

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**STANDARDİZE YERALTI SUYU İNDİSİNİN MAKİNE ÖĞRENMESİ VE VERİ
AYRIŞTIRMA TEKNİKLERİ KULLANILARAK MODELLENMESİ**

Erdal KOÇ

Danışman: Dr. Öğr. Üyesi Okan Mert KATİPOĞLU

TEZ JÜRİ ÜYELERİ

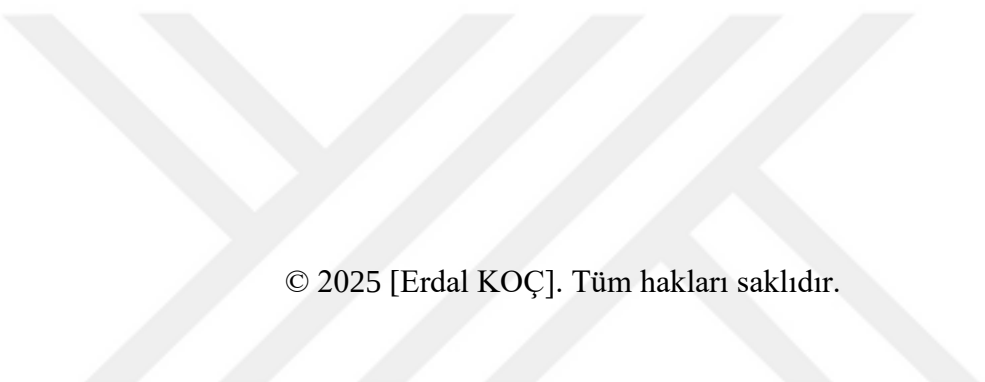
Dr. Öğr. Üyesi Gaye AKTÜRK

Dr. Öğr. Üyesi Zeynep Özge TERZİOĞLU

Dr. Öğr. Üyesi Okan Mert KATİPOĞLU

YÜKSEK LİSANS TEZİ

ERZİNCAN, 2025



© 2025 [Erdal KOÇ]. Tüm hakları saklıdır.

ÖZET

STANDARDİZE YERALTI SUYU İNDİSİNİN MAKİNE ÖĞRENMESİ VE VERİ AYRIŞTIRMA TEKNİKLERİ KULLANILARAK MODELLENMESİ

Erdal KOÇ

Yüksek Lisans Tezi, Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü,

İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Okan Mert KATİPOĞLU

2025, 63 sayfa

Çalışma kapsamında Erzincan ilindeki yeraltı suyu indisi (SGI) değerlerinin tahmini için Tekil Spektrum Analizi (SSA), Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS), Kategorik Artırma (CatBoost), Evrişimsel Sinir Ağı (CNN), Otokodlayıcı (Autoencoder), Derin Sinir Ağı (DNN), Kapılı Tekrarlayan Birim (GRU) ve Uzun Kısa Süreli Bellek (LSTM) modelleri kullanılmıştır. SSA veri ayırıştırma tekniği ile yenilikçi derin öğrenme ve makine öğrenmesi yaklaşımları birleştirilerek SGI tahmin performansı üzerine etkisi değerlendirilmiştir. SSA ile yağış, rölatif nem, sıcaklık ve gecikmeli SGI değerlerine ait trend, mevsimsellik, döngüsellik ve gürültü gibi farklı bileşenlere ayrılmış ve bu bileşenler AI modellerine sunularak hibrit yaklaşımlar kurulmuştur. Model performansı çeşitli istatistiksel metriklerle ve grafiklere göre analiz edilmiştir. Sonuç olarak tüm alt bileşenlerin AI modeline girdi olarak kullanılması ile kurulan hibrit yaklaşımlar aylık SGI tahmin doğruluğunu çoğunlukla artırırken, 12 aylık SGI tahminlerini ise artış ve azalışlar gözlenmiştir. Ayrıca gürültü bileşenlerinin atılarak kurulan SGI tahmin performansının ve modelin genelleme yeteneğinin arttığı dikkat çekmiştir. Ek olarak yapay sinir ağları ve bulanık mantık sistemlerini birleştiren hibrit ANFIS yaklaşımının yeraltı suyu kuraklığının en iyi tahmin eden model olduğunun ortaya çıkarmaktadır. Tahmin modellerinde etkili parametrenin ortaya çıkarılması için ANFIS tahmin çıktılarına Sobol duyarlılık analizi uygulanmıştır. Buna göre SGI 1 (t) değerlerinin tahmininde rölatif nem ve SGI-1 (t-1) değerlerin en yüksek etkiye sahip olduğu saptanmıştır.

Anahtar Kelimeler: derin öğrenme, kuraklık, standardize yeraltı suyu indisi, sobol duyarlılık analizi, tahmin.

ABSTRACT

MODELING OF STANDARDIZED GROUNDWATER INDEX USING MACHINE LEARNING AND DATA DECOMPOSITION TECHNIQUES

Erdal KOÇ

**Master's Thesis, Erzincan Binali Yıldırım University, Institute of Science and
Technology,**

Department of Civil Engineering

Advisor Dr. Öğr. Üyesi Okan Mert KATİPOĞLU

2025, 63 pages

In this study, Singular Spectrum Analysis (SSA), Adaptive Neural Fuzzy Inference System (ANFIS), Categorical Boosting (CatBoost), Convolutional Neural Network (CNN), Autoencoder, Deep Neural Network (DNN), Gated Recurrent Unit (GRU) and Long Short Term Memory (LSTM) models were used to predict groundwater index (SGI) values in Erzincan province. The SSA data parsing technique was combined with innovative deep learning and machine learning approaches to evaluate its impact on SGI forecast performance. With SSA, rainfall, relative humidity, temperature and lagged SGI values are separated into different components such as trend, seasonality, cyclical components and noise, and these components are presented to artificial intelligence models and hybrid approaches are established. Model performance is analyzed according to various statistical metrics and graphs. As a result, hybrid approaches with all sub-components as inputs to the artificial intelligence model mostly increase the monthly SGI forecast accuracy, while increases and decreases are observed in the 12-month SGI forecasts. It was also noted that the SGI prediction performance and generalization ability of the model increased by removing noise components. In addition, it is revealed that the hybrid ANFIS approach combining artificial neural networks and fuzzy logic systems is the best predictor of groundwater drought. In order to reveal the most effective parameter in the prediction models, Sobol sensitivity analysis was applied to ANFIS prediction outputs. Accordingly, relative humidity and SGI-1 (t-1) values were found to have the highest effect on the prediction of SGI-1 (t) values.

Keywords: deep learning, drought, standardized groundwater index, sobol sensitivity analysis, forecasting.

TEŞEKKÜR

Yüksek lisans tezi olarak sunduğum bu çalışma süresince bilgisi ve tecrübesiyle beni yönlendirirken sabrını ve desteğini hiçbir zaman esirgemeyerek bana olan inancını derinden hissettiren çok değerli danışman hocam Sayın Dr. Öğr. Üyesi Okan Mert KATIPOĞLU'na teşekkürü bir borç bilirim. Bu tez çalışması süresince varlığıyla moral, motivasyon ve destek sağlamış olan abim Ferdi KOÇ ve sevgili aileme teşekkürlerimi sunarım. Çalışmada kullanılan yeraltı suyu verilerini temin eden Devlet Su İşleri Genel Müdürlüğüne ve meteoroloji verileri temin eden Devlet Meteoroloji Genel Müdürlüğüne teşekkür ederiz. Bu çalışma Erzincan Binali Yıldırım Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince desteklenmiştir. Proje Numarası: FYL-2024-986

Erdal KOÇ

Ocak, 2025

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ.....	ix
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ.....	1
1.1. Araştırmanın Amacı	1
1.3. Araştırmanın Önemi	1
2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR	3
2.1. Yeraltı Su Seviyesinin Gözlemlenmesi	3
2.2. Kuraklık Tipleri	3
2.3. Kuraklık Tahmini	4
2.4. Yapay Zekâ (Artificial Intelligence-AI) Modelleri	4
2.5. Literatür Özeti.....	4
3. YÖNTEM	8
3.1. Çalışma alanı	8
3.1.1. Standardize yeraltı suyu indisi (Standardized Groundwater Index-SGI)	8
3.1.2. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS - Adaptive Neuro-Fuzzy Inference System)	9
3.1.3. Uzun-Kısa Süreli Bellek Ağları (LTSM-Long Short-Term Memory)	10
3.1.4. Geçitli tekrarlayan birimler (GRU-Gated recurrent units)	10
3.1.5. Kategorik Artırma (CatBoost- Categorical Boosting).....	11
3.1.6. Evrimsel Sinir Ağı (CNN- Convolutional Neural Network)	11

3.1.7. Otokodlayıcı (Autoencoder)	12
3.1.8. Derin Sinir Ağı (DNN- Deep Neural Network)	12
3.1.9. Tekil Spektrum Analizi (SSA-Singular Spectral Analysis)	13
3.1.10. Sobol Duyarlılık Analizi.....	14
4. BULGULAR	15
4.1. SGI Değerlerinin Hesaplaması	15
4.2. SGI Değerlerinin Tahmini	26
5. SONUÇLAR.....	56
5.1 TARTIŞMA VE SONUÇ	56
5.2. SONUÇ ve ÖNERİLER	57
KAYNAKÇA	59

TABLÖLAR DİZİNİ

Tablo 1. Çalışmada kullanılan istasyonlara ait lokasyon bilgileri.....	8
Tablo 2. Brastik(Çatalören) istasyonu 1 aylık zaman ölçekli kuraklık değerleri	16
Tablo 3. Brastik(Çatalören) 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	17
Tablo 4. Brastik (Çatalören) istasyonu 12 aylık zaman ölçekli kuraklık değerleri	18
Tablo 5. Brastik(Çatalören) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	18
Tablo 6. Karakaya istasyonu 1 aylık zaman ölçekli kuraklık değerleri.....	19
Tablo 7. Karakaya istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	20
Tablo 8. Karakaya istasyonu 12 aylık zaman ölçekli kuraklık değerleri.....	20
Tablo 9. Karakaya istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	21
Tablo 10. Kığ (Yaylabaşı) istasyonu 1 aylık zaman ölçekli kuraklık değerleri	21
Tablo 11. Kığ (Yaylabaşı) istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	22
Tablo 12. Kığ (Yaylabaşı) istasyonu 12 aylık zaman ölçekli kuraklık değerleri	23
Tablo 13. Kığ (Yaylabaşı) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	23
Tablo 14. Harabedi (Üçkonak) istasyonu 1 aylık zaman ölçekli kuraklık değerleri	24
Tablo 15. Harabedi(Üçkonak) istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	25
Tablo 16. Harabedi (Üçkonak) istasyonu 12 aylık zaman ölçekli kuraklık değerleri	25
Tablo 17. Harabedi(Üçkonak) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı	26
Tablo 18. SGI değerleri ile meteorolojik değişkenler arasındaki çapraz korelasyonlar.....	27
Tablo 19. Seçilen model kombinasyonları	28
Tablo 20. Test aşamasına ait SGI1 tahmin sonuçları	35
Tablo 21. Test aşamasına ait SGI12 tahmin sonuçları	36
Tablo 22. SGI 1 ANFIS çıktılarına göre parametre etkileri	53
Tablo 23. SGI 12 ANFIS çıktılarına göre parametre etkileri	54

ŞEKİLLER DİZİNİ

Şekil 1. ANFIS modelinin yapısı (Jang, 1993).....	9
Şekil 2. LSTM Yapısı (Olah, 2015).	10
Şekil 3. GRU ünitesinin yapısı (Cho vd. 2022; Le vd. 2020).....	11
Şekil 4. CNN modelinin yapısı (Taye, 2023)	12
Şekil 5. Tez çalışmasının akış diyagramı	13
Şekil 6. SGI-1 değerlerine ait PACF grafiği.....	27
Şekil 7. SGI-12 değerlerine ait PACF grafiği.....	27
Şekil 8. Yağış serisinin SSA ile alt serilere ayrıştırılması.....	29
Şekil 9. Sıcaklık serisinin SSA ile alt serilere ayrıştırılması	30
Şekil 10. Rölatif nem serisinin SSA ile alt serilere ayrıştırılması	31
Şekil 11. SGI 1 (t-1) serisinin SSA ile alt serilere ayrıştırılması.....	32
Şekil 12. SGI 1 (t-2) serisinin SSA ile alt serilere ayrıştırılması.....	33
Şekil 13. SGI 12 (t-1) serisinin SSA ile alt serilere ayrıştırılması.....	34
Şekil 14. SGI 1 değerlerinin tekil ML yaklaşımları tahminlerine ait saçılma diyagramları	37
Şekil 15. SGI 12 değerlerinin tekil ML yaklaşımları tahminlerine ait saçılma diyagramları ..	38
Şekil 16. SGI 1 değerlerinin SSA1 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları.....	39
Şekil 17. SGI 12 değerlerinin SSA1 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları.....	40
Şekil 18. SGI 1 değerlerinin SSA2 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları.....	41
Şekil 19. SGI 12 değerlerinin SSA2 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları.....	42
Şekil 20. SGI1 değerlerinin ML modelleri ile tahminlerine ait ısı haritaları	43
Şekil 21. SGI12 değerlerinin ML modelleri ile tahminlerine ait ısı haritaları	44
Şekil 22. SGI1 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait ısı haritaları	45
Şekil 23. SGI12 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait ısı haritaları ...	46
Şekil 24. SGI1 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait ısı haritaları	47
Şekil 25. SGI12 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait ısı haritaları ...	48
Şekil 26. SGI1 değerlerinin ML modelleri ile tahminlerine ait kutu diyagramları	48

