,x} * X_t + W_{c,h} * h_{t-1} + b_c) \quad (8)$$

Denklem 9 tarafından yeni bilgiler oluşturulur.

$$C_t = C_{t-1} * f_t + i_t * g_t \quad (9)$$

Son olarak çıktı katmanında denklem 10 ve 11 kullanılarak çıktı verileri elde edilir.

$$o_t = \sigma(W_{o,x} * X_t + W_{o,h} * h_{t-1} + b_o) \quad (10)$$

$$h_t = o_t * \tanh(C_t) \quad (11)$$

Yukarıda ifade edilen süreç tekrarlanarak devam eder. Ağırlık parametreleri W ve bias parametreleri b gerçek eğitim değerleri ile LSTM çıktı değerleri arasındaki farkı minimize edecek şekilde model tarafından öğrenilmektedir.

2.2.7 Kök-Ortalama-Kare Yayılımı (RMSprop) Algoritması

RMSprop, son yıllarda stokastik gradyan iniş algoritmasının bir uzantısı olmasıyla ünlenen uyarlanabilir bir öğrenme tekniğidir. RMSprop, parametrelerin karesel gradyanlarının çalışan bir ortalamasını hesaplar ve saklar. Aşağıda rmsprop için formüller verilmiştir.

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_\ell)]^2 \quad (12)$$

burada β_2 hareketli ortalamanın bozulma oranını temsil eder. Yaygın olarak kullanılan bozulma oranları 0,9, 0,99 ve 0,999'dur. Ortalama karesel gradyan uzunlukları 10, 100 ve 1000 parametre güncellemesi için $1/(1 - \beta_2)$ olarak ilişkilendirilmiştir. RMSprop algoritması, her bir parametre için güncellemeleri ayrı ayrı standartlaştırmak için denklem 13'ü kullanır. RMSprop algoritması, belirli bir denklem kullanarak her parametre için güncellemeleri ayrı ayrı normalleştirir.

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha \nabla E(\theta_\ell)}{\sqrt{v_\ell} + \epsilon} \quad (13)$$

burada eleman bazında bölme işlemi, ϵ sıfıra bölmeyi önlemek için dahil edilen küçük bir sabit değeri temsil edecek şekilde gerçekleştirilir.

2.2.8 Uyarlanabilir Moment Tahmini (Adam) Algoritması

Uyarlanabilir moment tahmini (Adam) yaklaşımı, RMSprop'a benzer bir momentum terimi kullanarak parametreleri değiştirir. Eleman bazında hareketli ortalamaları kullanılarak hesaplanan karesel değerler ve parametre gradyanları denklem 14 ve 15 ile temsil edilir.

$$m_\ell = \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_\ell) \quad (14)$$

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_\ell)]^2 \quad (15)$$

burada bozunma oranları β_1 ve β_2 , 'GradientDecayFactor' ve 'SquaredGradientDecayFactor' argümanları kullanılarak ayarlanabilir. Adam, ağ ayarlarını yapmak için denklem 16 tarafından sağlanan hareketli ortalamaları kullanır (Adige vd., 2023).

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha m_\ell}{\sqrt{v_\ell} + \epsilon} \quad (16)$$

2.3 Ortalama Karekök Hatası (RMSE)

RMSE, tahminlerini gerçek değerlerle karşılaştırarak bir tahmin modelinin doğruluğunu değerlendirmek için kullanılan istatistiksel bir ölçüdür. RMSE, özellikle regresyon analizi gibi görevlerde yaygın olarak kullanılır. Hesaplama, beklenen ve gerçek değerler arasındaki farkların karesinin alınmasını, bu karesel farkların ortalamasının alınmasını ve ardından sonucun karekökünün hesaplanmasını içerir. Daha düşük bir RMSE, modelin gerçek değerlerle yakın bir şekilde hizalanarak daha doğru tahminler sağladığını gösterir. Bir tahmin modelinin hassasiyetini ve etkinliğini değerlendirmek için kullanılan çok önemli bir ölçüdür.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (17)$$

ÜÇÜNCÜ BÖLÜM

DENEYLER

3.1 Simülasyon Çalışma Düzenegi

Simülasyon çalışmaları Intel Core i7 işlemci ile güçlendirilmiş, 16GB RAM'e sahip bir bilgisayarda ve MATLAB 2022b versiyonunda gerçekleştirilmiştir.

Deneylerde NAR-NN eğitiminde trainlm ve trainbr yapay sinir ağları eğitim algoritmaları kullanılmıştır. LSTM modelinin eğitiminde ise adam ve rmsprop algoritmaları kullanılmıştır. Her iki makine öğrenmesi yöntemi için gizli katmanın boyutları (nöron sayıları) (gkb) (2, 10, 30 ve 40) ve epok sayıları (50, 100, 150, 200) kullanılarak deneyler gerçekleştirilmiştir. Girdi verileri için $t=1$ ve $t=2$ adım olmak üzere zaman gecikmesi kullanılmıştır. Deneyde kullanılan veri setlerindeki özellikleri Tablo 2.1'de verilmiştir. Bu verinin %70'i yapay sinir ağlarının eğitimde ve kalan %30'u ise test verisi olarak kullanılmıştır. Deneyler 30 kez tekrarlanmış ve bu tekrarlarının ortalaması ile standart sapmaları hesaplanmıştır. Tablolarda ortalama hata sonuçları verilmiş olup, standart sapmalar ise parantez içlerinde verilmiştir.

3.2 Sayısal Sonuçlar

Bu bölümde deneylere ilişkin RMSE sonuçları sunulmuştur.

Tablo 3.1. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0747 (2,16E-01)	0,0347 (1,34E-04)	0,0350 (4,92E-04)	0,0350 (1,60E-04)
epok = 100	0,0348 (9,98E-04)	0,0347 (3,61E-04)	0,0351 (6,37E-04)	0,0350 (4,58E-04)
epok = 150	0,0346 (1,12E-04)	0,0347 (9,00E-04)	0,0351 (6,14E-04)	0,0350 (4,30E-04)
epok = 200	0,1135 (3,00E-01)	0,0347 (6,25E-04)	0,0351 (5,23E-04)	0,0350 (5,75E-04)

Tablo 3.1.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.2. *LT2 Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0346 (1,18E-03)	0,0345 (9,87E-04)	0,0352 (3,53E-04)	0,0352 (3,56E-04)
epok= 100	0,0343 (4,09E-04)	0,0346 (1,62E-04)	0,0353 (2,88E-04)	0,0355 (3,14E-04)
epok= 150	0,0343 (4,25E-04)	0,0347 (2,36E-04)	0,0354 (3,17E-04)	0,0358 (7,94E-04)
epok= 200	0,0343 (4,54E-04)	0,0348 (2,71E-04)	0,0354 (3,82E-04)	0,0359 (8,40E-04)

Tablo 3.2.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 100, 150 ve 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.3. *LT2 Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0349 (7,18E-04)	0,0347 (2,47E-04)	0,0349 (3,28E-04)	0,0349 (2,93E-04)
epok= 100	0,0346 (2,86E-04)	0,0347 (2,18E-04)	0,0349 (1,78E-04)	0,0349 (2,69E-04)
epok= 150	0,0346 (2,54E-04)	0,0347 (1,56E-04)	0,0349 (2,04E-04)	0,0349 (3,31E-04)
epok= 200	0,0345 (3,02E-04)	0,0347 (2,67E-04)	0,0349 (2,65E-04)	0,0349 (2,62E-04)

Tablo 3.3.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.4. *LT2 Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0344 (1,19E-04)	0,0343 (9,69E-04)	0,0498 (5,92E-02)	0,0384 (2,24E-02)
epok= 100	0,0343 (3,00E-04)	0,0343 (1,62E-04)	0,0343 (4,72E-04)	0,0344 (2,04E-04)
epok= 150	0,0343 (3,53E-04)	0,0343 (8,68E-04)	0,0343 (3,61E-04)	0,0345 (2,21E-04)
epok= 200	0,0342 (2,98E-04)	0,0343 (4,30E-04)	0,0343 (2,19E-04)	0,0345 (3,85E-04)

Tablo 3.4.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.5. *LT2 Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0906 (9,34E-03)	0,0720 (2,98E-03)	0,0627 (2,26E-03)	0,0576 (1,08E-03)
epok= 100	0,0697 (4,80E-03)	0,0648 (2,53E-03)	0,0599 (1,59E-03)	0,0572 (1,12E-03)
epok= 150	0,0639 (3,41E-03)	0,0606 (2,21E-03)	0,0587 (1,33E-03)	0,0564 (1,04E-03)
epok= 200	0,0628 (3,66E-03)	0,0597 (2,81E-03)	0,0577 (1,45E-03)	0,0561 (9,50E-04)

Tablo 3.5.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.6. *LT2 Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0965 (1,06E-02)	0,0759 (4,12E-03)	0,0678 (1,66E-03)	0,0635 (7,16E-04)
epok= 100	0,0760 (3,98E-03)	0,0690 (2,40E-03)	0,0654 (1,35E-03)	0,0629 (6,25E-04)
epok= 150	0,0693 (3,01E-03)	0,0659 (1,87E-03)	0,0639 (1,16E-03)	0,0624 (6,33E-04)
epok= 200	0,0680 (3,05E-03)	0,0650 (1,87E-03)	0,0634 (1,02E-03)	0,0623 (7,52E-04)

Tablo 3.6.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.7. *LT2 Kuyusu LSTM rmsprop algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0775 (6,58E-03)	0,0740 (3,98E-03)	0,0695 (3,38E-03)	0,0722 (3,21E-03)
epok= 100	0,0665 (5,60E-03)	0,0646 (2,82E-03)	0,0625 (1,85E-03)	0,0646 (2,96E-03)
epok= 150	0,0610 (3,39E-03)	0,0590 (2,56E-03)	0,0573 (1,70E-03)	0,0592 (3,65E-03)
epok= 200	0,0573 (2,49E-03)	0,0559 (1,61E-03)	0,0535 (1,49E-03)	0,0554 (3,30E-03)

Tablo 3.7.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.8. LT2 Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0834 (8,58E-03)	0,0770 (4,08E-03)	0,0745 (2,48E-03)	0,0772 (3,40E-03)
epok= 100	0,0709 (3,09E-03)	0,0689 (2,39E-03)	0,0674 (1,85E-03)	0,0703 (2,96E-03)
epok= 150	0,0660 (1,85E-03)	0,0646 (1,64E-03)	0,0631 (9,25E-04)	0,0654 (3,20E-03)
epok= 200	0,0638 (2,36E-03)	0,0620 (1,39E-03)	0,0605 (9,51E-04)	0,0624 (1,93E-03)

Tablo 3.8.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.9. LT2 Kuyusu NAR-NN ve LSTM RMSE sonuçları.

	trainlm	trainbr	adam	rmsprop
t=1	0,0346 (1,12E-04)	0,0345 (3,02E-04)	0,0561 (9,50E-04)	0,0535 (1,49E-03)
t=2	0,0343 (4,09E-04)	0,0342 (2,98E-04)	0,0623 (7,52E-04)	0,0605 (9,51E-04)

Tablo 3.9.'deki sonuçlar incelendiğinde ortalama hata için, NAR-NN eğitiminde trainbr eğitim algoritması ve $t=2$ zaman gecikmesi uygulandığında iyi sonuçlar elde edildiği gözlemlenmiştir. Zaman gecikmesi artarken NAR-NN eğitiminde iyileşme görülürken LSTM eğitiminde ise kötüleşme görülmektedir. NAR-NN eğitiminde trainbr eğitim algoritması trainlm eğitim algoritmasında göre daha başarılı sonuçlar elde edilmiştir. LSTM eğitiminde ise rmsprop eğitim algoritması adam eğitim algoritmasına göre daha başarılı olduğu görülmektedir.

Tablo 3.10. SAL Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0805 (5,11E-04)	0,0802 (5,94E-04)	0,1063 (1,11E-02)	0,1137 (7,09E-03)
epok = 100	0,0804 (2,87E-04)	0,0804 (4,70E-04)	0,1282 (1,35E-03)	0,1278 (3,19E-04)
epok = 150	0,0801 (2,57E-04)	0,0805 (7,82E-04)	0,1325 (1,29E-02)	0,1271 (8,23E-04)
epok = 200	0,0802 (2,24E-04)	0,0805 (4,10E-04)	0,1313 (9,68E-03)	0,1270 (1,94E-04)

Tablo 3.10.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.11. SAL Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0797 (6,63E-04)	0,0780 (5,47E-03)	0,0911 (1,09E-02)	0,0918 (9,84E-03)
epok= 100	0,0798 (9,14E-04)	0,0794 (7,91E-03)	0,0957 (1,35E-02)	0,1087 (2,38E-02)
epok= 150	0,0799 (8,16E-04)	0,0791 (7,49E-03)	0,1027 (1,36E-02)	0,1200 (2,23E-02)
epok= 200	0,0800 (3,87E-04)	0,0824 (9,39E-03)	0,1167 (4,64E-02)	0,1377 (4,21E-02)

Tablo 3.11.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 50 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.12. SAL Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0804 (3,86E-04)	0,0803 (9,48E-04)	0,1108 (8,04E-03)	0,1071 (1,95E-02)
epok= 100	0,0802 (1,85E-04)	0,0803 (1,29E-04)	0,1255 (1,11E-02)	0,1064 (2,26E-02)
epok= 150	0,0802 (1,88E-04)	0,0803 (1,27E-04)	0,1231 (1,19E-02)	0,1235 (1,35E-02)
epok= 200	0,0801 (8,10E-04)	0,0803 (9,55E-04)	0,1274 (8,66E-03)	0,1208 (1,74E-02)

Tablo 3.12.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.13. SAL Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0794 (8,07E-04)	0,0779 (1,74E-03)	0,0789 (4,10E-03)	0,0833 (7,45E-03)
epok= 100	0,0800 (4,80E-04)	0,0747 (9,33E-04)	0,0795 (8,67E-03)	0,0876 (1,06E-02)
epok= 150	0,0798 (3,19E-04)	0,0757 (5,20E-03)	0,0796 (9,60E-03)	0,0898 (1,19E-02)
epok= 200	0,0800 (4,96E-04)	0,0773 (6,34E-03)	0,0831 (1,07E-02)	0,0890 (1,37E-02)

Tablo 3.13.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 100 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.14. SAL Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1564 (1,60E-02)	0,1331 (5,56E-03)	0,1201 (2,99E-03)	0,1124 (2,11E-03)
epok= 100	0,1259 (6,26E-03)	0,1165 (4,07E-03)	0,1080 (3,22E-03)	0,1021 (1,80E-03)
epok= 150	0,1147 (8,06E-03)	0,1058 (4,01E-03)	0,0987 (3,60E-03)	0,0969 (2,30E-03)
epok= 200	0,1035 (5,17E-03)	0,0911 (4,49E-03)	0,0882 (2,92E-03)	0,0926 (2,68E-03)

Tablo 3.14.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.15. SAL Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1669 (1,29E-02)	0,1480 (5,98E-03)	0,1372 (2,94E-03)	0,1294 (1,48E-03)
epok= 100	0,1383 (8,19E-03)	0,1313 (4,07E-03)	0,1272 (2,40E-03)	0,1210 (1,08E-03)
epok= 150	0,1295 (5,83E-03)	0,1229 (3,50E-03)	0,1176 (3,57E-03)	0,1164 (1,36E-03)
epok= 200	0,1228 (4,18E-03)	0,1119 (3,73E-03)	0,1080 (1,45E-03)	0,1112 (1,48E-03)

Tablo 3.15.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.16. SAL Kuyusu LSTM rmsprop algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1391 (1,13E-02)	0,1198 (4,42E-03)	0,1162 (3,70E-03)	0,1175 (4,09E-03)
epok= 100	0,1023 (5,49E-03)	0,0978 (5,20E-03)	0,0962 (3,95E-03)	0,0998 (3,95E-03)
epok= 150	0,0892 (1,88E-03)	0,0887 (2,99E-03)	0,0879 (2,06E-03)	0,0912 (3,41E-03)
epok= 200	0,0846 (1,27E-03)	0,0842 (2,78E-03)	0,0846 (3,88E-03)	0,0852 (2,85E-03)

Tablo 3.16.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.17. SAL Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1516 (1,44E-02)	0,1367 (4,25E-03)	0,1324 (2,70E-03)	0,1358 (9,59E-03)
epok= 100	0,1208 (3,94E-03)	0,1175 (2,63E-03)	0,1153 (2,15E-03)	0,1185 (3,40E-03)
epok= 150	0,1106 (2,47E-03)	0,1092 (1,31E-03)	0,1102 (2,45E-03)	0,1106 (2,26E-03)
epok= 200	0,1067 (1,13E-03)	0,1068 (1,26E-03)	0,1065 (1,53E-03)	0,1071 (1,89E-03)

Tablo 3.17.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.18. SAL Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.

	trainlm	trainbr	adam	rmsprop
t=1	0,0801 (2,57E-04)	0,0801 (2,57E-04)	0,0882 (2,92E-03)	0,0842 (2,78E-03)
t=2	0,0780 (5,47E-03)	0,0747 (9,33E-04)	0,1080 (1,45E-03)	0,1065 (1,53E-03)

Tablo 3.18.'deki sonuçlar incelendiğinde ortalama hata için, NAR-NN eğitiminde trainbr eğitim algoritması ve $t=2$ zaman gecikmesi uygulandığında iyi sonuçlar elde edildiği gözlemlenmiştir. Zaman gecikmesi artarken NAR-NN eğitiminde iyileşme görülürken LSTM eğitiminde ise kötüleşme görülmektedir. NAR-NN eğitiminde trainbr eğitim algoritması trainlm eğitim algoritmasında göre daha başarılı sonuçlar elde edilmiştir. LSTM eğitiminde ise rmsprop eğitim algoritması adam eğitim algoritmasına göre daha başarılı olduğu görülmektedir.