Şekil 27. SGI12 değerlerinin ML modelleri ile tahminlerine ait kutu diyagramları	50
Şekil 28. SGI1 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları	51
Şekil 29. SGI12 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları.....	51
Şekil 30. SGI1 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları	52
Şekil 31. SGI12 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları.....	53
Şekil 32. SGI 1 tahmindeki girdilerin etkileri	54
Şekil 33. SGI 12 tahmindeki girdilerin etkileri	55



SİMGELER VE KISALTMALAR DİZİNİ

AI	Yapay Zekâ
ANFIS	Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
ANN	Yapay Sinir Ağları
Autoencoder	Otokodlayıcı
CatBoost	Kategorik Artırma
CNN	Evrişimli Sinir Ağının
DNN	Derin Sinir Ağı
DWT	Ayrık Dalgacık Dönüşümü
GA	Genetik Algoritma
GRACE	Yüksek Mekânsal Çözünürlüklü Yerçekimi Kurtarma ve İklim Deneyi
GRU	Geçitli Tekrarlayan Birimler
GWL	Yeraltı Suyu Seviyesi
LSTM	Uzun Kısa Süreli Bellek Ağları
M _{GWL}	Ortalama Yeraltı Suyu Seviyesi
ML	Makine Öğrenmesi
MRFO	Yeni Işın Besleme Optimizasyonu
PB	Fizik Tabanlı
PDSI	Palmer Kuraklık Şiddeti İndeksi
PSO	Parçacık Sürüsü Optimizasyonu
RF	Rastgele Orman
RNN	Tekrarlayan Sinir Ağlar
SD	Standart Sapma
SGI	Standart Yeraltı Suyu İndisi
SPEI	Standartlaştırılmış Yağış Evapotranspirasyon İndisi
SPI	Standart Yağış İndeksi
SSA	Tekli Spektrum Analizi
SVM	Destek Vektör Makinesini
TRMM	Tropikal Yağış Ölçme Misyonu

1. GİRİŞ

1.1. Araştırmanın Amacı

Bu çalışmanın temel amacı Erzincan'daki yeraltı suyu kuraklık riskinin yönetimi ve gelecek kuraklıklara karşı alınması gereken önlemlerin ortaya konulmasıdır. Bu amaçla standart yeraltı suyu indisi (Standard Groundwater Index-SGI) değerleri değerlendirilerek geleceğe yönelik tahminlerde bulunulmuştur. SGI değerlerinin değerlendirilmesi için kuraklık sınırlarına göre hafif, orta, şiddetli ve olağan üstü kuraklıklar ifade edilerek gölgedeki yeraltı kuraklık tehlikesi ortaya çıkarılmıştır. Kuraklıkların tahmin edilmesi için ise yapay zekâ (Artificial Intelligence - AI) ve veri ayrıştırma teknikleri entegre edilerek güçlü hibrit modeller kurulmuştur. Bu teknikler veri içindeki örüntülerin ve dalgalanmaların daha iyi anlaşılmasını sağlayarak yüksek doğrulukta tahminler üretilmesini sağlar. Bu da AI modellerinin daha iyi öğrenme ve tahmin yapabilmesini sağlar. Tez çalışması kapsamında tekli spektrum analizinin (Single Spectrum Analysis-SSA) tekniklerinin AI modellerinin performansı üzerindeki etkisi değerlendirilecektir. Bunun için ilk olarak çeşitli meteorolojik ve hidrolojik veri kombinasyonlarına göre SGI değerleri AI modelleri kullanılarak tahmin edilmiştir. Ardından SSA girdiler ayrıştırılarak trend, döngüsel yapı, mevsimsellik ve gürültü bileşenleri AI modellerine sunulmuş ve tekli modellere göre performans karşılaştırması yapılmıştır. Çeşitli istatistiksel göstergeler aracılığı ile kurulan model ve girdi kombinasyonları karşılaştırılarak optimum sonuçları veren model ve parametreler tespit edilmiştir. Böylece gelecek çalışmalar için SGI tahminlerini etkileyen değişkenler belirlenmiştir. Ayrıca gelecek SGI değerlerini en iyi tahmin edebilen model belirlenmiş ve Sobol duyarlılık analizine göre kullanılan girdilerin kuraklık tahmini üzerindeki etkileri ortaya çıkarılmıştır. Bu doğrultuda önerilen model ve değişken yapıları ile yeraltı suyu kuraklıkları tahmin edilerek kuraklık risk yönetimine katkıda bulunulmuştur.

1.3. Araştırmanın Önemi

Yeraltı suyu özellikle kurak dönemler depo görevi nedeniyle önemli bir su kaynağıdır. Genellikle yüzey suyu kaynakları kadar sınırlı olmayan bu kaynak yıl boyunca yüksek ve istikrarlı kaliteye sahip olma eğilimindedir (UK Groundwater Forum, 2018; Li ve Rodell, 2020). Yeraltı suyu üzerindeki herhangi bir olumsuz etki, diğer su kaynaklarında da sorunlara

yol açabilir (European Union, 2018). NASA'nın 2021 haritası, kuraklık nedeniyle Türkiye'nin yeraltı suyu seviyelerinde önemli düşüşler olduğunu vurgulamıştır (NASA, 2021). Bu nedenle, yeraltı suyu kuraklığını tespit etmek, tanımlamak ve tahmin etmek gerekir. Yeraltı suyu kuraklığının tahmini, ekolojik koruma, su kaynaklarının sürdürülebilirliği, tarımsal üretim, ülkenin ekonomisi için hayati öneme sahiptir. Yeraltı suyu seviyesinin ortalama değerlerin altında seyretmesi durumunda yeraltı suyu kuraklığı meydana gelmektedir. Bu çalışmada yeraltı suyu kuraklığı SGI göstergesine göre belirlenmiştir. SGI değerlerine göre çalışma alanında (Erzincan) kuraklık durumu değerlendirilmiştir. Ayrıca çeşitli meteorolojik ve hidrolojik parametreleri SGI üzerindeki etkisi analiz edilecek ve ileriye dönük SGI değerleri AI teknikleri ve SSA ile belirlenmiştir. Bu çalışma kapsamında Erzincan'daki yeraltı suyu kuraklığını gerçek değere en yakın seviyeyi tahmin ederek, bölgenin su ihtiyacını karşılayabilecek yeterli su potansiyelini karşılayıp karşılamadığı değerlendirilmiştir. Böylece bölgenin gelecek yıllar için daha verimli yaşam alanları ve tarım arazilerini kapsayacak su ihtiyacının yönetilmesi ve yeraltı sularıyla karşılanmasına yardımcı olacaktır.

2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR

2.1. Yeraltı Su Seviyesinin Gözlemlenmesi

Yeraltı suları, özellikler kurak dönemlerde su kaynaklarının güvenli deposu olarak görev yapan ve insan ihtiyaçları sağlayan temiz su kaynağıdır. Yeraltı suyunun fazla kullanımı, yeraltı suyu kuraklığına neden olmaktadır. Ayrıca kurak bölgelerde obruk oluşumuna neden olarak bölgesel yıkıma neden olabilir. Bir havzada tahmin edilecek yeraltı suyu seviyesi, bölgenin genel olarak yaşam kalitesinin gelecek yıllar için artacağına bir göstergesi olarak düşünülebilir. Su, çevrenin hemen hemen her yerinde bulunan en önemli doğal kaynaktır, sürdürülebilir bir kalkınma için çok önemlidir. Yüzey suyu ve yeraltı suyu, yoğunlukla insan ihtiyaçları için kullanılan iki rezervuardır (Pande vd. 2022). Yeraltı suyu, küresel nüfusun yarısının sulama, imalat sanayi, içme ve belediye su temini gibi çeşitli kullanımları için bağımlı olduğu güvenilir ve dinamik bir tatlı su rezervi kaynağıdır (Khadri ve Pande, 2016; Alam vd. 2022). Yeraltı suyu, akiferin yer yüzeyinin altındaki gözenek boşluklarında bulunur ve yeraltı suyunun yeniden şarj miktarı, yağışın süresine ve yoğunluğuna bağlıdır. Her ülke artan nüfus artışı, hızlı sanayileşme ve artan gıda üretim talebiyle karşı karşıyadır ve bu da tatlı su talebinin artmasına neden olmuştur (Pande ve Moharir, 2021; Escalante vd. 2023). Bu açıdan doğru yeraltı suyu kuraklıklarının tahmini, bölgedeki tarımsal üretimin verimli ve sürdürülebilir şekilde yönetimine imkân tanıyacak ve ülkenin ekonomisine katkıda bulunacaktır.

2.2. Kuraklık Tipleri

Kuraklıklar yağışların kaydedilen normal düzeylerin altına düşmesi nedeniyle arazi ve kaynak üretim sistemlerini olumsuz olarak etkileyen ve hidrolojik döngüyü bozan doğal bir felakettir. Yeraltı suyu kuraklığı, yeraltı suyu seviyesinin normalin altında olduğu veya kaynak deşarjının azaldığı bir dönem olarak tanımlanan bir hidrolojik kuraklık türüdür (Mishra ve Singh, 2010). Meteorolojik, tarımsal, hidrolojik ve sosyoekonomik olmak üzere 4 tip kuraklık vardır. Bu çalışma kapsamında SGI tabanlı yeraltı su değerleri kullanılarak hidrolojik kuraklık değerleri değerlendirilmiştir.

2.3. Kuraklık Tahmini

Kuraklıkların gerçeğe en yakın tahmini su kaynakları yönetimi afet risk yönetimi ve hazırlık ve erken uyarı açısından büyük öneme sahiptir. Kuraklıkların doğru şekilde tahmin edilmesi için geçmiş kuraklık zaman serileri ve bölgedeki birçok meteorolojik ve hidrolojik değişkenlerin modelde girdi olarak kullanılması hayati öneme sahiptir. Ayrıca doğru girdi kombinasyonların seçilmesi bu konuda hassaslığı artırmaktadır.

2.4. Yapay Zekâ (Artificial Intelligence-AI) Modelleri

Günümüzde matematiksel modeller yağış sıcaklık, buharlaşma, rüzgâr hızı, yeraltı suyu seviyesi (Groundwater Level-GWL) ve akım gibi meteorolojik ve hidrolojik değişkenlerin tahmininde yaygın şekilde kullanılmaya başlamıştır. Bu değişkenlerin doğru bir şekilde tahmini su kaynakları yönetimi ve planlaması açısından hayati öneme sahiptir. AI teknikleri ampirik denklemler ve stokastik modellerin önüne geçerek hidrolojik tahmin çalışmalarında hızlı ve kolay şekilde sonuca ulaşabilmektedir. SGI, yeraltı suyu kaynağının hangi seviyede olduğun ve kuraklıktan ne derece etkilendiğini ifade eden önemli bir indistir. SGI'nin doğru ve güvenilir tahmini, yeraltı suyu yönetimi için temel göstergelere arasında yer almaktadır (Kang ve Byun 2024; Pourmorad vd. 2024).

Makine öğrenimi ve veri ayrıştırma teknikleri kullanılarak GWL tahmininin gerçek değere bulunması, yeraltındaki suyun miktarının ne düzeyde olduğu sorununu da ortadan kaldırmaya yardımcı olmaktadır. Ayrıca, önerilen bu tekniklerle, sistemdeki tüm GWL değişimi aynı anda modelleyebildiği için yüksek bir verimliliğe sahip olacaktır. Kuraklık tahminleri toplumun refahı ve ulusal ekonomiye çok büyük katkı sağlayarak önemli gelişmeler sunacaktır (Khan vd. 2023).

2.5. Literatür Özeti

Literatürde yeraltı suyu seviyelerini tahmin etmek için kullanılan modeller kabaca iki kategoriye ayrılabilir: fizik tabanlı (Physics Based-PB) modeller ve makine öğrenmesi (machine learning-ML) modelleri. PB modelleri, GWL tahmininde yeraltı suyu akışının dinamik değişim sürecini gösterebilen yaygın yöntemlerdir (Ao vd. 2021). Bununla birlikte, meteoroloji, topografya, hidrojeoloji ve insan faaliyetleri gibi birçok faktörün birleşik etkisi nedeniyle, GWL değişiklikleri çok karmaşık ve doğrusal değildir (Malekzadeh vd. 2019). Bu nedenle, PB modelleri, karmaşık yeraltı suyu akış süreçlerini, akifer özelliklerini ve insan

faaliyetlerini tanımlamak için genellikle mevcut olmayan veya yanlış olan büyük miktarda ek veri gerektirir (Barthel ve Banzhaf, 2016). ML modelleri ise esnek olması, hızlı ve güvenilir sonuçlar üretmesi ve basit şekilde uygulanabilmesi yanında teknoloji ile birlikte sürekli ilerleme göstermesi nedeniyle avantajlara sahip olmaktadır. Bu özellikleri sayesinde hidrolojik ve meteorolojik tahminlerinde kullanımı giderek artmaktadır.