Tablo 3.19. PAG Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1211 (9,55E-02)	0,1036 (1,03E-04)	0,1044 (2,22E-04)	0,1052 (1,91E-04)
epok = 100	0,1209 (9,55E-02)	0,1043 (4,15E-04)	0,1047 (4,30E-04)	0,1060 (4,65E-04)
epok = 150	0,1210 (9,55E-02)	0,1048 (4,77E-04)	0,1051 (3,75E-04)	0,1061 (2,11E-04)
epok = 200	0,1035 (1,67E-04)	0,1050 (2,50E-04)	0,1051 (3,89E-04)	0,1059 (2,92E-04)

Tablo 3.19.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.20. PAG Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1183 (9,61E-02)	0,1019 (6,12E-04)	0,1053 (3,23E-03)	0,1054 (2,52E-03)
epok= 100	0,1008 (3,42E-04)	0,1020 (5,47E-04)	0,1055 (2,63E-03)	0,1103 (8,43E-03)
epok= 150	0,1008 (2,74E-04)	0,1022 (1,01E-03)	0,1095 (9,29E-03)	0,1133 (1,05E-02)
epok= 200	0,1007 (2,79E-04)	0,1024 (1,09E-03)	0,1120 (1,57E-02)	0,1229 (2,78E-02)

Tablo 3.20.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.21. PAG Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1042 (1,75E-03)	0,1034 (2,89E-04)	0,1042 (1,68E-04)	0,1047 (3,58E-04)
epok= 100	0,1036 (2,81E-04)	0,1034 (3,68E-04)	0,1042 (2,09E-04)	0,1050 (4,53E-04)
epok= 150	0,1035 (1,93E-04)	0,1034 (2,78E-04)	0,1043 (1,94E-04)	0,1055 (5,42E-04)
epok= 200	0,1209 (9,56E-02)	0,1034 (3,13E-04)	0,1043 (2,11E-04)	0,1057 (6,47E-04)

Tablo 3.21.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 50, 100, 150 ve 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.22. PAG Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0794 (8,07E-04)	0,0779 (1,74E-03)	0,0789 (4,10E-03)	0,0833 (7,45E-03)
epok= 100	0,0800 (4,80E-04)	0,0747 (9,33E-04)	0,0795 (8,67E-03)	0,0876 (1,06E-02)
epok= 150	0,0798 (3,19E-04)	0,0757 (5,20E-03)	0,0796 (9,60E-03)	0,0898 (1,19E-02)
epok= 200	0,0800 (4,96E-04)	0,0773 (6,34E-03)	0,0831 (1,07E-02)	0,0890 (1,37E-02)

Tablo 3.22.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 100 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.23. PAG Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2221 (2,28E-02)	0,2045 (9,12E-03)	0,1872 (5,43E-03)	0,1799 (3,62E-03)
epok= 100	0,1897 (1,03E-02)	0,1784 (7,80E-03)	0,1672 (5,37E-03)	0,1606 (1,17E-02)
epok= 150	0,1688 (9,76E-03)	0,1405 (9,98E-03)	0,1284 (3,59E-03)	0,1463 (1,52E-02)
epok= 200	0,1445 (1,11E-02)	0,1205 (4,17E-03)	0,1158 (2,71E-03)	0,1299 (8,18E-03)

Tablo 3.23.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.24. PAG Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2391 (1,14E-02)	0,2243 (6,07E-03)	0,2144 (4,66E-03)	0,2076 (2,21E-03)
epok= 100	0,2102 (7,51E-03)	0,2058 (6,23E-03)	0,2008 (4,13E-03)	0,1993 (2,14E-02)
epok= 150	0,1995 (5,89E-03)	0,1850 (8,27E-03)	0,1789 (5,82E-03)	0,1814 (5,75E-03)
epok= 200	0,1852 (7,88E-03)	0,1700 (4,46E-03)	0,1663 (1,66E-03)	0,1766 (5,17E-03)

Tablo 3.24.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.25. PAG Kuyusu LSTM rsmprop algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1912 (1,79E-02)	0,1807 (6,72E-03)	0,1767 (6,53E-03)	0,1874 (4,95E-03)
epok= 100	0,1499 (7,30E-03)	0,1418 (8,29E-03)	0,1500 (3,28E-02)	0,1497 (7,71E-03)
epok= 150	0,1305 (5,00E-03)	0,1265 (1,15E-02)	0,1274 (2,31E-02)	0,1282 (4,38E-03)
epok= 200	0,1189 (3,50E-03)	0,1165 (8,43E-03)	0,1231 (2,89E-02)	0,1156 (7,03E-03)

Tablo 3.25.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.26. PAG Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2192 (1,01E-02)	0,2069 (6,03E-03)	0,2079 (4,99E-03)	0,2140 (4,52E-03)
epok= 100	0,1889 (5,59E-03)	0,1839 (9,62E-03)	0,1855 (4,92E-03)	0,1890 (5,15E-03)
epok= 150	0,1738 (3,07E-03)	0,1772 (1,31E-02)	0,1740 (1,34E-02)	0,1757 (4,95E-03)
epok= 200	0,1674 (2,29E-03)	0,1657 (3,69E-03)	0,1687 (1,10E-02)	0,1663 (3,27E-03)

Tablo 3.26.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.27. PAG Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.

	trainlm	trainbr	adam	rmsprop
t=1	0,1035 (1,67E-04)	0,1034 (2,78E-04)	0,1158 (2,71E-03)	0,1156 (7,03E-03)
t=2	0,1007 (2,79E-04)	0,0747 (9,33E-04)	0,1663 (1,66E-03)	0,1657 (3,69E-03)

Tablo 3.27.'deki sonuçlar incelendiğinde ortalama hata için, NAR-NN eğitiminde trainbr eğitim algoritması ve $t=2$ zaman gecikmesi uygulandığında iyi sonuçlar elde edildiği gözlemlenmiştir. Zaman gecikmesi artarken NAR-NN eğitiminde iyileşme görülürken LSTM eğitiminde ise kötüleşme görülmektedir. NAR-NN eğitiminde trainbr eğitim algoritması trainlm eğitim algoritmasında göre daha başarılı sonuçlar elde edilmiştir. LSTM eğitiminde ise rmsprop eğitim algoritması adam eğitim algoritmasına göre daha başarılı olduğu görülmektedir.

Tablo 3.28. CoS Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0610 (4,47E-04)	0,0613 (3,49E-04)	0,0757 (6,33E-03)	0,1898 (7,00E-02)
epok = 100	0,0611 (1,40E-04)	0,0614 (2,68E-04)	0,1109 (1,43E-02)	0,9282 (3,35E-01)
epok = 150	0,1057 (2,45E-01)	0,0614 (1,04E-04)	0,1373 (5,09E-02)	1,0662 (3,97E-01)
epok = 200	0,1057 (2,45E-01)	0,0613 (2,13E-04)	0,2878 (4,06E-01)	1,2890 (3,14E-01)

Tablo 3.28.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 50 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.29. CoS Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0566 (6,05E-04)	0,0547 (3,91E-04)	0,0554 (5,10E-04)	0,0557 (3,47E-04)
epok= 100	0,0562 (4,22E-04)	0,0547 (3,31E-04)	0,0557 (6,45E-04)	0,0560 (6,23E-04)
epok= 150	0,0559 (6,39E-04)	0,0547 (4,99E-04)	0,0558 (7,38E-04)	0,0574 (2,40E-03)
epok= 200	0,0558 (4,86E-04)	0,0546 (3,12E-04)	0,0560 (6,79E-04)	0,0570 (1,71E-03)

Tablo 3.29.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.30. CoS Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1042 (1,75E-03)	0,0600 (2,89E-04)	0,1042 (1,68E-04)	0,1047 (3,58E-04)
epok= 100	0,1036 (2,81E-04)	0,0600 (3,68E-04)	0,1042 (2,09E-04)	0,1050 (4,53E-04)
epok= 150	0,1035 (1,93E-04)	0,0598 (2,78E-04)	0,1043 (1,94E-04)	0,1055 (5,42E-04)
epok= 200	0,1209 (9,56E-02)	0,1034 (3,13E-04)	0,1043 (2,11E-04)	0,1057 (6,47E-04)

Tablo 3.30.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.31. CoS Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,0642 (7,86E-03)	0,0611 (1,06E-04)	0,0623 (5,40E-04)	0,0674 (1,38E-02)
epok= 100	0,0610 (6,03E-04)	0,0611 (8,28E-04)	0,0624 (5,60E-04)	0,0647 (3,41E-03)
epok= 150	0,0586 (2,41E-04)	0,0611 (1,18E-04)	0,0626 (1,10E-03)	0,0685 (9,46E-03)
epok= 200	0,0542 (2,29E-04)	0,0611 (1,20E-04)	0,0631 (2,30E-03)	0,0663 (6,00E-03)

Tablo 3.31.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.32. CoS Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1164 (4,89E-04)	0,1156 (1,60E-03)	0,1152 (4,21E-04)	0,1132 (1,96E-04)
epok= 100	0,1160 (2,75E-04)	0,1152 (5,74E-04)	0,1150 (2,46E-04)	0,1130 (5,36E-04)
epok= 150	0,1160 (3,63E-04)	0,1152 (1,96E-04)	0,1151 (1,94E-04)	0,1128 (2,80E-04)
epok= 200	0,1159 (2,80E-04)	0,1152 (3,75E-04)	0,1150 (2,04E-04)	0,1148 (2,93E-04)

Tablo 3.32.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.33. CoS Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2800 (3,35E-02)	0,2338 (1,43E-02)	0,1971 (6,71E-03)	0,1765 (3,32E-03)
epok= 100	0,2010 (1,83E-02)	0,1833 (9,42E-03)	0,1757 (5,46E-03)	0,1620 (3,75E-03)
epok= 150	0,1807 (1,23E-02)	0,1688 (8,65E-03)	0,1603 (5,76E-03)	0,1496 (2,80E-03)
epok= 200	0,1696 (1,18E-02)	0,1591 (7,64E-03)	0,1522 (9,74E-03)	0,1597 (3,48E-02)

Tablo 3.33.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.34. CoS Kuyusu LSTM rsmprop algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2015 (2,43E-02)	0,1803 (1,51E-02)	0,1817 (7,92E-03)	0,1928 (2,07E-02)
epok= 100	0,1454 (1,28E-02)	0,1457 (1,17E-02)	0,1407 (7,06E-03)	0,1596 (8,86E-03)
epok= 150	0,1237 (7,43E-03)	0,1238 (9,18E-03)	0,1208 (1,25E-02)	0,1370 (1,72E-02)
epok= 200	0,1099 (7,06E-03)	0,1108 (1,28E-02)	0,1109 (1,01E-02)	0,1206 (1,63E-02)

Tablo 3.34.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.35. CoS Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2205 (2,67E-02)	0,1997 (9,73E-03)	0,2008 (6,82E-03)	0,2191 (3,82E-02)
epok= 100	0,1686 (1,00E-02)	0,1679 (1,04E-02)	0,1647 (7,08E-03)	0,1788 (8,45E-03)
epok= 150	0,1498 (6,72E-03)	0,1475 (1,20E-02)	0,1464 (9,38E-03)	0,1507 (9,67E-03)
epok= 200	0,1344 (3,96E-03)	0,1378 (1,78E-02)	0,1360 (7,46E-03)	0,1405 (1,38E-02)

Tablo 3.35.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.36. CoS Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.

	trainlm	trainbr	adam	rmsprop
t=1	0,0610 (4,47E-04)	0,0598 (2,78E-04)	0,1128 (2,80E-04)	0,1099 (7,06E-03)
t=2	0,0546 (3,12E-04)	0,0542 (2,29E-04)	0,1496 (2,80E-03)	0,1344 (3,96E-03)

Tablo 3.36.'deki sonuçlar incelendiğinde ortalama hata için, NAR-NN eğitiminde trainlm eğitim algoritması ve $t=2$ zaman gecikmesi uygulandığında iyi sonuçlar elde edildiği gözlemlenmiştir. Zaman gecikmesi artarken NAR-NN eğitiminde iyileşme görülürken LSTM eğitiminde ise kötüleşme görülmektedir. NAR-NN eğitiminde trainbr eğitim algoritması trainlm eğitim algoritmasında göre daha başarılı sonuçlar elde edilmiştir. LSTM eğitiminde ise rmsprop eğitim algoritması adam eğitim algoritmasına göre daha başarılı olduğu görülmektedir.

Tablo 3.37. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=1$ için RMSE sonuçları.

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1290 (6,98E-04)	0,1287 (9,19E-04)	0,1292 (1,29E-03)	0,1454 (7,22E-03)
epok = 100	0,1290 (1,87E-04)	0,1288 (3,17E-04)	0,1403 (1,99E-02)	0,1683 (9,60E-03)
epok = 150	0,1290 (7,46E-04)	0,1284 (1,45E-04)	0,1513 (2,69E-02)	0,1874 (1,45E-02)
epok = 200	0,1290 (8,80E-04)	0,1283 (9,79E-04)	0,1413 (2,43E-02)	0,2122 (1,91E-02)

Tablo 3.37.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.38. *DIEC Kuyusu NAR-NN trainlm algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1233 (9,25E-04)	0,1245 (7,36E-03)	0,1463 (2,90E-02)	0,1540 (2,47E-02)
epok= 100	0,1225 (9,10E-04)	0,1267 (1,56E-02)	0,1727 (4,75E-02)	0,1790 (4,20E-02)
epok= 150	0,1221 (1,05E-03)	0,1242 (7,52E-03)	0,1927 (5,58E-02)	0,1954 (4,79E-02)
epok= 200	0,1218 (9,59E-04)	0,1228 (2,86E-03)	0,2187 (8,29E-02)	0,2652 (1,22E-01)

Tablo 3.38.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 2 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.39. *DIEC Kuyusu NAR-NN trainbr algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1281 (7,03E-04)	0,1278 (1,45E-04)	0,1409 (1,57E-02)	0,1481 (1,08E-02)
epok= 100	0,1280 (5,68E-04)	0,1277 (1,17E-04)	0,1416 (1,36E-02)	0,1594 (5,23E-03)
epok= 150	0,1462 (9,98E-02)	0,1277 (7,69E-04)	0,1517 (2,21E-02)	0,1604 (6,13E-03)
epok= 200	0,1279 (2,19E-04)	0,1277 (1,33E-04)	0,1549 (2,07E-02)	0,1691 (1,10E-02)

Tablo 3.39.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 100, 150 ve 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.40. *DIEC Kuyusu NAR-NN trainbr algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,1227 (9,35E-04)	0,1215 (5,33E-04)	0,1221 (1,66E-03)	0,1233 (2,97E-03)
epok= 100	0,1217 (9,30E-04)	0,1214 (1,41E-03)	0,1240 (5,43E-03)	0,1247 (5,37E-03)
epok= 150	0,1213 (6,57E-04)	0,1211 (1,39E-03)	0,1217 (2,53E-03)	0,1347 (3,38E-02)
epok= 200	0,1215 (1,16E-03)	0,1210 (2,90E-03)	0,1233 (4,65E-03)	0,1273 (1,24E-02)

Tablo 3.40.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 10 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.41. *DIEC Kuyusu LSTM adam algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2772 (1,91E-02)	0,2566 (1,11E-02)	0,2404 (8,21E-03)	0,2209 (4,21E-03)
epok= 100	0,2403 (1,31E-02)	0,2186 (1,19E-02)	0,1952 (9,77E-03)	0,1956 (8,58E-03)
epok= 150	0,2025 (1,85E-02)	0,1731 (1,56E-02)	0,1506 (5,75E-03)	0,1747 (5,08E-03)
epok= 200	0,1799 (1,58E-02)	0,1460 (5,58E-03)	0,1384 (2,33E-03)	0,1618 (7,82E-03)

Tablo 3.41.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.42. *DIEC Kuyusu LSTM adam algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,3118 (1,93E-02)	0,2929 (9,35E-03)	0,2811 (5,81E-03)	0,2683 (3,12E-03)
epok= 100	0,2796 (9,75E-03)	0,2659 (7,12E-03)	0,2514 (6,22E-03)	0,2536 (4,46E-02)
epok= 150	0,2579 (1,17E-02)	0,2371 (1,06E-02)	0,2183 (4,21E-03)	0,2330 (3,29E-03)
epok= 200	0,2391 (1,01E-02)	0,2147 (6,10E-03)	0,2084 (3,41E-03)	0,2259 (6,26E-03)

Tablo 3.42.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.43. *DIEC Kuyusu LSTM rmsprop algoritması ve $t=1$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2610 (2,36E-02)	0,2246 (1,36E-02)	0,2174 (1,09E-02)	0,2301 (2,36E-02)
epok= 100	0,1839 (9,25E-03)	0,1749 (2,95E-02)	0,1747 (4,22E-02)	0,1788 (3,35E-02)
epok= 150	0,1541 (6,52E-03)	0,1505 (1,94E-02)	0,1379 (3,18E-03)	0,1627 (5,84E-02)
epok= 200	0,1409 (5,07E-03)	0,1409 (1,39E-02)	0,1421 (4,01E-02)	0,1434 (4,39E-02)

Tablo 3.43.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 30 ve epok sayısı 150 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.44. *DIEC Kuyusu LSTM rmsprop algoritması ve $t=2$ için RMSE sonuçları.*

	gkb=2	gkb=10	gkb=30	gkb=40
epok= 50	0,2877 (1,31E-02)	0,2701 (6,57E-03)	0,2632 (5,53E-03)	0,2740 (1,75E-02)
epok= 100	0,2439 (8,56E-03)	0,2331 (1,31E-02)	0,2320 (2,53E-02)	0,2366 (2,59E-02)
epok= 150	0,2187 (5,53E-03)	0,2138 (5,94E-03)	0,2198 (2,51E-02)	0,2148 (5,42E-03)
epok= 200	0,2098 (4,50E-03)	0,2094 (7,25E-03)	0,2165 (2,07E-02)	0,2073 (3,76E-03)

Tablo 3.44.'deki sonuçlar incelendiğinde ortalama hata için, gizli katman boyutu 40 ve epok sayısı 200 olduğunda daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Tablo 3.45. *DIEC Kuyusu NAR-NN ve LSTM RMSE en iyi sonuçları.*


	trainlm	trainbr	adam	rmsprop
t=1	0,1283 (9,79E-04)	0,1277 (1,17E-04)	0,1384 (2,33E-03)	0,1379 (3,18E-03)
t=2	0,1218 (9,59E-04)	0,1210 (2,90E-03)	0,2084 (3,41E-03)	0,2073 (3,76E-03)

Tablo 3.45.'deki sonuçlar incelendiğinde ortalama hata için, NAR-NN eğitiminde trainbr eğitim algoritması ve $t=2$ zaman gecikmesi uygulandığında iyi sonuçlar elde edildiği gözlemlenmiştir. Zaman gecikmesi artarken NAR-NN eğitiminde iyileşme görülürken LSTM eğitiminde ise kötüleşme görülmektedir. NAR-NN eğitiminde trainbr eğitim algoritması trainlm eğitim algoritmasında göre daha başarılı sonuçlar elde edilmiştir. LSTM eğitiminde ise rmsprop eğitim algoritması adam eğitim algoritmasına göre daha başarılı olduğu görülmektedir.


3.3 Grafıksel Sonuçlar

Bu bölümde tahmin sonuçları görselleri Şekil 3.1 - 3.40'da verilmiştir. Mavi çizgi orijinal veriyi, kırmızı çizgi ise tahmin sonucunu ifade etmektedir.