Yeraltı suyu kuraklıklarının belirlenmesi için yeraltı suyu seviyelerinin standardizasyonu yapılarak ortalamanın altındaki su seviyelerinin belirlenmesi gerekmektedir. Son yıllarda gelişen teknoloji sayesinde AI teknikleri GWL ve SGI tahmin birçok araştırmacı tarafından kullanılmıştır. Bidwell (2005), akifer dinamiklerinin özdeğerlerini ile otoregresif, hareketli ortalama, ekzojen değişkenli (ARMAX) ile yeraltı suyu kuraklık tahmin potansiyelini araştırmıştır. Medicino vd. (2008) Akdeniz bölgesinde basit bir dağıtılmış su dengesi modeli aracılığı ile hesaplanan yaz kuraklığını tahmin etmek için yeraltı suyu kaynak endeksinin standart yağış indeksi (SPI)'dan daha etkili olduğunu ortaya çıkarmıştır. Rahim vd. (2015), Pakistan'daki yeraltı suyu kuraklığını standart su seviyesi endeksi ve SPI kullanarak değerlendirmişlerdir. Kumar vd. (2016), SPI'nın yeraltı suyu kuraklığının tahminine uygulanamayacağını göstermiştir. Shahbazi vd. (2023) Aspas akiferinin GWL değerlerini modellemek için ANN ve SVM modellerini dalgacık dönüşümü (WT) ve tamamlayıcı topluluk ampirik mod ayrıştırması (CEEMD) ile birleştirmiştir. GWL tahmin sonuçlarını Aspas akiferi yeraltı suyunun birim hidrografi ile karşılaştırılmıştır. Model sonuçlarının değerlendirilmesi, ANN'nin SVM modelinden daha üstün olduğu ve ön işleme tekniklerinin model doğruluğunun artırdığı ortaya çıkarılmıştır. Zhou vd. (2017), yeraltı suyu seviyesini tahmin etmek için veriye dayalı bir tahmin modeli kullanmışlardır. Bu bağlamda ayrık dalgacık dönüşümü (DWT) ve destek vektör makinesini (SVM) birleştirmişler ve sonuçları ANN ile karşılaştırmışlardır. Analizler DWT-SVM modelinin, yapay sinir ağları (ANN) ve SVM ile karşılaştırıldığında en hassas ve güvenilir yeraltı suyu derinliği tahminini ürettiği ortaya çıkarılmıştır. Naghibi vd. (2017) SVM, rastgele orman (RF) ve genetik algoritmayla (GA) optimize edilmiş RF (RFGA) algoritmaları kullanılarak yeraltı suyu potansiyel haritalarını ve yeraltı suyu potansiyel bölgeleri tespit etmişlerdir. Goodarzi vd. (2019), kuraklık tahmini ve erken uyarı için yeraltı suyu kuraklığını doğal ve yapay kuraklık olarak ayırtmıştır. Seo ve Lee (2019) yüksek mekânsal çözünürlüklü Yerçekimi Kurtarma ve İklim Deneyi (GRACE) ve Tropikal Yağış Ölçme Misyonu (TRMM) uydu tabanlı yeraltı suyu kaynakları aracılığı ile yeraltı suyu kuraklığının analiz etmişlerdir. Bu amaçla Güney Kore'de ANN ile SGI değerleri tahmin edilmiştir. Ayrıca yeraltı suyu ile SGI değerleri arasına korelasyon analizi uygulanarak yüksek ilişkinin olduğu ortaya çıkarılmıştır. Sonuç olarak SGI'nın standartlaştırılmış yağış evapotranspirasyon indisine (SPEI) ve PDSI'ye

benzer bir yapıya sahip olduğunu ortaya çıkarmışlardır. Bowes vd. (2019), GWL'lerin Norfolk, Virginia'daki fırtına olayları üzerindeki etkisini simüle etmek ve tahmin etmek için iki sinir ağı, uzun kısa süreli bellek (LSTM) ağları ve tekrarlayan sinir ağları (RNN)'nin performansını araştırmışlardır. Analizlere göre LSTM'lerin ANN'lerden daha iyi performans gösterdiğini ortaya koymuşlardır. İlgili verilere göre, birleştirilmiş modellerin tahmin performansı, tek modellere göre daha güçlü olduğu tespit edilmiştir. Cao vd. (2020), heyelanın üç yerinde yeraltı suyu seviyelerini tahmin etmek için hibrit bir genetik algoritma destekli vektör makinesi (GA-SVM) modeli geliştirdi. Sonuçlar, modelin GWL'leri tahmin etmenin başarılı bir yolu olduğunu gösterdi. Mevcut literatür incelendiğinde çalışmaların genellikle ağaç, kernel ve sinir ağı tabanlı algoritmaların tek başına GWL ve kuraklığı tahminine dayandığı görülmektedir. Osman vd. (2021), aşırı gradyan artırma (Xgboost) modelini kullanarak Malezya'nın Selangor kentindeki doğru yeraltı suyu seviyelerini tahmin etti. Yang ve Zhang (2022), GWL'leri tahmin etmek için evrişimli sinir ağının (CNN), LSTM'nin birleşik bir ağ yapısını kullanarak ve bir meta-öğrenme algoritması ile birleştirilmiş hibrit bir model CNN-LSTM-ML kullandı ve hem uzun vadeli hem de kısa vadeli tahminlerde iyi sonuçlar elde etti. GWL tahmini için sinir ağı üstün performans göstermiş olsa da ağ hiper parametrelerinin seçimi genellikle yeterince dikkate alınmaz. Geçmişte, çoğu hiper parametreye ya varsayılan değerler atandı ya da manuel öznel tahminlerle belirlenmiştir. Bununla birlikte, tahmin modellerindeki gelişmeler, araştırmacıların sinir ağları için en uygun parametreleri belirlemek için akıllı optimizasyon algoritmaları kullanmasına yol açmıştır. Zounemat-Kermani vd. (2022), parçacık sürüsü optimizasyonu (PSO) ve manta vatozu beslenme optimizasyonu (MRFO) kullanarak yeraltı suyuna özgü iletkenlik (SC) tahmini için uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) modelini optimize etmişlerdir. Sonuçlar, modelin artan tahmin gücünü göstermiştir. Kumari vd. (2023) Hindistan'ın Bihar eyaletinin yeraltı suyu kuraklık indekslerini veriye dayalı teknikler kullanarak tahmin etmişlerdir. Bu amaçla GRACE uydu su eşdeğeri verileri, yağış verileri ve GWL verileri girdi olarak seçilerek SGI değerleri yapay sinir ağı (ANN) ve RF ile tahmin edilmiştir. Kurulan modellerin performansı ortalama kare hatası ve korelasyon katsayısı değerine göre değerlendirilerek RF modelinin YSA' dan daha üstün olduğuna karar verilmiştir. Yun vd. (2023) kuraklıkların tahmini ve öngörüsü için Nesnelerin İnterneti (IoT) özellikli bir sis tabanlı çerçeve önermektedir. Bu amaçla kuraklık şiddeti kategorisini değerlendirmek için genetik algoritma sınıflandırıcılı ANN ve Holt-Winters yöntemine başvurmuştur. Yeraltı suyu kuraklıklarını tespit etmek için, yeraltı suyu seviyesi özelliklerine Changnyeong-Haman Nehri barajında yukarı akıştaki yeraltı suyu seviyesi dalgalanmalarından faydalanılmıştır. Yeraltı suyu kuraklığını, barajın açılış ve kapanışına karşılık gelen SGI değerlerini ne göre analizi

edilmiştir. Çalışma alanında, yeraltı suyu kuraklığını ayırt etmek için SGWI kriterleri sırasıyla -0.674 (dikkat), -1.282 (şiddetli) ve -1.645 (çok şiddetli) olarak tespit edilmiştir. Kartal vd. (2024) SPEI, Çin Z İndeksi (CZI), Standartlaştırılmış Yağış İndeksi (SPI), Z-Puan İndeksi (ZSI), Desil İndeksi (DI), Normalin Yüzdesi İndeksi (PNI) ve Yağış Anomali İndeksi (RAI) göstergelerine bağlı yeraltı suyu kuraklığı tahmin etmek için ANN, LSTM, SVM, RF, En Küçük Kareler Artırma Ağacı (LSBT), Genelleştirilmiş Doğrusal Regresyon (GLR) ve k-En Yakın Komşular (KNN) gibi makine öğrenmesi algoritmalarının başvurmuştur. Bu geleneksel kuraklık endeksleri yeraltı suyu kuraklığının değerlendirilmesi için değiştirilmiştir. Ayrıca, yeraltı suyu kuraklığı hidro-meteorolojik parametrelere (sıcaklık, bağıl nem, rüzgâr hızı, yağış, yeraltı suyu seviyesi) dayanarak tahmin edilmiştir. Analizlere göre doğrusal SVM genellikle kuraklıkları tahmin etmek için en doğru iken GLR ise ikinci en iyi performans gösteren model olarak tespit edilmiştir.

Mevcut literatür incelendiğinde GRU, Otokodlayıcı, RNN, LSTM gibi derin öğrenme yaklaşımları ile yeraltı suyu kuraklıklarının tahmin edildiği çalışmalar sınırlıdır. Bu tez çalışması kapsamında yeni derin öğrenmesi modelleri SSA gibi veri ayrıştırma tekniği ile birleştirilerek veriyi daha anlamlı bileşenlere ayırarak ve farklı frekans seviyeleri ve bileşenleri ortaya çıkararak daha umut verici çıktılar üretilmesi amaçlanmıştır. Ayrıca hem verinin özellikleri ayıklanarak hem de derin öğrenme modelinin daha iyi bir giriş verisiyle çalışmasını sağlanarak daha gerçekçi yeraltı suyu kuraklığı tahminleri elde edilmesi sağlayabilecektir.

3. YÖNTEM

3.1. Çalışma alanı

Bu çalışma Erzincan ilinde bulunan 4 yeraltı suyu gözlem istasyonuna ve 1 meteoroloji istasyonuna ait 1986 ile 2022 yılları arasındaki yeraltı suyu seviyeleri ve meteorolojik veriler kullanılmıştır. Yeraltı suyu verileri Devlet Su İşleri 8. Bölge Müdürlüğünden ve meteorolojik veriler ise Devlet Meteoroloji Genel müdürlüğünden temin edilmiştir. Çalışmada kullanılan istasyonlara ait özet bilgiler Tablo 1’de sunulmuştur.

Tablo 1. Çalışmada kullanılan istasyonlara ait lokasyon bilgileri

	Brastik (Çatalören)	Karakaya	Kığ (Yaylabaşı)	Harabedi (Üçkonak)	Erzincan
İstasyon No	577	11286	1197	2671	17094
İstasyon tipi		Yeraltı suyu			Meteoroloji
Enlem	39.67	39.66	39.65	39.73	39.75
Boylam	39.53	39.74	39.54	39.45	39.49
Zemin kotu/Yükseklik (m)	1157	1240	1197	1175	1154

3.1.1. Standardize yeraltı suyu indisi (Standardized Groundwater Index-SGI)

SGI, yeraltı su seviyesinin ortalamadan farkının standart sapmaya bölünmesiyle hesaplanmaktadır. Negatif değerler, yeraltı suyu seviyesinin kuraklık koşullarının altında olduğunu, pozitif değerler ise yeraltı suyu seviyesinin düşmediğini ve kuraklık olmadığını belirtmektedir (Bloomfield ve Marchant 2013). SGI değerleri aşağıdaki gibi hesaplanmaktadır.

$$SGI = (GWL - M_{GWL}) / SD$$

SGI: Standartlaştırılmış Yeraltı Suyu İndisi

GWL: Yeraltı suyu seviyesi


M_{GWL} : Ortalama yeraltı suyu seviyesi

SD: Standart sapma

SGI, yeraltı suyu kaynağının hangi seviyede olduğunu ve kuraklıktan ne derece etkilendiğini ifade eden önemli bir indistir. SGI'nin doğru ve güvenilir tahmini, yeraltı suyu yönetimi için temel göstergelere arasında yer almaktadır.

3.1.2. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS- Adaptive Neuro-Fuzzy Inference System)


Takagi-Sugeno bulanık çıkarım sistemine dayalı bir yapay sinir ağı yaklaşımıdır. ANFIS, yapay sinir ağları ve bulanık mantığı uyum içinde kullandığı için her iki yöntemden de fayda sağlar (Raju, 2011; Jang, 1993). ANFIS, kuralları birbiriyle bağlayan iki bölümden oluşur: birinci bölüm kuralların öncülü, ikinci bölüm ise sonuç kısmıdır. Bu yapı, beş katmanlı bir ağla oluşturulmuştur ve ANFIS modelinin yapısı Şekil 1'de gösterilmiştir (Jang, 1993). Modelin ilk katmanında, A_i ve B_i değerleri sözel değişkenleri temsil eder ve üyelik fonksiyonu aracılığıyla üyelik derecelerini alıp katmandan çıkarlar. İkinci katmanda ise girdiler çarpılıp bir düğümden çıkar. Üçüncü katmanda ateşleme güçleri normalleştirilir, dördüncü katmanda ise Takagi-Sugeno-Kang modeli çalıştırılır (Jang, 1993).



Şekil 1. ANFIS modelinin yapısı (Jang, 1993)

3.1.3. Uzun-Kısa Süreli Bellek Ağları (LSTM-Long Short-Term Memory)

LSTM mimarisinde, girdileri uzun süre hafızada tutabilen ve "hafıza hücreleri" olarak adlandırılan özel gizli birimler bulunur. Bu yapı, Unutma, Giriş, Güncelleme ve Çıkış kapısı katmanlarından oluşur ve bu kapılar, bir girdinin önemli olup olmadığını belirleyip kaydedilmesine karar verir. Tipik bir LSTM birimi, bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısından meydana gelir. Hücre, belirli zaman aralıklarında bilgileri hatırlar ve üç kapı (unutma, giriş ve çıkış) bu bilginin hücreye girişini ve çıkışını düzenler (Olah, 2015). x_t : LSTM biriminin giriş vektörü, f_t : geçidin aktivasyon unutma vektörünü, i_t : giriş kapısının aktivasyon vektörü, c_t : hücre durum vektörü, h_t : LSTM birimin çıkış vektörünü göstermektedir. Girilen sayının artması sonucu, dereceler değişir ve sıfıra eşitlenir. LSTM, hücreye bilgi ekleyebilen, düzenleyebilen veya çıkarabilen iç kapılar kullanılır. LSTM yapısı Şekil 2'de sunulmuştur (Olah, 2015).




Şekil 2. LSTM Yapısı (Olah, 2015).

3.1.4. Geçitli tekrarlayan birimler (GRU-Gated recurrent units)

GRU, aynı zamanda LSTM'nin bir varyasyonu olan kapılı bir RNN yapısıdır. GRU, Cho vd. (2014) tarafından önerildi. GRU'lar LSTM'lere oldukça benzer; her ikisi de uzun menzilli verileri işlemek için tasarlanmıştır. LSTM'de olduğu gibi, GRU da yok olan ve patlayan eğimleri önlemek için icat edilmiştir. LSTM'ye paralel olan GRU, dinamik olarak tasarlanmıştır. Bilgi akışını hatırlayın ve unutun; bu, daha önce bahsedilen zorlukları büyük ölçüde azaltabilir. Karşılaştırıldığında, GRU'lar LSTM'lerden daha basit bir ağ yapısına sahiptir

çünkü GRU'lar daha az eğitim parametresine ve daha az kapaıya sahiptir. GRU'lar ayrıca ayrı hafıza hücrelerine ihtiyaç duymadan ünite içindeki bilgi akışını yöneten kapılı ünitelere de sahiptir. GRU daha az parametreye sahip olduğundan eğitim sürecinde LSTM'ye göre daha hızlı yakınsar (Cho vd. 2022; Le vd. 2020). Şekil 3'te GRU ünitesinin yapısı gösterilmiştir.




Şekil 3. GRU ünitesinin yapısı (Cho vd. 2022; Le vd. 2020)

3.1.5. Kategorik Artırma (CatBoost- Categorical Boosting)

CatBoost algoritması, birden fazla karar ağacını bir araya gelmesi ile meydana gelen topluluk öğrenme algoritmasıdır. Gradyan artırma yaklaşımına dayanan yenilikçi bir tekniktir. CatBoost, ağaç tabanlı bir model olup, gradyan artırma tekniğini kullanır. Bu teknik, zayıf karar ağaçlarını birleştirerek güçlü bir tahmin modeli oluşturmayı hedefler. CatBoost, ağaçları ardışık olarak birleştirerek önceki ağaçların hatalarını düzeltmeye çalışır (Prokhorenkova vd. 2018; Bentéjac vd. 2021).

3.1.6. Evrişimsel Sinir Ağı (CNN- Convolutional Neural Network)

CNN, görsel işlemeye yönelik olarak kullanılan ve giriş olarak resimleri alan bir derin öğrenme algoritmasıdır. Bu algoritma, çeşitli işlemlerle resimlerdeki özellikleri yakalayıp sınıflandıran farklı katmanlardan oluşur (Bui vd. 2021). Evrişim katmanı; filtre veya çekirdekten meydana gelmektedir. Her öznitelikleri gösterir ve sonraki katmanlara iletilir ve geriye doğru ağırlıklar güncellenir (Taye, 2023). Havuzlama katmanı, aşağı yönlü örnekleme işlemi ile verilerin özellikleri daraltılır. Bu işlem için genellikle en çok azami (maksimum) değer yaklaşımından faydalanılır. Tam Bağlantılı katmanlarda ise nöronlar düğümler halinde birbirlerine entegre edilir (Taye, 2023). Şekil 4'te CNN modelinin yapısı sunulmuştur.



Şekil 4. CNN modelinin yapısı (Taye, 2023)

3.1.7. Otokodlayıcı (Autoencoder)


Otomatik kodlayıcılar verileri alarak, verileri sıkıştırarak ve kodlayarak ve ardından verileri kodlama temsilinden yeniden oluşturarak çalışır. Model, kayıp en aza indirilene ve veriler mümkün olduğunca yakın bir şekilde yeniden üretilene kadar eğitilir (Hancock ve Khoshgoftaar 2020).

3.1.8. Derin Sinir Ağı (DNN- Deep Neural Network)

DNN, ANN modelinin yapısal olarak daha derinleşmiş versiyonu olarak ifade edilmektedir. DNN, ANN modelinin 2’den fazla gizli katmanının bulunması ve nöron sayısının fazla olması olarak ifade edilmektedir. DNN, bir bilgisayarın eğitilerek geleneksel programlama teknikleri kullanılarak yapılması çok zor olan görevleri yapmasını sağlayan bir makine öğrenme tekniğidir. Sinir ağı algoritmaları insan beyninden ve işlevlerinden esinlenmiştir: insan zihnimiz gibi, yalnızca önceden belirlenmiş bir kurallar listesini takip ederek değil, aynı zamanda önceki yinelenmelere ve deneyimlere dayanarak çözümleri tahmin ederek ve sonuçlar çıkararak çalışmak üzere tasarlanmıştır (Bui vd. 2021; Le vd. 2023).

3.1.9. Tekil Spektrum Analizi (SSA-Singular Spectral Analysis)

Zaman serisi analizinde, SSA parametrik olmayan bir spektral tahmin yöntemidir. Klasik zaman serisi analizi, çok değişkenli istatistik, çok değişkenli geometri, dinamik sistemler ve sinyal işleme gibi unsurları bir araya getirir. Kökenleri, zaman serisi ve rastgele alanların klasik spektral ayrışımına ve gömme teoremine dayanır. SSA, zaman serisinin anlamlı bir yorumu olan bileşenlerin toplamına ayrıştırılmasında bir yardımcı olabilir (Marques vd. 2006; Golyandina vd. 2018). Şekil 5'te tez çalışmasının akış diyagramı ve modellerin adım adım uygulanma işlemi sunulmuştur.



Şekil 5. Tez çalışmasının akış diyagramı

3.1.10. Sobol Duyarlılık Analizi

Sobol yöntemi, model çıktı varyansının, artan boyutluluktaki girdi parametrelerinin varyanslarının toplamına ayrıştırılmasına dayanmaktadır (Saltelli, 1999). Sobol duyarlılık analizi, her bir girdi parametresinin ve bunların etkileşimlerinin genel model çıktı varyansına katkısını belirler. Sobol duyarlılık analizi, model çıktısındaki değişkenliğin ne kadarının tek bir parametreye veya farklı parametreler arasındaki etkileşime bağlı olduğunu belirlemek için tasarlanmıştır. Bir Sobol duyarlılık analizindeki çıktı varyansının ayrıştırılması, faktöriyel bir tasarımdaki klasik varyans analiziyle aynı prensibi kullanır. Sobol duyarlılık analizinin girdi değişkenliğinin nedenini belirlemek için tasarlanmadığı unutulmamalıdır. Sadece model çıktısı üzerinde ne kadar ve ne ölçüde bir etkisi olacağını gösterir (Zhang, 2015).



4. BULGULAR

Bu çalışmada Erzincan ilindeki yeraltı suyu kuraklıklarının gözlemlenmesi ve tahmin edilmesi için standardize yeraltı suyu indisi (SGI) analiz edilmiştir. Bunun için 1 ve 12 aylık zaman ölçeklerinde SGI değerleri hesaplanmış ve kuraklık süre ve şiddet değerleri analiz edilmiştir.

4.1. SGI Değerlerinin Hesaplaması

Erzincan ilinde uygun veri bulunan 4 adet istasyon belirlenmiş olup, yeraltı suyu zaman serisi hesaplamaları yapılmıştır. Yeraltı suyu seviyesi, ortalama yeraltı suyu seviyesinden çıkarılıp standart sapmaya bölünerek 1986-2022 yılları arasında her bir ay için kuraklık ve nemli değerler hesaplanmıştır. Her bir ay için negatif değerler yeraltı suyu seviyesinin kuraklığın altında olduğunu ve pozitif değerler yeraltı suyu seviyesini düşmediğini ve kuraklığı olmadığını göstermektedir. Tablo 2’de Brastik istasyonuna ait verilerle yapılan SGI değerlerine ait 1986 yılının 7 ayı aşırı kurak geçtiği diğer aylarda ise orta şiddetli kurak olduğu ve 1987 yılında ise 4 ay şiddetli 2 ay normale yakın kurak bir dönem geçirildiği hesaplanmıştır. 1990 yılında devam eden kuraklık 1995 yılının nisan, mayıs, haziran, temmuz aylarında orta düzeyde kuraklık görülmüştür. Daha sonraki yıllarda ara ara devam eden kuraklığın 2013 ile 2022 yılları arasında tekrardan kuraklığın yoğun olduğu dönemlere gelinmiştir. 2020 yılı kasım ayında normale yakın başlayan kuraklık 2022 yılının mayıs ayına kadar orta düzeyde kurak ve şiddetli kurak şeklinde geçilmiştir.