Şekil 3.1. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.2. LT2 Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.3. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.4. LT2 Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.5. LT2 Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.6. LT2 Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.7. LT2 Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.8. LT2Kuyusu LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.9. SAL Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.10. SAL Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.11. SAL Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.12. SAL Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.13. SAL Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.14. SAL Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.15. SAL Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.16. SAL Kuyusu LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.17. PAG Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.18. PAG Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.19. PAG Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.20. PAG Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.21. PAG Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.22. PAG Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.23. PAG Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.24. PAG LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.25. COS Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.26. COS Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.27. COS Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.28. COS Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.29. COS Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.30. COS Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.31. COS Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları




Şekil 3.32. COS LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.33. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.34. DIEC Kuyusu NAR-NN trainlm algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.35. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.36. DIEC Kuyusu NAR-NN trainbr algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.37. DIEC Kuyusu LSTM adam algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.




Şekil 3.38. DIEC Kuyusu LSTM adam algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.



Şekil 3.39. DIEC Kuyusu LSTM rmsprop algoritması ve $t=1$ için test verisi ve eğitim çıktısı sonuçları.



Şekil 3.40. DIEC LSTM rmsprop algoritması ve $t=2$ için test verisi ve eğitim çıktısı sonuçları.



DÖRDÜNCÜ BÖLÜM

SONUÇ VE TARTIŞMA

Bu tez çalışmasında, su temin ve dağıtım sistemlerinde yeraltı suyu seviyelerinin tahmini için Yapay Zekâ (YZ) tekniklerinin kullanımı incelenmiştir. Özellikle, Doğrusal Olmayan Otoregresif Sinir Ağı (NAR-NN) ve Uzun Kısa Süreli Bellek (LSTM) modelleri, AquiferAuser veri setinden alınan beş farklı kuyu verisi kullanılarak test edilmiştir.

Çalışma sonuçları, hem NAR-NN hem de LSTM modellerinin yeraltı suyu seviyelerinin tahmininde başarılı olabileceğini göstermiştir. NAR-NN modeli için, trainbr eğitim algoritması genellikle trainlm algoritmasından daha iyi sonuçlar vermiştir. LSTM modeli için ise, rmsprop eğitim algoritması adam algoritmasından daha başarılı bulunmuştur.

Genel olarak, NAR-NN modeli, LSTM modeline kıyasla daha düşük RMSE değerleri elde ederek daha doğru tahminler sağlamıştır. Bunun nedeni, NAR-NN modelinin zaman serilerindeki doğrusal olmayan ilişkileri modellemede daha etkili olabilmesidir. Ayrıca, zaman gecikmesinin artması NAR-NN modelinin performansını olumlu yönde etkilerken, LSTM modelinin performansını olumsuz yönde etkilemiştir. Bu durum, NAR-NN modelinin uzun vadeli bağımlılıkları yakalamada LSTM modelinden daha iyi olduğunu gösterebilir.

Bu tez çalışması, sınırlı sayıda veri seti ve YZ modeli kullanılarak gerçekleştirilmiştir. Bu nedenle, elde edilen sonuçların genelleştirilebilirliği sınırlı olabilir. Ayrıca, çalışma sadece yeraltı suyu seviyelerinin tahminine odaklanmıştır. Su temin ve dağıtım sistemlerindeki diğer değişkenlerin (örneğin, yağış, sıcaklık, pompaj oranları) tahmini için YZ tekniklerinin kullanımı gelecekteki çalışmalar için bir konu olabilir.

Bu tez çalışması, su temin ve dağıtım sistemlerinde YZ tekniklerinin kullanımı için birçok gelecek çalışma fırsatı sunmaktadır. Bunlardan bazıları şunlardır:

- Farklı coğrafi bölgelerden ve daha uzun zaman dilimlerini kapsayan veri setleri kullanılarak YZ modellerinin performansı daha kapsamlı bir şekilde değerlendirilebilir.
- Destek Vektör Makineleri (SVM), Rastgele Ormanlar (RF) ve Derin Öğrenme (DL) gibi diğer YZ modelleri, yeraltı suyu seviyelerinin tahmini için test edilebilir ve performansları NAR-NN ve LSTM modelleriyle karşılaştırılabilir.
- Farklı YZ modellerinin güçlü yönlerini birleştiren hibrit modeller, tahmin doğruluğunu artırmak için geliştirilebilir.
- Yağış, sıcaklık, pompaj oranları gibi diğer değişkenlerin tahmini için YZ teknikleri kullanılabilir ve bu tahminler, su kaynaklarının daha etkin yönetimi için kullanılabilir.
- YZ modellerinin karar verme süreçlerinin daha şeffaf hale getirilmesi, bu modellerin su kaynakları yönetiminde daha yaygın bir şekilde kullanılmasını sağlayabilir.
- Su temin ve dağıtım sistemlerinde YZ tekniklerinin kullanımı henüz emekleme aşamasındadır. Bu alanda yapılacak gelecek çalışmalar, su kaynaklarının daha sürdürülebilir bir şekilde yönetilmesine önemli katkılar sağlayabilir.

KAYNAKLAR

- Acea Smart Water Analytics. (2023). Kaggle. <https://www.kaggle.com/competitions/acea-water-prediction/data>
- Achylov, A., & Kaygın, B. (2022). RECYCLING WASTE VEGETABLE OILS. *Bartın University International Journal of Natural and Applied Sciences*, 5(2), 95-100.
- Adige, S., Kurban, R., Durmuş, A., & Karaköse, E. (2023). Classification of apple images using support vector machines and deep residual networks. *Neural Computing and Applications*, 35(16), 12073-12087.
- Aeschbach-Hertig, W., & Gleeson, T. (2012). Regional strategies for the accelerating global problem of groundwater depletion. *Nature Geoscience*, 5(12), 853-861.
- Akalın, B., & Demirbaş, M. B. (2022). Rehabilitasyon Hizmetlerinde Yapay Zekâ Uygulamaları. *Acta Infologica*, 6(2), 141-161.
- Alexakis, D. E. (2021). Linking DPSIR model and water quality indices to achieve sustainable development goals in groundwater resources. *Hydrology*, 8(2), 90.
- Anggoro, D. A., & Hajiati, S. (2023). Comparison of performance metrics level of restricted boltzmann machine and backpropagation algorithms in detecting diabetes mellitus disease. *Iraqi Journal of Science*, 907-921.
- Aslantaş, V., & Kurban, R. (2007). Yapay sinir ağları ve coğrafi bilgi sistemlerindeki uygulamaları. *TMMOB Harita Kadastro Mühendisleri Odası Ulusal Coğrafi Bilgi Sistemleri Kongresi*, 30.
- Asoka, A., Gleeson, T., Wada, Y., & Mishra, V. (2017). Relative contribution of monsoon precipitation and pumping to changes in groundwater storage in India. *Nature Geoscience*, 10(2), 109-117.
- Balasubramanian, R., & Saravanakumar, V. (2022). Climate sensitivity of groundwater systems in South India: Does it matter for agricultural income. *Climate change and community resilience: Insights from South Asia*, 143-156.
- Başbüyük, Z., Ekincioğlu, G., & Yavaşlı, D. D. (2020). Seyfe Gölü çevresinin (Kırşehir) yeraltı suyu kalitesinin coğrafi bilgi sistemleri (CBS) kullanılarak

- belirlenmesi. *Aksaray University Journal of Science and Engineering*, 4(1), 77-89.
- Becker, S., Zhang, Y., & Lee, A. A. (2020). Geometry of energy landscapes and the optimizability of deep neural networks. *Physical review letters*, 124(10), 108301.
- Bhattarai, N., Lobell, D. B., Balwinder-Singh, Fishman, R., Kustas, W. P., Pokhrel, Y., & Jain, M. (2023). Warming temperatures exacerbate groundwater depletion rates in India. *Science Advances*, 9(35), eadi1401.
- Castro, W., Oblitas, J., Santa-Cruz, R., & Avila-George, H. (2017). Multilayer perceptron architecture optimization using parallel computing techniques. *PloS one*, 12(12), e0189369.
- Chen, H., Wu, M., Duan, Z., Zha, Y., Wang, S., Yang, L., ... & Zhang, W. (2023). Forecasting the human and climate impacts on groundwater resources in the irrigated agricultural region of North China Plain. *Hydrological Processes*, 37(3), e14853.
- Chetpattananondh, K., Tapoanoi, T., Phukpattaranont, P., & Jindapetch, N. (2014). A self-calibration water level measurement using an interdigital capacitive sensor. *Sensors and Actuators A: Physical*, 209, 175-182.
- Collenteur, R. A., Bakker, M., Klammler, G., & Birk, S. (2021). Estimation of groundwater recharge from groundwater levels using nonlinear transfer function noise models and comparison to lysimeter data. *Hydrology and Earth System Sciences*, 25(5), 2931-2949.
- Costantini, M., Colin, J., & Decharme, B. (2023). Projected water table depth changes of the world's major groundwater basins. *Authorea Preprints*.
- Cozzarelli, I. M., Schreiber, M. E., Erickson, M. L., & Ziegler, B. A. (2016). Arsenic cycling in hydrocarbon plumes: secondary effects of natural attenuation. *Groundwater*, 54(1), 35-45.
- Cömert, Z., & Kocamaz, A. (2017). A study of artificial neural network training algorithms for classification of cardiocography signals. *Bitlis Eren University journal of science and technology*, 7(2), 93-103.

- Cuthbert, M. O., Gleeson, T., Moosdorf, N., Befus, K. M., Schneider, A., Hartmann, J., & Lehner, B. (2019). Global patterns and dynamics of climate–groundwater interactions. *Nature Climate Change*, 9(2), 137-141.
- Deines, J. M., Kendall, A. D., Butler, J. J., & Hyndman, D. W. (2019). Quantifying irrigation adaptation strategies in response to stakeholder-driven groundwater management in the US High Plains Aquifer. *Environmental Research Letters*, 14(4), 044014.
- Deng, X., Zhang, L., Xu, R., Zeng, M., He, Q., Xu, D., & Qi, Y. (2022). Do cooperatives affect groundwater protection? Evidence from rural China. *Agriculture*, 12(7), 1016.
- Denisov, I. A. (2017). Luciferase-based bioassay for rapid pollutants detection and classification by means of multilayer artificial neural networks. *Sensors and Actuators B: Chemical*, 242, 653-657.
- Döll, P. (2009). Vulnerability to the impact of climate change on renewable groundwater resources: a global-scale assessment. *Environmental Research Letters*, 4(3), 035006.
- Eamus, D., Froend, R., Loomes, R., Hose, G., & Murray, B. (2006). A functional methodology for determining the groundwater regime needed to maintain the health of groundwater-dependent vegetation. *Australian Journal of Botany*, 54(2), 97-114.
- Eltner, A., Elias, M., Sardemann, H., & Spieler, D. (2018). Automatic image-based water stage measurement for long-term observations in ungauged catchments. *Water Resources Research*, 54(12), 10-362.
- Erşahin, S., & Bilgili, B. C. (2023). Nitrates in Turkish waters: Sources, mechanisms, impacts, and mitigation. *Environmental Science and Pollution Research*, 30(42), 95250-95271.
- Fahs, M., Koohbor, B., Shao, Q., Doummar, J., Baalousha, H. M., & Voss, C. I. (2022). Effect of Flow-Direction-Dependent Dispersivity on Seawater Intrusion in Coastal Aquifers. *Water Resources Research*, 58(8), e2022WR032315.

- Fang, X., Papaioannou, N., Leach, F., & Davy, M. H. (2021). On the application of artificial neural networks for the prediction of NO_x emissions from a high-speed direct injection diesel engine. *International Journal of Engine Research*, 22(6), 1808-1824.
- Foster, S. S. D., & Chilton, P. J. (2003). Groundwater: the processes and global significance of aquifer degradation. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 358(1440), 1957-1972.
- Foster, S., Pulido-Bosch, A., Vallejos, Á., Molina, L., Llop, A., & MacDonald, A. M. (2018). Impact of irrigated agriculture on groundwater-recharge salinity: a major sustainability concern in semi-arid regions. *Hydrogeology Journal*, 26(8), 2781-2791.
- Gao, Z., Shi, M., Zhang, H., Feng, J., Fang, S., & Cui, Y. (2020). Formation and in situ treatment of high fluoride concentrations in shallow groundwater of a semi-arid region: Jiaolai Basin, China. *International Journal of environmental research and public health*, 17(21), 8075.
- Gençoğlu, C., Tüysüz, M. D., & Gençoğlu, S. (2023). Evaluation of Water Levels and Flow Rates Measured in Irrigation Canal Using Limnigraph, Pressure and Ultrasonic Sensors. *Tekirdağ Ziraat Fakültesi Dergisi*, 20(3), 642-652.
- Gibert, J., & Culver, D. C. (2009). Assessing and conserving groundwater biodiversity: an introduction. *Freshwater Biology*, 54(4), 639-648.
- Giordano, M. (2009). Global groundwater? Issues and solutions. *Annual review of Environment and Resources*, 34(1), 153-178.
- Gleeson, T. (2020). Global groundwater sustainability. *Groundwater*, 58(4), 484-485.
- Gleeson, T., Huggins, X., & Curran, D. (2022). Applying a science-forward approach to groundwater regulatory design.
- Goderniaux, P., Brouyere, S., Blenkinsop, S., Burton, A., Fowler, H. J., Orban, P., & Dassargues, A. (2011). Modeling climate change impacts on groundwater resources using transient stochastic climatic scenarios. *Water Resources Research*, 47(12).

- Golpour, I., Ferrão, A. C., Gonçalves, F., Correia, P. M., Blanco-Marigorta, A. M., & Guiné, R. P. (2021). Extraction of phenolic compounds with antioxidant activity from strawberries: Modelling with artificial neural networks (ANNs). *Foods*, 10(9), 2228.
- Gouravaraju, S., Narayan, J., Sauer, R. A., & Gautam, S. S. (2023). A Bayesian regularization-backpropagation neural network model for peeling computations. *The Journal of Adhesion*, 99(1), 92-115.
- Gönül, Y., Ulu, Ş., Bucak, A., & Bilir, A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. *Genel Tıp Dergisi*, 25(3), 104-111.
- Green, T. R., Taniguchi, M., Kooi, H., Gurdak, J. J., Allen, D. M., Hiscock, K. M., ... & Aureli, A. (2011). Beneath the surface of global change: Impacts of climate change on groundwater. *Journal of Hydrology*, 405(3-4), 532-560.
- Guo, Z. C., Shi, L., & Lin, S. B. (2019). Realizing data features by deep nets. *IEEE Transactions on Neural Networks and Learning Systems*, 31(10), 4036-4048.
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6), 989-993.
- Hamidi, M. J., Larabi, A., & Faouzi, M. (2021). Modeling and Mapping of coastal aquifer vulnerability to seawater intrusion using SEAWAT code and GALDIT index technique: the case of the Rmel aquifer–Larache, Morocco. In *E3S Web of Conferences* (Vol. 298, p. 05002). EDP Sciences.
- He, S., Sepehri, N., & Unbehauen, R. (2001). Modifying weights layer-by-layer with levenberg-marquardt backpropagation algorithm. *Intelligent Automation & Soft Computing*, 7(4), 233-247.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Holland, M., Thomas, C., Livneh, B., Tatge, S., Johnson, A., & Thomas, E. (2022). Development and Validation of an In Situ Groundwater Abstraction Sensor Network, Hydrologic Statistical Model, and Blockchain Trading Platform: A Demonstration in Solano County, California. *ACS Es&t Water*, 2(12), 2345-2358.

- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- Hu, F., Yu, X., Chu, H., Zhao, L., Jude, U., & Jiang, T. (2018). Similar effects for resting state and unconscious thought: Both solve multi-attribute choices better than conscious thought. *Frontiers in psychology*, 9, 1360.
- Ibrahim, M., Jemei, S., Wimmer, G., & Hissel, D. (2016). Nonlinear autoregressive neural network in an energy management strategy for battery/ultra-capacitor hybrid electrical vehicles. *Electric Power Systems Research*, 136, 262-269.
- Indika, S., Wei, Y., Cooray, T., Ritigala, T., Jinadasa, K. B. S. N., Weragoda, S. K., & Weerasooriya, R. (2022). Groundwater-based drinking water supply in Sri Lanka: Status and perspectives. *Water*, 14(9), 1428.
- Ismail, H. T. H. (2022). Assessment toxic effects of exposure to 3-indoleacetic acid via hemato-biochemical, hormonal, and histopathological screening in rats. *Environmental Science and Pollution Research*, 29(60), 90703-90718.
- Jia, J., & Duan, H. (2017). Automatic target recognition system for unmanned aerial vehicle via backpropagation artificial neural network. *Aircraft Engineering and Aerospace Technology*, 89(1), 145-154.
- Jia, Z. A., Wei, L., Wu, Y. C., Guo, G. C., & Guo, G. P. (2020). Entanglement area law for shallow and deep quantum neural network states. *New Journal of Physics*, 22(5), 053022.
- Khan, I., Raja, M. A. Z., Shoaib, M., Kumam, P., Alrabaiah, H., Shah, Z., & Islam, S. (2020). Design of neural network with Levenberg-Marquardt and Bayesian regularization backpropagation for solving pantograph delay differential equations. *IEEE Access*, 8, 137918-137933.
- Khidir, A. M., Adlan, H. H. A., & Basheir, I. A. (2013, August). Neural Networks forecasting architectures for rainfall in the rain-fed Sectors in Sudan. In *2013 International Conference On Computing, Electrical And Electronic Engineering (ICCEEE)* (pp. 700-707). IEEE.