Tablo 2. Brastik (Çatalören) istasyonu 1 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1986	-1,900	-1,109	-0,507	-2,380	-2,075	-2,179	-3,157	-2,873	-2,664	-2,186	-1,413	-0,837
1987	-0,308	-2,261	0,000	1,203	0,310	-0,884	-1,927	-2,172	-2,233	0,335	0,831	1,181
1988	1,461	1,977	1,118	1,574	1,697	1,021	0,533	0,734	0,687	1,175	1,504	0,720
1989	1,284	0,907	1,285	1,409	1,350	-0,007	-1,107	0,183	-0,127	-0,025	-0,740	-0,087
1990	-0,219	0,454	-1,507	-1,309	-1,989	-2,179	-1,722	-1,020	-2,089	-0,445	0,494	-1,933
1991	-1,060	-0,204	-1,840	-0,815	-1,208	-0,579	0,041	-1,220	-1,419	-1,466	-0,515	0,605
1992	0,842	0,000	0,000	0,000	-1,121	1,174	0,656	0,533	0,400	-0,025	-0,628	-0,664
1993	0,134	0,000	-0,882	-1,062	-0,861	-0,693	-0,492	0,283	0,000	0,995	1,280	1,700
1994	1,904	-0,862	-1,090	-0,897	-0,254	-1,036	-1,353	-0,970	-0,845	-1,706	-0,628	-0,318
1995	0,090	0,742	1,160	-1,474	-1,381	-0,541	-1,394	1,385	1,357	1,175	0,000	2,334
1996	1,506	2,018	2,577	1,409	0,000	1,745	1,271	1,685	1,711	1,835	2,289	2,334
1997	0,975	0,907	0,000	0,000	-0,081	0,541	1,476	0,233	0,352	0,455	0,606	1,181
1998	1,373	-0,039	0,493	0,000	0,743	-0,884	0,369	0,583	0,543	-0,445	0,270	0,432
1999	0,267	0,537	0,535	0,503	0,000	1,098	0,533	-0,218	0,017	0,575	0,000	-0,491
2000	1,815	1,236	1,660	1,492	-0,211	-0,655	0,000	-0,970	-0,175	-0,745	-0,403	0,000
2001	-1,325	-1,051	-0,824	-1,227	1,767	0,663	-0,180	-0,849	-0,845	-0,697	-1,110	-0,814
2002	0,000	-1,734	-1,749	-1,351	-0,991	-0,160	0,804	0,804	1,089	0,335	0,158	-0,364
2003	0,000	-0,303	-0,382	-0,329	-1,078	-0,899	0,738	0,563	0,065	-0,349	-1,032	-0,860
2004	-1,591	-0,418	-0,265	0,083	0,535	0,107	0,959	1,074	1,175	1,547	0,988	0,535
2005	0,435	1,137	0,693	0,742	0,188	1,250	0,312	-0,118	0,275	-0,565	0,382	0,120
2006	0,081	0,397	0,610	0,775	0,466	1,189	0,574	-0,268	-0,701	1,055	1,055	0,512
2007	-0,750	-0,368	0,501	0,569	0,136	-0,914	1,263	1,114	0,294	0,107	0,663	0,558
2008	0,453	1,294	1,226	1,813	1,194	0,907	0,041	-0,058	-0,079	-0,025	0,943	0,259
2009	0,046	0,208	0,160	0,379	0,154	0,610	0,377	0,283	0,400	0,959	0,943	0,524
2010	0,356	0,578	0,543	0,701	1,819	1,387	0,533	0,513	0,285	-0,061	-0,213	-0,237
2011	0,046	-0,015	-0,049	0,289	0,006	0,206	0,533	0,784	1,692	0,695	-0,055	-0,191
2012	0,117	0,068	0,043	0,050	-0,193	-1,554	0,123	-0,268	0,208	0,275	-0,213	-0,526
2013	-0,308	0,175	0,326	0,503	1,324	0,831	-0,451	-0,268	-0,404	-0,793	-0,246	-0,433
2014	-0,264	-0,122	-0,190	-0,197	-0,167	-0,206	-1,025	-1,571	-0,558	-2,090	-2,423	-1,644
2015	-1,962	-2,055	-1,507	-0,897	-1,312	-1,280	-0,369	-0,328	0,227	-0,265	-0,549	-0,560
2016	-0,290	0,027	0,326	0,421	0,327	0,564	0,615	0,583	0,112	-0,277	-0,235	-0,249
2017	-0,007	0,199	0,251	0,190	0,631	0,518	-0,139	-0,308	-0,050	-0,529	-1,929	-1,183
2018	-0,989	-1,010	-1,007	-0,832	-0,384	-0,754	-0,443	-0,048	-0,318	-0,529	-0,605	-0,503
2019	-0,122	0,265	-0,007	0,009	-0,167	0,305	1,263	1,455	1,261	1,547	1,100	0,731
2020	0,462	0,619	0,626	0,651	1,220	0,999	0,451	0,383	0,189	0,335	-0,145	-0,653
2021	-0,750	-0,615	-0,740	-0,733	0,318	0,031	-0,336	-0,789	-0,807	-1,346	-1,469	-1,898
2022	-1,803	-1,578	-1,590	-1,260	-0,714	0,259	0,631	1,144	0,974	1,175	1,044	0,720

Aşırı Kurak	≤ -2
Şiddetli Kurak	-1,5 ~ -1,99
Orta Düzeyde Kurak	-1 ~ -1,49
Normale Yakın Kurak	-0,5 ~ -0,99
Normal	-0,499 ~ 0,499
Normale Yakın Nemli	0,5 ~ 0,99
Orta Düzeyde Nemli	1 ~ 1,49
Çok nemli	1,5 ~ 1,99
Aşırı Nemli	≥ 2

Tablo 3'te ≤ -2 değer aralığında 15 ay %3,4 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 21 ay %4,8 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 35 ay %7,9 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 56 ay %12,6 normale yakın kurak, toplamda 37 yılda 127 ay %28,6 kurak dönem olduğu görülmüştür.

Tablo 3. Brastik (Çatalören) 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemli	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
15	21	35	56	177	73	44	18	5

Brastik (Çatalören) istasyonu 12 aylık zaman serisinde Tablo 4'te 1986 ile 1987 yılında aşırı kurak ve şiddetli kurak olduğu, 1990 ile 1995 yılları arasında bu kuraklığın orta düzey ve normale yakın kurak olarak devam ettiği gözlemlenmiştir. Daha sonra yağışlı bir döneme denk gelinmiş olsa da 2001 ve 2004 yılları arasında yeraltı sularındaki seviyenin düştüğü, 2004 yılının kasım ayında normale dönmesiyle 2012 yılının temmuz ayına kadar normal seviyelerde seyretmiştir. 2012 yılının ağustos ayında başlayan kuraklık 2015 yılında orta düzeyde, şiddetli ve aşırı kurak seviyelerine inmiştir. 2016 ve 2017 yıllarında ise normale yakın kurak şeklinde devam ederken 2018 yılının haziran, temmuz, ağustos, eylül, ekim ve kasım aylarında orta düzeyde kurak olarak hesaplanmıştır. 2022 yılında ise nisan, mayıs, haziran ve temmuz aylarında şiddetli kuraklık, ocak, şubat, mart, ağustos ve eylül aylarında orta düzeyde kurak, ekim, kasım ve aralık aylarında ise normale yakın kuraklık şeklinde geçilmiştir.

Tablo 4. Brastik (Çatalören) istasyonu 12 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Hazir.	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1986	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	-2,857
1987	-2,677	-2,846	-2,808	-2,346	-1,992	-1,785	-1,670	-1,658	-1,632	-1,423	-1,199	-0,810
1988	-0,597	-0,017	0,141	0,190	0,363	0,629	0,973	1,337	1,702	1,819	1,908	1,749
1989	1,728	1,591	1,638	1,632	1,550	1,368	1,156	1,117	1,013	0,906	0,661	0,592
1990	0,396	0,338	-0,037	-0,424	-0,857	-1,176	-1,304	-1,504	-1,776	-1,872	-1,765	-1,694
1991	-1,818	-1,914	-1,980	-1,941	-1,805	-1,557	-1,362	-1,445	-1,387	-1,534	-1,672	-1,185
1992	-0,958	-0,932	-0,688	-0,587	-0,568	-0,313	-0,249	-0,064	0,151	0,292	0,275	0,200
1993	0,104	0,106	-0,010	-0,163	-0,131	-0,414	-0,599	-0,662	-0,731	-0,654	-0,458	-0,109
1994	0,108	-0,008	-0,033	-0,015	0,060	-0,001	-0,136	-0,302	-0,423	-0,719	-0,946	-0,973
1995	-1,216	-1,000	-0,700	-0,794	-0,931	-0,856	-0,897	-0,662	-0,405	-0,130	-0,070	0,269
1996	0,442	0,621	0,827	1,240	1,391	1,699	2,097	2,191	2,243	2,355	2,629	2,444
1997	2,381	2,242	1,920	1,744	1,693	1,484	1,534	1,401	1,231	1,110	0,930	0,801
1998	0,848	0,724	0,805	0,811	0,898	0,667	0,513	0,559	0,575	0,487	0,448	0,407
1999	0,260	0,342	0,356	0,428	0,317	0,594	0,616	0,529	0,456	0,561	0,531	0,464
2000	0,655	0,756	0,924	1,071	1,017	0,736	0,664	0,585	0,554	0,422	0,375	0,461
2001	0,057	-0,255	-0,595	-0,990	-0,716	-0,523	-0,575	-0,594	-0,696	-0,717	-0,811	-0,735
2002	-0,578	-0,673	-0,804	-0,836	-1,186	-1,301	-1,209	-1,068	-0,849	-0,773	-0,650	-0,467
2003	-0,477	-0,281	-0,093	0,045	0,028	-0,091	-0,117	-0,163	-0,305	-0,392	-0,536	-0,456
2004	-0,668	-0,685	-0,673	-0,629	-0,410	-0,267	-0,257	-0,218	-0,094	0,088	0,305	0,485
2005	0,737	0,955	1,103	1,206	1,132	1,275	1,200	1,087	0,971	0,770	0,704	0,669
2006	0,620	0,523	0,522	0,530	0,550	0,524	0,559	0,547	0,417	0,583	0,657	0,705
2007	0,595	0,495	0,490	0,464	0,406	0,082	0,165	0,321	0,436	0,340	0,293	0,344
2008	0,491	0,723	0,836	1,017	1,131	1,374	1,221	1,110	1,061	1,064	1,100	1,037
2009	0,983	0,840	0,709	0,512	0,361	0,302	0,342	0,381	0,431	0,533	0,532	0,580
2010	0,614	0,670	0,735	0,786	0,983	1,075	1,107	1,159	1,143	1,056	0,934	0,843
2011	0,800	0,724	0,656	0,603	0,348	0,160	0,149	0,173	0,338	0,414	0,429	0,466
2012	0,469	0,485	0,507	0,476	0,436	0,161	0,093	-0,042	-0,240	-0,298	-0,327	-0,252
2013	-0,315	-0,300	-0,261	-0,205	-0,007	0,334	0,247	0,242	0,155	0,040	0,029	0,110
2014	0,109	0,070	0,004	-0,098	-0,297	-0,455	-0,561	-0,747	-0,786	-0,947	-1,207	-1,130
2015	-1,359	-1,629	-1,826	-1,953	-2,069	-2,210	-2,185	-2,126	-2,060	-1,933	-1,756	-1,402
2016	-1,205	-0,923	-0,679	-0,507	-0,287	-0,023	0,100	0,198	0,173	0,166	0,195	0,281
2017	0,311	0,338	0,336	0,304	0,332	0,311	0,199	0,087	0,054	0,020	-0,174	-0,172
2018	-0,306	-0,472	-0,646	-0,803	-0,924	-1,110	-1,193	-1,216	-1,273	-1,314	-1,190	-0,932
2019	-0,834	-0,661	-0,528	-0,421	-0,390	-0,239	-0,021	0,143	0,330	0,540	0,728	0,851
2020	0,921	0,976	1,079	1,179	1,333	1,407	1,312	1,217	1,082	0,974	0,841	0,699
2021	0,540	0,375	0,197	0,000	-0,123	-0,274	-0,405	-0,571	-0,713	-0,912	-1,076	-1,016
2022	-1,162	-1,298	-1,427	-1,524	-1,634	-1,589	-1,506	-1,342	-1,144	-0,924	-0,664	-0,270

Tabloda 5'te ≤ -2 değer aralığında 10 ay %2,3 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 27 ay %6,2 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 31 ay %7,2 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 62 ay %14,3 normale yakın kurak, toplamda 37 yılda 130 ay %30 kurak dönem olduğu görülmüştür.

Tablo 5. Brastik (Çatalören) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemli	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
10	27	31	62	160	80	40	18	4

Karakaya istasyon verilerine bağı olarak 1986 ve 1987 yıllarında kurak dönem olduğu, daha sonraki yıllarda yerini nemli bir döneme bırakmış olsa da 2002 ile 2022 yıllarında normale yakın kurak, orta düzeyde kurak, aşırı kurak ve şiddetli kuraklıkların olduğu hesaplanmıştır ve bu değerler Tablo 6’da belirtilmiştir. Bu değerler 1 aylık zaman ölçekli hesaplanmıştır.

Tablo 6. Karakaya istasyonu 1 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1986	0,000	0,000	0,000	-0,553	-0,503	-1,028	-0,689	-0,459	-0,519	-0,757	-0,635	-0,345
1987	0,000	-0,519	0,000	-0,553	-0,986	0,103	-0,079	0,311	0,581	-0,250	-0,219	-0,449
1988	0,000	-0,200	0,285	0,445	1,346	1,836	2,305	1,722	1,499	2,056	1,856	2,059
1989	0,000	2,463	2,500	2,654	1,829	1,158	0,420	0,653	0,948	1,503	0,715	1,014
1990	0,450	0,546	0,740	0,730	0,944	0,555	1,030	0,738	0,948	0,073	0,300	0,282
1991	0,277	0,439	0,229	0,445	0,703	-0,500	-0,467	0,567	0,856	1,134	1,649	0,648
1992	0,507	0,000	0,000	0,730	0,703	1,233	0,919	0,995	0,490	0,258	0,403	0,387
1993	0,565	0,000	1,592	1,371	1,748	0,931	1,362	0,909	0,000	0,673	0,870	0,805
1994	0,967	1,078	0,797	0,872	1,266	0,479	0,309	0,396	0,719	0,534	0,715	0,648
1995	0,680	0,705	0,115	0,017	-0,503	-0,048	0,143	1,380	1,682	1,134	0,000	2,059
1996	2,232	1,930	1,819	0,730	0,000	0,479	1,141	1,080	1,361	1,595	1,960	2,007
1997	0,507	0,333	0,000	0,000	0,462	0,781	0,919	1,422	1,315	1,300	1,514	0,805
1998	1,542	1,717	2,046	0,872	0,783	0,781	1,529	0,909	0,811	0,811	1,337	1,223
1999	1,082	1,078	0,910	0,373	0,000	0,856	1,141	0,738	1,361	1,226	0,000	0,909
2000	1,945	1,185	1,081	1,442	0,462	0,404	0,000	1,080	0,000	0,857	0,870	0,000
2001	1,945	1,185	1,081	1,442	0,462	0,404	0,000	1,080	0,000	0,857	0,870	0,000
2002	-0,919	0,013	-0,214	0,003	-1,034	-0,907	-0,578	-0,245	-0,244	-0,452	-0,583	0,000
2003	-0,792	-0,839	-1,135	-1,266	-1,356	-1,329	-0,844	-0,630	-0,574	-0,775	-0,251	-1,066
2004	0,000	-1,851	-1,146	-1,152	-1,420	-0,726	-0,378	-0,459	-0,235	-0,148	-0,541	-0,575
2005	-0,689	-0,402	-0,737	-0,696	-0,584	-1,344	-0,168	-0,416	-0,272	-0,157	-0,064	0,596
2006	0,000	0,003	0,047	0,174	0,381	0,901	0,254	0,097	0,123	0,018	0,019	-0,094
2007	-0,148	-0,200	-0,283	1,072	-0,342	-0,365	-0,256	-0,262	-0,262	-0,397	-0,282	-0,251
2008	-0,286	0,152	-0,192	-0,126	0,172	0,494	0,032	-0,023	1,177	-0,203	0,216	-0,010
2009	-0,160	-0,093	-0,226	-0,268	-0,021	0,540	0,620	-0,117	-0,061	-0,111	0,040	-0,031
2010	-0,033	-0,253	-0,941	0,117	1,137	0,404	0,121	0,003	-0,207	-0,286	-0,302	-1,369
2011	-0,608	-0,402	-0,533	-0,696	-1,018	-0,199	-0,223	-0,330	-0,290	-0,406	-0,365	-0,334
2012	-0,516	-0,424	-0,555	-0,909	-0,680	-1,630	-0,633	-0,544	-0,519	-0,157	-0,790	-0,899
2013	-0,965	-1,382	-1,146	-1,365	-0,310	-0,606	-1,409	-1,810	-2,143	-1,799	-1,714	-1,233
2014	-1,494	-1,265	-1,362	-1,693	-2,095	-1,570	-3,105	-2,853	-2,464	-2,740	-2,814	-2,644
2015	-2,713	-2,383	-2,134	-2,121	-2,497	-2,987	-2,152	-2,460	-2,335	-1,901	-1,880	-1,746
2016	-1,758	-1,467	-1,396	-1,451	-0,439	0,796	0,054	-0,399	-0,418	-0,333	-0,188	-0,084
2017	0,047	0,141	0,149	0,188	0,462	0,238	-0,323	-0,741	-0,932	-0,877	-0,718	-0,658
2018	-0,643	-0,551	-0,601	-0,553	-0,181	-0,591	-0,711	-0,792	-0,886	-0,711	-0,842	-0,700
2019	-0,689	-0,573	-0,589	-0,439	0,301	0,962	0,819	0,225	0,224	0,239	0,455	0,491
2020	0,622	0,620	0,626	1,057	1,620	0,886	0,309	-0,100	-0,015	-0,130	0,019	-0,063
2021	-0,068	-0,029	-0,055	-0,083	-0,503	-1,329	-1,110	-1,023	-1,060	-1,024	-0,988	-0,888
2022	-0,884	-0,754	-0,771	-0,810	-0,310	-0,063	-0,301	-0,647	-0,657	-0,655	-0,635	-0,491

Tabloda 7’de ≤ -2 değer aralığında 16 ay %3,6 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 11 ay %2,5 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 29 ay %6,5 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 72 ay %16,2 normale yakın kurak, toplamda 37 yılda 128 ay %28,8 kurak dönem olduğu görülmüştür.

Tablo 7. Karakaya istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemlice	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
16	11	29	72	188	62	36	20	10

Tablo 8’de Erzincan ilinde bulunan Karakaya istasyonun verileriyle hesaplanan yeraltı suyu kuraklık indisi 12 aylık zaman serisinde 1987 yılının tamamında kurak olduğu 1988 yılının mayıs ayından itibaren yerini normal seviyelere bırakarak, 2002’nin temmuz ayına kadar normal düzeyde nemli, nemli ve aşırı nemli seviyelere ulaşmıştır. 2002 yılının ağustos ayından başlayıp sadece 2020 yılının tamamında kurak dönemden çıkıldığı buna bağlı 2022 yılına kadar kurak dönem olduğu hesaplanmıştır.

Tablo 8. Karakaya istasyonu 12 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Hazir.	Temm.	Ağus.	Eylül	Ekim	Kasım	Aralık
1986	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	-0,505
1987	-0,517	-0,560	-0,553	-0,545	-0,575	-0,507	-0,460	-0,371	-0,249	-0,192	-0,149	-0,146
1988	-0,161	-0,127	-0,098	-0,027	0,117	0,232	0,455	0,629	0,739	0,998	1,197	1,468
1989	1,439	1,683	1,864	1,997	2,024	1,997	1,855	1,742	1,695	1,631	1,507	1,426
1990	1,438	1,243	1,076	0,929	0,873	0,840	0,908	0,927	0,935	0,773	0,727	0,673
1991	0,636	0,621	0,572	0,545	0,529	0,463	0,331	0,314	0,307	0,425	0,557	0,611
1992	0,610	0,564	0,540	0,554	0,553	0,672	0,810	0,869	0,835	0,736	0,607	0,599
1993	0,583	0,579	0,717	0,753	0,817	0,803	0,856	0,854	0,806	0,852	0,892	0,954
1994	0,965	1,061	0,982	0,936	0,904	0,882	0,798	0,743	0,831	0,815	0,794	0,798
1995	0,749	0,708	0,642	0,575	0,465	0,432	0,423	0,546	0,660	0,727	0,651	0,809
1996	0,925	1,035	1,178	1,214	1,244	1,290	1,402	1,378	1,353	1,404	1,590	1,608
1997	1,424	1,260	1,088	1,024	1,051	1,080	1,076	1,127	1,131	1,097	1,045	0,947
1998	1,015	1,140	1,312	1,358	1,376	1,388	1,465	1,417	1,372	1,315	1,289	1,353
1999	1,284	1,213	1,102	1,054	1,004	1,017	0,997	0,985	1,056	1,102	0,962	0,951
2000	1,004	1,006	1,013	1,076	1,103	1,082	0,994	1,044	0,899	0,856	0,937	0,867
2001	0,843	0,837	0,831	0,821	0,820	0,826	0,839	0,847	0,854	0,853	0,847	0,867
2002	0,587	0,471	0,353	0,249	0,156	0,068	0,015	-0,144	-0,172	-0,320	-0,463	-0,451
2003	-0,452	-0,527	-0,602	-0,683	-0,702	-0,739	-0,777	-0,829	-0,873	-0,909	-0,870	-0,966
2004	-0,904	-0,990	-0,979	-0,959	-0,962	-0,934	-0,907	-0,893	-0,861	-0,791	-0,814	-0,756
2005	-0,828	-0,679	-0,634	-0,594	-0,542	-0,590	-0,582	-0,581	-0,589	-0,590	-0,539	-0,411
2006	-0,363	-0,318	-0,244	-0,179	-0,120	0,027	0,065	0,128	0,174	0,194	0,201	0,148
2007	0,117	0,099	0,070	0,133	0,087	0,002	-0,046	-0,089	-0,133	-0,180	-0,209	-0,211
2008	-0,238	-0,200	-0,188	-0,269	-0,237	-0,184	-0,162	-0,133	0,029	0,051	0,100	0,139
2009	0,132	0,110	0,108	0,097	0,084	0,086	0,141	0,131	-0,007	0,003	-0,015	-0,002
2010	-0,008	-0,021	-0,082	-0,054	0,018	0,007	-0,040	-0,025	-0,042	-0,062	-0,095	-0,214
2011	-0,280	-0,290	-0,249	-0,302	-0,435	-0,482	-0,522	-0,566	-0,580	-0,593	-0,596	-0,482
2012	-0,486	-0,481	-0,477	-0,485	-0,464	-0,566	-0,614	-0,645	-0,675	-0,647	-0,685	-0,731
2013	-0,781	-0,864	-0,906	-0,926	-0,902	-0,845	-0,931	-1,091	-1,283	-1,468	-1,550	-1,578
2014	-1,628	-1,600	-1,601	-1,604	-1,713	-1,796	-1,983	-2,125	-2,178	-2,283	-2,377	-2,517
2015	-2,622	-2,702	-2,741	-2,737	-2,759	-2,884	-2,843	-2,819	-2,827	-2,732	-2,621	-2,532
2016	-2,443	-2,330	-2,239	-2,164	-2,034	-1,804	-1,631	-1,396	-1,190	-1,013	-0,838	-0,663
2017	-0,513	-0,352	-0,209	-0,092	-0,036	-0,076	-0,112	-0,154	-0,213	-0,275	-0,325	-0,370
2018	-0,445	-0,505	-0,565	-0,609	-0,648	-0,712	-0,760	-0,772	-0,773	-0,754	-0,762	-0,756
2019	-0,770	-0,763	-0,752	-0,735	-0,704	-0,610	-0,479	-0,360	-0,237	-0,130	0,000	0,132
2020	0,232	0,346	0,453	0,552	0,633	0,633	0,595	0,561	0,539	0,497	0,451	0,413
2021	0,331	0,268	0,206	0,125	-0,007	-0,157	-0,291	-0,404	-0,526	-0,627	-0,723	-0,794
2022	-0,877	-0,936	-0,988	-1,027	-1,014	-0,941	-0,883	-0,845	-0,805	-0,764	-0,724	-0,674

Tabloda 9’da ≤ -2 değer aralığında 22 ay %5 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 11 ay %2,5 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 8 ay %1,9 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 94 ay %21,7 normale yakın kurak, toplamda 37 yılda 135 ay %31,2 kurak dönem olduğu görülmüştür.

Tablo 9. Karakaya istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemli	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
22	11	8	94	139	93	54	95	1

Tablo 10. Kığ (Yaylabaşı) istasyonu 1 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1986	-2,441	-2,590	-1,399	-2,100	-2,738	-2,710	-2,424	-2,554	-2,423	-2,381	-2,257	-2,113
1987	-2,114	-2,045	0,000	-1,686	-1,777	-1,941	-2,225	-1,216	-1,326	-1,082	-0,960	-0,943
1988	-0,564	-0,342	-0,397	0,094	0,387	0,568	0,990	0,766	0,458	0,485	0,484	0,328
1989	0,877	1,156	1,725	1,460	1,028	0,055	-0,505	-0,968	-1,554	-1,351	-1,767	-1,554
1990	-1,516	-1,568	-1,759	-1,438	-0,895	-1,513	-1,353	-1,711	-1,691	-1,732	-1,572	-1,706
1991	-1,462	-1,296	-1,799	-1,190	-0,975	-1,428	-1,701	-1,637	-1,554	-1,485	-1,278	-1,299
1992	-1,081	0,000	0,000	-0,726	-0,334	-0,544	-0,655	-0,894	-0,822	-0,858	-0,691	-0,638
1993	-0,265	0,000	-0,237	-0,030	0,227	-0,601	-0,605	-0,869	0,000	-0,948	-0,789	-0,740
1994	-0,265	-0,683	-0,758	-0,444	-1,056	-1,371	-1,627	-1,860	-1,920	-2,023	-1,963	-1,808
1995	-1,108	-1,466	-1,399	-1,521	-1,296	-1,456	-1,552	0,667	0,687	0,709	0,000	1,295
1996	0,986	1,496	2,206	1,626	0,000	1,481	1,189	1,281	1,328	0,978	1,267	1,549
1997	1,122	1,156	0,000	0,000	1,028	0,437	0,790	1,014	0,984	0,844	0,875	1,193
1998	1,584	0,407	0,964	0,000	1,669	-0,002	0,616	0,122	0,550	0,306	0,729	1,447
1999	1,394	1,088	1,325	1,129	0,000	0,112	0,242	0,295	0,230	0,396	0,000	0,506
2000	1,529	1,803	2,126	3,033	0,267	0,283	0,000	0,716	0,138	0,038	0,288	0,000
2001	-0,102	-0,111	-0,958	-0,345	0,323	-0,145	-0,480	-0,621	-0,740	-0,872	-0,891	-0,531
2002	0,000	-1,064	-1,159	-0,693	-0,735	-0,156	0,666	0,578	0,468	0,329	0,454	0,094
2003	0,000	0,134	-0,197	-0,171	-0,294	0,443	0,282	0,092	-0,411	-0,012	-0,182	-0,196
2004	-0,766	-0,336	-0,053	0,392	0,627	0,825	1,279	1,469	1,414	1,332	1,345	1,091
2005	1,698	1,149	1,133	1,096	0,788	1,184	0,551	0,692	0,655	0,508	0,704	0,456
2006	0,349	0,257	0,444	0,442	0,547	0,984	0,621	0,984	0,884	0,933	0,934	0,700
2007	0,730	0,774	0,756	0,632	0,066	1,412	0,910	0,474	0,458	0,889	0,910	0,629
2008	0,578	1,380	0,476	1,063	0,996	1,366	1,139	0,850	0,651	0,969	0,777	1,483
2009	0,469	0,434	0,364	0,301	0,114	0,141	0,591	0,568	0,550	0,611	0,704	0,837
2010	0,387	0,441	0,460	0,524	0,764	0,642	0,740	0,627	0,701	0,620	0,508	0,242
2011	0,469	0,059	-0,077	-0,088	-0,382	-0,304	-0,172	-0,052	0,138	0,508	0,313	-0,404
2012	-0,059	-0,036	-0,181	-0,279	-0,254	-1,063	0,327	0,171	0,481	0,530	0,562	-0,007
2013	0,018	-0,077	-0,093	0,094	2,967	0,471	0,392	0,161	0,230	0,172	-0,025	0,166
2014	0,105	-0,016	-0,037	0,053	-0,190	0,563	-0,879	-1,414	-1,348	-1,284	-1,474	-1,198
2015	-0,608	-0,649	-0,750	-0,776	-1,360	-0,903	-0,142	-0,076	0,385	0,454	0,415	0,211
2016	0,251	0,325	0,267	0,309	0,411	0,471	0,362	0,478	0,783	0,853	0,959	0,705
2017	0,654	0,768	0,860	0,649	0,443	0,260	-0,047	-0,176	-0,145	-0,204	-0,152	-0,384
2018	-0,363	-0,594	-0,638	-0,403	0,090	0,266	0,297	0,057	0,102	0,020	-0,015	-0,231
2019	-0,195	-0,172	-0,293	-0,212	0,139	0,722	1,448	1,573	1,561	1,601	1,590	1,285
2020	1,073	1,122	0,980	0,649	0,291	0,768	0,486	0,221	0,047	0,029	0,029	-0,211
2021	-0,287	-0,376	-0,558	-0,660	-0,214	-0,447	-0,500	-0,696	-0,868	-0,867	-0,901	-1,070
2022	-1,076	-0,526	-1,343	-0,784	-0,671	1,127	0,950	0,890	0,920	0,987	1,071	0,817