- Kim, D., & Lekic, V. (2019). Groundwater variations from autocorrelation and receiver functions. *Geophysical Research Letters*, 46(23), 13722-13729.
- KIYICI, İ., DORUK, İ., ÇOMAK, E., KAÇAMAZ, M., & BAKLAN, R. O. (2022). Halojensiz ve alev geciktiricili (HFFR) polimerik kompozit kılıflı kablo kopma uzaması test sonuçlarının makine öğrenmesi yöntemleri kullanılarak tahmin edilmesi. *Pamukkale University Journal of Engineering Sciences*, 28(5).
- Knierim, K. J., Nottmeier, A. M., Worland, S., Westerman, D. A., & Clark, B. R. (2017). Challenges for creating a site-specific groundwater-use record for the Ozark Plateaus aquifer system (central USA) from 1900 to 2010. *Hydrogeology Journal*, 25(6), 1779-1793.
- Kumar, A., & Sodhi, S. S. (2022). Effect of Hidden Neuron Size on Different Training Algorithm in Neural Network. *Communications in Mathematics and Applications*, 13(1), 351.
- Kumar, P. A., & Anuradha, B. (2018). Reflectivity Parameter Extraction from RADAR Images Using Back Propagation Algorithms. *International Journal of Electrical & Computer Engineering (2088-8708)*, 8(5).
- Les Landes, A. A., Aquilina, L., De Ridder, J., Longuevergne, L., Pagé, C., & Goderniaux, P. (2014). Investigating the respective impacts of groundwater exploitation and climate change on wetland extension over 150 years. *Journal of Hydrology*, 509, 367-378.
- Lee, J. Y., Cha, J., & Raza, M. (2021). Groundwater development, use, and its quality in Korea: tasks for sustainable use. *Water Policy*, 23(6), 1375-1387.
- Lee, S., Hyun, Y., & Lee, M. J. (2019). Groundwater potential mapping using data mining models of big data analysis in Goyang-si, South Korea. *Sustainability*, 11(6), 1678.
- Li, S., Duan, Q., Chu, X., & Yang, C. (2019). Fluviograph design based on an ultra-small pressure sensor. *Sensors*, 19(21), 4615.
- Lin, X., McKinley, J., Resch, C. T., Kaluzny, R., Lauber, C. L., Fredrickson, J., ... & Konopka, A. (2012). Spatial and temporal dynamics of the microbial community in the Hanford unconfined aquifer. *The ISME journal*, 6(9), 1665-1676.

- Long, Y., Huang, T., Zhang, F., Li, Z., Ma, B., Li, Y., & Pang, Z. (2021). Origin of sulphate in the unsaturated zone and groundwater of a loess aquifer. *Hydrological Processes*, 35(4), e14166.
- López, M., Valero, S., Senabre, C., Aparicio, J., & Gabaldon, A. (2012). Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study. *Electric Power Systems Research*, 91, 18-27.
- Ma, C., & Yin, L. (2021). Deep flexible transmitter networks for non-intrusive load monitoring of power distribution networks. *IEEE Access*, 9, 107424-107436.
- Malakar, P., Bhanja, S. N., Dash, A. A., Saha, D., Ray, R. K., Sarkar, S., ... & Mukherjee, A. (2022). Delineating Variabilities of Groundwater Level Prediction Across the Agriculturally Intensive Transboundary Aquifers of South Asia. *ACS ES&T Water*, 3(6), 1547-1560.
- Malenda, H. F., & Penn, C. A. (2020). *Groundwater levels in the Denver Basin bedrock aquifers of Douglas County, Colorado, 2011–19* (No. 2020-5076). US Geological Survey.
- Manghi, F., Mortazavi, B., Crother, C., & Hamdi, M. R. (2009). Estimating regional groundwater recharge using a hydrological budget method. *Water resources management*, 23, 2475-2489.
- Maréchal, J. C., Dewandel, B., Ahmed, S., Galeazzi, L., & Zaidi, F. K. (2006). Combined estimation of specific yield and natural recharge in a semi-arid groundwater basin with irrigated agriculture. *Journal of Hydrology*, 329(1-2), 281-293.
- Masood, A., Tariq, M. A. U. R., Hashmi, M. Z. U. R., Waseem, M., Sarwar, M. K., Ali, W., ... & Ng, A. W. (2022). An overview of groundwater monitoring through point-to satellite-based techniques. *Water*, 14(4), 565.
- McDonough, L. K., Santos, I. R., Andersen, M. S., O'Carroll, D. M., Rutledge, H., Meredith, K., ... & Baker, A. (2020). Changes in global groundwater organic carbon driven by climate change and urbanization. *Nature Communications*, 11(1), 1279.
- Medeiros, E. (2021). The territorial dimension of the united nations sustainable development goals. *Area*, 53(2), 292-302.

- Meyer, C. (2017). GRAPHIC - Groundwater and Climate Change - Mitigating the Global Groundwater Crisis and Adapting to Climate Change Impacts - Position Paper and Call To Action. <https://doi.org/10.29104/wins.d.0036.2018>
- Miguez, G., Xavier, A. E., & Maculan, N. (2014). An evaluation of the bihyperbolic function in the optimization of the backpropagation algorithm. *International Transactions in Operational Research*, 21(5), 835-854.
- Mirnezami, S. J., de Boer, C., & Bagheri, A. (2020). Groundwater governance and implementing the conservation policy: The case study of Rafsanjan Plain in Iran. *Environment, Development and Sustainability*, 22(8), 8183-8210.
- Rahman, A. K. M. M. M., & Roy, C. K. (2016). Embedded emotion-based classification of stack overflow questions towards the question quality prediction. In *Proc. 28th Int. Conf. Softw. Eng. Knowl. Eng.* (pp. 521-526).
- Monir, M. M., Sarker, S. C., Sarker, S. K., Ahmed, M., Mallick, J., & Islam, A. R. M. T. (2022). Spatiotemporal depletion of groundwater level in a drought-prone Rangpur district, northern region of Bangladesh.
- Muhammad, Y., & Vaino, D. (2019). Controlling Electronic Devices with brain rhythms/electrical activity using artificial neural network (ANN). *Bioengineering*, 6(2), 46.
- Nawi, N. M., Khan, A., & Rehman, M. Z. (2013). A new cuckoo search based Levenberg-Marquardt (CSLM) algorithm. In *Computational Science and Its Applications–ICCSA 2013: 13th International Conference, Ho Chi Minh City, Vietnam, June 24-27, 2013, Proceedings, Part I 13* (pp. 438-451). Springer Berlin Heidelberg.
- Ni, Z., He, H., Prokhorov, D. V., & Fu, J. (2011, July). An online actor-critic learning approach with Levenberg-Marquardt algorithm. In *The 2011 International Joint Conference on Neural Networks* (pp. 2333-2340). IEEE.
- Nikmatya, U., Kustiyo, A., & Jayanegara, A. (2022). Pengembangan model Bayesian regularization backpropagation untuk estimasi nilai nutrisi berdasarkan komposisi kimia pakan ternak ruminansia. *Jurnal Ilmu Komputer dan Agri-Informatika*, 9(2), 168-176.

- Niu, B., Loaiciga, H. A., Wang, Z., Zhan, F. B., & Hong, S. (2014). Twenty years of global groundwater research: A Science Citation Index Expanded-based bibliometric survey (1993–2012). *Journal of Hydrology*, 519, 966-975.
- Nowak, M., & Sobota, I. (2015). Artificial neural networks in proglacial discharge simulation: application and efficiency analysis in comparison to the multivariate regression; a case study of Waldemar River (Svalbard). *Geografiska Annaler: Series A, Physical Geography*, 97(3), 489-506.
- Nyanteh, Y. D., Srivastava, S. K., Edrington, C. S., & Cartes, D. A. (2013). Application of artificial intelligence to stator winding fault diagnosis in Permanent Magnet Synchronous Machines. *Electric Power Systems Research*, 103, 201-213.
- Ouyang, Y., Wan, Y., Jin, W., Leininger, T. D., Feng, G., & Han, Y. (2021). Impact of climate change on groundwater resource in a region with a fast depletion rate: the Mississippi Embayment. *Journal of water and climate change*, 12(6), 2245-2255.
- ÖZKAN, C., ÖZTÜRK, C., Sunar, F., & KARABOĞA, D. (2011). The artificial bee colony algorithm in training artificial neural network for oil spill detection. *Neural Network World*, 21(6).
- Parvin, M., Tadakuma, N., Asaue, H., & Koike, K. (2011). Characterizing the regional pattern and temporal change of groundwater levels by analyses of a well log data set. *Frontiers of Earth Science*, 5, 294-304.
- Petitta, M., Kreamer, D., Davey, I., Dottridge, J., MacDonald, A., Re, V., & Szócs, T. (2023). Topical Collection: International Year of Groundwater—managing future societal and environmental challenges. *Hydrogeology Journal*, 31(1), 1-6.
- Petpongpan, C., Ekkawatpanit, C., & Kositgittiwong, D. (2020). Climate change impact on surface water and groundwater recharge in Northern Thailand. *Water*, 12(4), 1029.
- Pratoomchai, W., Kazama, S., Hanasaki, N., Ekkawatpanit, C., & Komori, D. (2014). A projection of groundwater resources in the Upper Chao Phraya River basin in Thailand. *Hydrological Research Letters*, 8(1), 20-26.
- Purnawan, M. Y., Hendrayana, H., & Setijadji, L. D. (2022, August). Reducing groundwater use and mitigating floods through increasing surface water

- utilization in the Cimahi Region of West Java Indonesia. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1071, No. 1, p. 012003). IOP Publishing.
- Qi, Z., Xiao, C., Wang, G., & Liang, X. (2021). Study on ecological threshold of groundwater in typical salinization area of Qian'an County. *Water*, 13(6), 856.
- Queen, T. L., & Hess, T. M. (2010). Age differences in the effects of conscious and unconscious thought in decision making. *Psychology and Aging*, 25(2), 251.
- Reddy, G. S. K., Koteswararao, N. V., Ravi, R., Paidipati, K. K., & Chesneau, C. (2022). Dissolution-Driven Convection in a Porous Medium Due to Vertical Axis of Rotation and Magnetic Field. *Mathematical and Computational Applications*, 27(3), 53.
- Reinecke, R., Gnann, S., Stein, L., Bierkens, M., de Graaf, I., Gleeson, T., ... & Wagener, T. (2023). Global accessibility of groundwater remains highly uncertain. *EarthArXiv eprints*, X5SM0R.
- Reynaldi, A., Lukas, S., & Margaretha, H. (2012, November). Backpropagation and Levenberg-Marquardt algorithm for training finite element neural network. In *2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation* (pp. 89-94). IEEE.
- Richey, A. S., Thomas, B. F., Lo, M. H., Reager, J. T., Famiglietti, J. S., Voss, K., ... & Rodell, M. (2015). Quantifying renewable groundwater stress with GRACE. *Water resources research*, 51(7), 5217-5238.
- Roy, R. B., Rokonuzzaman, M., Amin, N., Mishu, M. K., Alahakoon, S., Rahman, S., ... & Pasupuleti, J. (2021). A comparative performance analysis of ANN algorithms for MPPT energy harvesting in solar PV system. *IEEE Access*, 9, 102137-102152.
- Ruiz, L. G. B., Cuéllar, M. P., Calvo-Flores, M. D., & Jiménez, M. D. C. P. (2016). An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. *Energies*, 9(9), 684.
- Sağiroğlu, Ş. E. R. E. F., Erler, M., & Beşdok, E. (2003). Mühendislikte yapay zeka uygulamaları-I: yapay sinir ağları.