Tablo 10’da 1986 ile 1987 yıllarının tamamında aşırı kurak olduğu ve 1995 yılının temmuz ayına kadar devam ettiği hesaplanmıştır. 1996 ve 2010 yılları arasında ise çoğunlukla nemli dönemlerden geçildiği 2011 ile 2022 yılının mayıs ayına kadar çoğunlukla kurak dönemler olduğu hesaplanmıştır.

Tablo 11’de ≤ -2 değer aralığında 16 ay %3,6 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 26 ay %5,9 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 35 ay %7,9 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 50 ay %11,3 normale yakın kurak, toplamda 37 yılda 127 ay %28,7 kurak dönem olduğu görülmüştür.

Tablo 11. Kığ (Yaylabaşı) istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemlice	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
16	26	35	50	178	84	40	12	4

Kığ (Yaylabaşı) istasyonu verileriyle 12 aylık zaman ölçekli kuraklık değerleri Tablo 12’de 1986 ile 1995 yılları arasında aşırı kurak dönemler olduğu hesaplanmıştır. 1996 yılının şubat ayında başlayan nemli dönem 2011 yılına kadar devam etmiştir. 2012 ile 2022 yıllarında belli dönemlerde nemli olması görülse de çoğunlukla kurak dönem olduğu hesaplanmıştır. 1989 yılının ocak ayı ile eylül ayları arasında yeraltı suyu seviyesi normal olduğu görülmüştür.

Tablo 12. Kığ (Yaylabaşı) istasyonu 12 aylık zaman ölçekli kuraklık değerleri

	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1986	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	-2,814
1987	-2,734	-2,693	-2,580	-2,527	-2,456	-2,402	-2,439	-2,408	-2,381	-2,290	-2,150	-1,717
1988	-1,528	-1,393	-1,412	-1,282	-1,135	-0,910	-0,581	-0,387	-0,180	0,020	0,194	0,382
1989	0,531	0,648	0,789	0,868	0,904	0,848	0,689	0,507	0,250	-0,012	-0,313	-0,418
1990	-0,648	-0,873	-1,107	-1,288	-1,416	-1,581	-1,718	-1,897	-2,011	-2,142	-2,143	-1,857
1991	-1,818	-1,800	-1,791	-1,758	-1,760	-1,769	-1,854	-1,943	-2,023	-2,067	-2,055	-1,717
1992	-1,646	-1,545	-1,412	-1,369	-1,324	-1,255	-1,174	-1,153	-1,120	-1,081	-1,025	-0,771
1993	-0,669	-0,674	-0,686	-0,635	-0,599	-0,616	-0,634	-0,672	-0,605	-0,650	-0,679	-0,547
1994	-0,531	-0,591	-0,623	-0,646	-0,734	-0,820	-0,961	-1,134	-1,450	-1,660	-1,835	-1,683
1995	-1,738	-1,805	-1,838	-1,891	-1,904	-1,929	-1,970	-1,778	-1,523	-1,204	-0,971	-0,454
1996	-0,226	0,010	0,257	0,458	0,540	0,812	1,123	1,236	1,363	1,432	1,593	1,516
1997	1,516	1,483	1,323	1,199	1,260	1,155	1,123	1,134	1,126	1,130	1,076	0,988
1998	1,029	0,963	1,023	1,010	1,045	0,997	0,987	0,918	0,889	0,829	0,804	0,814
1999	0,790	0,841	0,860	0,922	0,802	0,806	0,770	0,815	0,797	0,822	0,721	0,608
2000	0,621	0,674	0,725	0,840	0,850	0,860	0,840	0,917	0,933	0,900	0,932	0,843
2001	0,673	0,513	0,298	0,070	0,070	0,019	-0,044	-0,214	-0,352	-0,504	-0,671	-0,587
2002	-0,561	-0,643	-0,653	-0,671	-0,743	-0,757	-0,656	-0,557	-0,434	-0,293	-0,134	0,019
2003	0,026	0,119	0,184	0,214	0,239	0,287	0,239	0,182	0,062	0,003	-0,091	-0,043
2004	-0,113	-0,156	-0,145	-0,109	-0,050	-0,024	0,076	0,230	0,469	0,659	0,848	0,967
2005	1,212	1,327	1,400	1,429	1,430	1,459	1,397	1,361	1,308	1,222	1,135	1,011
2006	0,867	0,789	0,737	0,684	0,661	0,634	0,644	0,698	0,746	0,817	0,840	0,845
2007	0,879	0,916	0,932	0,932	0,891	0,925	0,966	0,940	0,913	0,923	0,914	0,876
2008	0,856	0,900	0,875	0,891	0,947	0,936	0,970	1,048	1,108	1,142	1,120	1,162
2009	1,142	1,060	1,045	0,982	0,914	0,791	0,735	0,725	0,732	0,692	0,676	0,600
2010	0,591	0,586	0,589	0,595	0,633	0,673	0,692	0,721	0,760	0,773	0,741	0,664
2011	0,670	0,635	0,594	0,545	0,461	0,362	0,258	0,179	0,100	0,075	0,038	0,032
2012	-0,015	-0,027	-0,034	-0,049	-0,044	-0,126	-0,084	-0,073	-0,043	-0,054	-0,034	0,082
2013	0,097	0,089	0,094	0,115	0,328	0,466	0,472	0,482	0,457	0,409	0,324	0,377
2014	0,388	0,388	0,390	0,380	0,162	0,161	0,012	-0,183	-0,413	-0,642	-0,845	-0,834
2015	-0,887	-0,943	-0,986	-1,032	-1,111	-1,265	-1,219	-1,131	-0,963	-0,764	-0,538	-0,255
2016	-0,156	-0,082	-0,012	0,057	0,173	0,294	0,346	0,416	0,475	0,533	0,594	0,653
2017	0,693	0,724	0,760	0,771	0,766	0,739	0,698	0,643	0,536	0,393	0,240	0,163
2018	0,065	-0,050	-0,153	-0,223	-0,249	-0,260	-0,237	-0,232	-0,222	-0,211	-0,207	-0,098
2019	-0,072	-0,043	-0,019	-0,008	-0,009	0,024	0,142	0,316	0,511	0,735	0,934	1,069
2020	1,191	1,291	1,370	1,409	1,410	1,409	1,320	1,213	1,053	0,854	0,647	0,481
2021	0,343	0,217	0,110	0,020	-0,018	-0,144	-0,267	-0,398	-0,549	-0,705	-0,841	-0,775
2022	-0,837	-0,853	-0,902	-0,903	-0,934	-0,797	-0,663	-0,519	-0,317	-0,082	0,160	0,420

Tablo 13'te ≤ -2 değer aralığında 18 ay %4,2 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 29 ay %6,7 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 24 ay %5,5 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 57 ay %13 normale yakın kurak, toplamda 37 yılda 128 ay %29,4 kurak dönem olduğu görülmüştür.

Tablo 13. Kığ (Yaylabaşı) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemlice	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
18	29	24	57	137	117	48	3	0

Tablo 14'te Harabedi (Üçkonak) istasyonu verileriyle 1 aylık zaman ölçekli kurak dönemler hesap edilmiştir. 1986 yılında 4 ay normale yakın kuraklık, 4 ay normal kuraklık, 2 ay şiddetli kuraklık, kalan 2 ay ise normal seviyede olduğu görülmüştür. 2004 yılının ocak ayında aşırı kurak yaşanmıştır. 2003 yılında başlayan normal kuraklık 2014 yılından itibaren orta düzey kuraklıkla devam edip 2022 yılına kadar olan bölümde tamamen şiddetli kuraklık olduğu hesaplanmıştır.

Tablo 14. Harabedi (Üçkonak) istasyonu 1 aylık zaman ölçekli kuraklık değerleri

	Oca.	Şubat	Mar.	Nisan	May.	Hazi.	Tem.	Ağu.	Eyl.	Ek.	Kas.	Ara.
1986	-0,449	-0,722	-0,551	0,463	0,838	0,177	-0,141	-1,690	-1,625	-1,023	-0,925	-0,781
1987	-0,449	-0,124	-0,476	0,392	-0,302	0,177	-0,428	-0,049	-0,056	-0,125	-0,235	-0,202
1988	-0,060	-0,124	1,039	0,749	1,332	0,000	1,937	0,976	1,065	1,109	2,043	2,047
1989	1,885	2,678	2,629	2,715	1,788	1,319	1,364	1,017	1,699	1,034	1,767	1,876
1990	1,274	2,267	1,947	1,607	2,434	2,160	1,364	1,058	0,915	1,857	1,836	1,740
1991	1,496	1,893	2,023	2,036	1,902	2,059	2,117	2,493	1,812	1,857	1,871	1,570
1992	1,329	0,000	0,000	0,785	0,914	1,454	1,149	0,705	0,766	0,511	0,525	0,343
1993	0,551	0,000	0,736	0,499	0,800	1,185	0,575	0,771	0,000	0,585	0,456	0,411
1994	0,551	0,361	0,168	0,535	-0,226	-0,630	-0,643	-0,295	-0,355	-0,013	-0,097	-0,066
1995	0,107	0,100	0,168	-0,109	0,078	-0,092	0,145	0,771	0,691	1,408	0,000	1,365
1996	1,107	1,295	1,190	1,106	0,000	0,916	1,077	0,976	1,625	1,259	1,353	1,229
1997	0,607	0,772	0,000	0,000	0,914	0,782	1,221	1,509	1,139	1,049	0,835	0,956
1998	1,302	0,623	0,887	0,785	0,762	0,647	1,149	0,853	0,504	0,735	0,456	0,854
1999	0,551	0,548	0,433	0,356	0,000	0,580	0,647	0,607	0,915	0,698	0,000	0,411
2000	0,829	0,922	0,509	0,000	0,192	0,210	0,000	0,156	0,691	0,585	1,250	0,000
2001	0,318	0,347	0,244	0,177	0,116	0,123	0,303	0,566	0,616	0,458	0,041	0,139
2002	0,118	0,115	0,092	0,149	0,154	0,042	0,475	0,894	1,625	0,398	0,104	0,070
2003	0,084	0,025	-0,021	-0,237	-0,491	-0,159	0,045	0,164	-0,123	0,413	0,214	0,200
2004	-3,690	-0,005	0,039	0,084	0,329	0,425	0,468	0,369	0,250	0,219	0,062	0,016
2005	0,118	-0,012	-0,037	-0,037	0,314	0,412	0,188	0,115	-0,078	0,129	0,283	-0,168
2006	0,051	0,100	0,054	0,120	-0,013	0,580	0,067	0,098	-0,011	0,032	0,090	0,016
2007	0,134	0,197	0,175	0,034	0,132	0,311	-0,235	-0,238	-0,280	-0,260	-0,311	-0,332
2008	-0,094	-0,124	-0,090	-0,066	0,109	0,156	0,110	0,533	0,303	0,264	0,124	0,057
2009	0,134	0,205	0,206	0,249	0,291	0,378	0,332	0,443	0,243	0,324	0,283	-0,039
2010	0,118	0,100	0,107	-0,094	-0,089	0,136	-0,901	-0,566	-0,609	-0,320	-0,331	-0,080
2011	-0,127	-0,214	-0,476	-0,330	-0,317	-0,395	-0,227	-0,066	-0,146	0,010	0,041	-0,154
2012	-0,010	-0,094	0,001	-0,159	-0,309	-0,469	-0,550	-0,673	-0,303	-0,544	-0,352	0,145
2013	-0,238	-0,401	0,001	-0,252	-0,256	-0,556	-0,557	-0,443	-0,265	-0,357	-0,228	-0,216
2014	0,001	-0,050	-0,021	-0,051	-0,134	-0,496	-0,442	-0,787	-1,326	-1,359	-1,098	-1,088
2015	-0,700	-1,036	-0,953	-0,981	-1,099	-1,269	-1,217	-1,296	-1,259	-1,292	-0,449	-0,420
2016	-1,161	-1,566	-1,521	-1,567	-1,228	-1,067	-1,016	-1,115	-1,117	-1,255	-1,187	-1,197
2017	-0,844	-1,163	-1,195	-1,252	-1,092	-1,101	-1,152	-1,157	-1,094	-1,344	-1,201	-1,286
2018	-0,933	-1,320	-1,324	-1,402	-1,403	-1,524	-1,016	-0,738	-0,594	-0,851	-0,925	-0,945
2019	-0,633	-0,894	-1,028	-1,124	-1,107	-1,228	-1,123	-1,091	-0,915	-1,045	-1,091	-1,095
2020	-0,755	-1,148	-1,263	-1,374	-1,502	-1,437	-1,374	-1,206	-1,154	-1,374	-1,408	-1,443
2021	-1,100	-1,566	-1,642	-1,681	-1,669	-1,705	-1,718	-1,624	-1,655	-1,928	-1,905	-1,933
2022	-1,422	-1,985	-2,051	-2,124	-2,163	-2,102	-1,991	-2,042	-1,894	-1,846	-1,892	-2,001