- Salvia, A. L., Leal Filho, W., Brandli, L. L., & Griebeler, J. S. (2019). Assessing research trends related to Sustainable Development Goals: Local and global issues. *Journal of cleaner production*, 208, 841-849.
- Sarigiannis, D. A., Karakitsios, S. P., Gotti, A., Papaloukas, C. L., Kassomenos, P. A., & Pilidis, G. A. (2009). Bayesian algorithm implementation in a real time exposure assessment model on benzene with calculation of associated cancer risks. *Sensors*, 9(02), 731-755.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Seidel, A., Seidel, P., Manuwald, O., & Herbarth, O. (2015). Modified nucleosides as biomarkers for early cancer diagnose in exposed populations. *Environmental toxicology*, 30(8), 956-967.
- Singha, K., & Navarre-Sitchler, A. (2022). The importance of groundwater in critical zone science. *Groundwater*, 60(1), 27-34.
- Smerdon, B. D., Mendoza, C. A., & Devito, K. J. (2008). Influence of subhumid climate and water table depth on groundwater recharge in shallow outwash aquifers. *Water Resources Research*, 44(8).
- Smerdon, B. D., Redding, T., & Beckers, J. (2009). An overview of the effects of forest management on groundwater hydrology. *Journal of Ecosystems and Management*.
- Janardhanan, S., Nair, A. S., Indu, J., Pagendam, D., & Kaushika, G. S. (2023). Estimation of groundwater storage loss for the Indian Ganga Basin using multiple lines of evidence. *Scientific Reports*, 13(1), 1797.
- Su Döngüsü. (2024). Wikipedia.
https://tr.wikipedia.org/wiki/Su_d%C3%B6ng%C3%BCs%C3%BC
- Sürdürülebilir Kalkınma Hedefleri. (2024). United Nation.
<https://www.skdturkiye.org/haber/surdurulebilir-kalkinma-hedefleri-ve-is-dunyasi>
- Şentürk, A., & Şentürk, Z. K. (2021). Yapay sinir ağları ile göğüs kanseri tahmini. *El-Cezeri*, 3(2).

- Şentürk, R., Kurban, R., & Çakıroğlu, F. (2023, December). Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini. In *SETSCI-Conference Proceedings* (Vol. 15, pp. 59-63). SETSCI-Conference Proceedings.
- Tanachaichoksirikun, P., Seeboonruang, U., & Saraphirom, P. (2018). Impact of climate change on the groundwater sustainability in the lower Chao Phraya basin, Thailand. In *MATEC web of conferences* (Vol. 192, p. 02006). EDP Sciences.
- Thomas, B. F., & Famiglietti, J. S. (2019). Identifying climate-induced groundwater depletion in GRACE observations. *Scientific reports*, 9(1), 4124.
- Tolera, M. B., & Chung, I. M. (2021). Integrated hydrological analysis of little Akaki watershed using SWAT-MODFLOW, Ethiopia. *Applied Sciences*, 11(13), 6011.
- De Vries, J. J., & Simmers, I. (2002). Groundwater recharge: an overview of processes and challenges. *Hydrogeology journal*, 10, 5-17.
- Wada, Y., Van Beek, L. P., Van Kempen, C. M., Reckman, J. W., Vasak, S., & Bierkens, M. F. (2010). Global depletion of groundwater resources. *Geophysical research letters*, 37(20).
- Wahyudi, M., & Pujiastuti, L. (2022). Application of Neural Network Variations for Determining the Best Architecture for Data Prediction. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(5), 742-748.
- Shidong, W., Tiantian, W., Lei, S., Zhibin, Y., Hongpu, T., Hanjiang, L., ... & Gang, F. (2021). Hydrogeochemical Characteristics and Formation Processes of Ordovician Limestone Groundwater in Zhuozishan Coalfield, Northwest China.
- Wang, S. J., Lee, C. H., Yeh, C. F., Choo, Y. F., & Tseng, H. W. (2021). Evaluation of climate change impact on groundwater recharge in groundwater regions in Taiwan. *Water*, 13(9), 1153.
- Wood, W. W., & Hyndman, D. W. (2017). Groundwater depletion: a significant unreported source of atmospheric carbon dioxide. *Earth's Future* 5.
- Wossenyeleh, B. K., Worku, K. A., Verbeiren, B., & Huysmans, M. (2020). Drought propagation and its impact on groundwater hydrology of wetlands. *Natural Hazards and Earth System Sciences Discussions*, 2020, 1-27.

- Wu, W. Y., Lo, M. H., Wada, Y., Famiglietti, J. S., Reager, J. T., Yeh, P. J. F., ... & Yang, Z. L. (2020). Divergent effects of climate change on future groundwater availability in key mid-latitude aquifers. *Nature communications*, 11(1), 3710.
- Yagbasan, O. (2016). Impacts of climate change on groundwater recharge in Küçük Menderes River Basin in Western Turkey. *Geodinamica Acta*, 28(3), 209-222.
- Yang, W., Long, D., Scanlon, B. R., Burek, P., Zhang, C., Han, Z., ... & Wada, Y. (2022). Human intervention will stabilize groundwater storage across the North China Plain. *Water Resources Research*, 58(2), e2021WR030884.
- Ye, Z., & Kim, M. K. (2018). Predicting electricity consumption in a building using an optimized back-propagation and Levenberg–Marquardt back-propagation neural network: Case study of a shopping mall in China. *Sustainable Cities and Society*, 42, 176-183.
- Yetiz, F., Terzioğlu, M., & Kayakuş, M. (2021). Makina öğrenmesi yöntemleri ile Türk mevduat bankalarının müşteri tahminine yönelik bir uygulama. *Sosyoekonomi*, 29(50), 413-432.
- Lihe, Y., Guangcai, H., Zhengping, T., & Ying, L. (2010). Origin and recharge estimates of groundwater in the ordos plateau, People's Republic of China. *Environmental Earth Sciences*, 60, 1731-1738.
- Van Zanten, J. A., & Van Tulder, R. (2018). Multinational enterprises and the Sustainable Development Goals: An institutional approach to corporate engagement. *Journal of International Business Policy*, 1(3), 208-233.
- Zhang, J., Wang, F., Yalamarty, S. S. K., Filipczak, N., Jin, Y., & Li, X. (2022). Nano silver-induced toxicity and associated mechanisms. *International journal of nanomedicine*, 1851-1864.
- Zucatelli, P. J., Nascimento, E. G. S., Aylas, G. Y. R., Souza, N. B. P., Kitagawa, Y. K. L., Santos, A. A. B., ... & Moreira, A. M. (2019). Short-term wind speed forecasting in Uruguay using computational intelligence. *Heliyon*, 5(5).

Yapay Zekâ Teknikleri Kullanarak Su Temin ve Dağıtım Sistemlerinde Zaman Serileri Tahmini

Yazar Ramazan ŞENTÜRK

Gönderim Tarihi: 27-Tem-2024 01:57AM (UTC+0300)

Gönderim Numarası: 2422940588

Dosya adı: emin_ve_Da_t_m_Sistemlerinde_Zaman_Serileri_Tahmini_Turnitin.pdf (3.59M)

Kelime sayısı: 13544

Karakter sayısı: 80120

Yapay Zekâ Teknikleri Kullanarak Su Temin ve Dağıtım Sistemlerinde Zaman Serileri Tahmini

ORJİNALLİK RAPORU

% 0	% 0	% 0	% 0
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	dergipark.org.tr İnternet Kaynağı	<% 1
----------	---	----------------

Alıntıları çıkart

Kapat

Eşleştirmeleri çıkar

Kapat

Bibliyografyayı Çıkart üzerinde

ÖZGEÇMİŞ

1. İletişim Bilgileri

Adı Soyadı : Ramazan Şentürk

Uyruğu : T.C.

2. Öğrenim Durumu

Derece	Alan	Üniversite	Yıl
Ön Lisans	Bilgisayar Programcılığı	Kayseri Üniversitesi	2023
Lisans	Mekatronik Mühendisliği	Erciyes Üniversitesi	2014

3. Yabancı Dil : İngilizce

4. İş Deneyimleri (Varsa)

Yıl	Kurum	Görev
2013-halen	Envest Enerji ve Su Teknolojileri Ltd. Şti.	Planlama ve Üretim Müdürü

5. Yayınlar

Şentürk, R., Kurban, R., & Çakıroğlu, F. (2023). Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini. Cognitive Models and Artificial Intelligence Conference 26-28 Ekim 2023, Ankara, Türkiye,