Tablo 15'te ≤ -2 değer aralığında 7 ay %1,6 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 23 ay %5,2 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 56 ay %12,6 orta düzeyde kurak, $-0,5 \sim -0,99$ değer

aralığında 29 ay %6,5 normale yakın kurak, toplamda 37 yılda 115 ay %26 kurak dönem olduğu görülmüştür.

Tablo 15. Harabedi (Üçkonak) istasyonu 1 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı

Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemlice	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
7	23	56	29	214	50	32	20	13

Tablo 16. Harabedi (Üçkonak) istasyonu 12 aylık zaman ölçekli kuraklık değerleri

	Oca.	Şubat	Mar.	Nisan	May.	Hazi.	Tem.	Ağu.	Eyl.	Ek.	Kas.	Ara.
1986	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	-0,568
1987	-0,653	-0,594	-0,583	-0,578	-0,668	-0,652	-0,672	-0,539	-0,400	-0,310	-0,249	-0,176
1988	-0,196	-0,192	-0,053	-0,012	0,138	0,125	0,346	0,427	0,524	0,862	0,843	1,079
1989	1,307	1,561	1,705	1,881	1,918	2,027	1,975	1,972	2,022	2,000	1,975	1,987
1990	1,945	1,906	1,847	1,735	1,789	1,853	1,854	1,851	1,778	1,854	1,843	1,857
1991	1,911	1,876	1,884	1,916	1,866	1,837	1,906	2,015	2,087	2,045	2,075	2,087
1992	2,104	1,931	1,752	1,627	1,539	1,465	1,378	1,232	1,138	0,933	0,890	0,796
1993	0,679	0,681	0,749	0,723	0,716	0,687	0,637	0,641	0,573	0,559	0,572	0,600
1994	0,569	0,604	0,556	0,562	0,476	0,298	0,191	0,106	0,076	0,005	-0,024	-0,050
1995	-0,165	-0,185	-0,181	-0,233	-0,198	-0,137	-0,060	0,026	0,118	0,313	0,253	0,409
1996	0,491	0,601	0,696	0,810	0,806	0,900	0,988	1,002	1,080	1,111	1,188	1,199
1997	1,135	1,088	0,985	0,880	0,962	0,942	0,958	0,998	0,953	0,935	0,882	0,879
1998	0,946	0,933	1,015	1,087	1,075	1,053	1,049	0,994	0,936	0,874	0,869	0,882
1999	0,773	0,768	0,730	0,691	0,627	0,618	0,576	0,555	0,590	0,528	0,543	0,522
2000	0,522	0,557	0,567	0,536	0,557	0,520	0,464	0,427	0,407	0,435	0,515	0,497
2001	0,399	0,349	0,329	0,349	0,348	0,341	0,373	0,405	0,398	0,340	0,275	0,308
2002	0,239	0,221	0,211	0,213	0,223	0,218	0,238	0,264	0,352	0,306	0,353	0,368
2003	0,322	0,316	0,309	0,277	0,227	0,210	0,175	0,117	-0,035	0,003	-0,019	0,013
2004	-0,505	-0,504	-0,494	-0,453	-0,371	-0,303	-0,259	-0,241	-0,207	-0,186	-0,231	-0,231
2005	0,164	0,166	0,163	0,157	0,162	0,165	0,143	0,124	0,095	0,081	0,112	0,114
2006	0,052	0,065	0,077	0,098	0,076	0,098	0,091	0,090	0,096	0,081	0,074	0,110
2007	0,067	0,079	0,093	0,091	0,111	0,089	0,066	0,040	0,017	-0,061	-0,041	-0,055
2008	-0,144	-0,170	-0,189	-0,191	-0,184	-0,191	-0,154	-0,091	-0,040	0,017	0,051	0,107
2009	0,081	0,114	0,144	0,179	0,201	0,226	0,251	0,244	0,238	0,224	0,261	0,272
2010	0,224	0,217	0,212	0,184	0,157	0,138	0,029	-0,050	-0,124	-0,187	-0,231	-0,217
2011	-0,315	-0,339	-0,387	-0,399	-0,410	-0,450	-0,383	-0,341	-0,299	-0,240	-0,228	-0,217
2012	-0,272	-0,257	-0,210	-0,186	-0,177	-0,175	-0,200	-0,247	-0,259	-0,279	-0,337	-0,290
2013	-0,390	-0,414	-0,410	-0,408	-0,394	-0,391	-0,386	-0,366	-0,360	-0,330	-0,325	-0,342
2014	-0,387	-0,351	-0,349	-0,320	-0,301	-0,285	-0,269	-0,294	-0,385	-0,579	-0,545	-0,611
2015	-0,783	-0,867	-0,946	-1,018	-1,090	-1,144	-1,208	-1,243	-1,233	-1,113	-1,150	-1,073
2016	-1,237	-1,279	-1,324	-1,361	-1,358	-1,314	-1,288	-1,268	-1,251	-1,252	-1,301	-1,361
2017	-1,443	-1,400	-1,366	-1,319	-1,292	-1,272	-1,276	-1,275	-1,268	-1,284	-1,261	-1,255
2018	-1,382	-1,390	-1,397	-1,392	-1,405	-1,421	-1,400	-1,361	-1,313	-1,230	-1,228	-1,182
2019	-1,258	-1,213	-1,182	-1,139	-1,100	-1,050	-1,052	-1,076	-1,100	-1,125	-1,118	-1,117
2020	-1,242	-1,259	-1,275	-1,281	-1,301	-1,298	-1,313	-1,317	-1,333	-1,386	-1,374	-1,394
2021	-1,559	-1,589	-1,618	-1,626	-1,625	-1,623	-1,646	-1,673	-1,711	-1,803	-1,784	-1,819
2022	-2,001	-2,031	-2,062	-2,079	-2,104	-2,108	-2,123	-2,148	-2,162	-2,143	-2,129	-2,125

Tablo 16’da Harabedi (Üçkonak) istasyonu verileriyle 12 aylık zaman serisinin yeraltı suyu seviyesi hesaplamıştır. 1987’nin tamamı ve 1988 yılının nisan ayına kadar kuraklığın olduğu

gözlemlenmiştir. 1989 ve 2007 yılları arasında, 1994 yılının kasım ayı ile 1995 yılının temmuz ayı arasında ve 2004 yılının tamamında kuraklığın olduğu hesap edilmiştir. 2007 yılının ekim ayında tekrar başlayan kuraklık dönemi 2008 yılının eylül ayına kadar sürmüştür ve 2010 ağustos ayında tekrardan başlayan kuraklık 2022 yılı da dahil bu aradaki bütün aylarda istasyon verileriyle kurak ve aşırı kurak olduğu hesap edilmiştir.

Tablo 17’de ≤ -2 değer aralığında 12 ay %2,8 aşırı kurak, $-1,5 \sim -1,99$ değer aralığında 12 ay %2,8 şiddetli kurak, $-1 \sim -1,49$ değer aralığında 69 ay %15,9 orta düzeyde kurak, $-0,5 \sim -0,99$ değer aralığında 17 ay %3,9 normale yakın kurak, toplamda 37 yılda 110 ay %25,4 kurak dönem olduğu görülmüştür.

Tablo 17. Harabedi (Üçkonak) istasyonu 12 aylık zaman ölçekli 1986-2022 yılları arası kurak ayların sayısı


Aşırı Kurak	Şiddetli Kurak	Orta Düzeyde Kurak	Normale Yakın kurak	Normal	Normale Yakın Nemlice	Orta Düzeyde Nemli	Çok Nemli	Aşırı Nemli
12	12	69	17	202	64	18	30	9

4.2. SGI Değerlerinin Tahmini


SGI değerlerinin tahmini için SSA veri ayrıştırma tekniği ile ANFIS, CatBoost, CNN, Otokodlayıcı, DNN, GRU ve LSTM modellerine başvurulmuştur. Modelleme sırasında girdi değişkenlerinin seçimi için çapraz korelasyonlar ve Kısmi korelasyon analizleri yapılmıştır. (Tablo 18 ve Şekil 6). Buna göre Erzincan merkezde 4 istasyon olmasına rağmen tahmin modellerinin kurulumunda meteoroloji istasyonunun konum olarak en yakın ve SGI indisleri ile en yüksek ilişkiye sahip olan Harabedi (Üçkonak) istasyonunun seçilmiştir. SGI 1 ve 12 değerlerinin tahminimdeki geçmiş girdilerin seçilmesinde ise SGI değerlerinin kısmi otokorelasyon analizlerine göre belirlenmiştir. Buna göre SGI1 (t) değerlerinin tahmininde %95 güven limitlerin aşan SGI1 (t-1) ve SGI1 (t-2) değerleri ve SGI12 (t) tahmininde ise SGI12 (t-1) değerleri girdi olarak seçilmiştir (Şekil 6).

Tablo 18. SGI değerleri ile meteorolojik değişkenler arasındaki çapraz korelasyonlar

	Brastik (Çatalören)		Karakaya		Kığ (Yaylabaşı)		Harabedi (Üçkonak)	
	SGI-1	SGI-12	SGI-1	SGI-12	SGI-1	SGI-12	SGI-1	SGI-12
Korelasyon katsayıları								
P	0.01	-0.03	0.02	-0.02	-0.04	-0.06	0.03	0.04
T	0.01	0.00	-0.03	-0.03	0.03	0.04	-0.06	-0.07
RH	0.02	0.00	0.19	0.19	-0.04	-0.09	0.32	0.33



Şekil 6. SGI-1 değerlerine ait PACF grafiği




Şekil 7. SGI-12 değerlerine ait PACF grafiği

PACF Grafiklerine göre SGI-1 değerlerinin tahmininde %95 güven limitlerin önemli ölçüde geçen 1 ve 2 aylık gecikmeler seçilirken SGI-12 için sadece 1 aylık gecikme kullanılacaktır. Buna göre SGI tahmin modellerinin girdi ve hedef kombinasyonları Tablo 19’da sunulmuştur.


Tablo 19. Seçilen model kombinasyonları

Girdi	Hedef
P, T, RH, SGI-1 (t-1), SGI-1 (t-2)	SGI-1 (t)
P, T, RH, SGI-12 (t-1)	SGI-12 (t)


Hibrit modellerin kurulumunda ilk olarak tüm girdi değişkenleri trend, mevsimsellik, döngü ve gürültü alt bileşenlerine ayrılarak tüm bileşenler ayrı ayrı seri olarak derin öğrenmesi modeline sunulması ile SSA1 olarak adlandırılmıştır. İkinci olarak gürültü bileşeni atılarak trend, mevsimsellik ve döngü alt bileşenlerinin tümünün ayrı ayrı ML modeline sunulması ile SSA2 olarak adlandırılan yaklaşım denenmiştir. Şekil 8-13’te girdi serisinin SSA ile alt serilere ayrıştırılması sonucu elde edilen trend, mevsimsellik, döngü ve gürültü alt bileşenleri gösterilmiştir.




Şekil 8. Yağış serisinin SSA ile alt serilere ayrıştırılması




Şekil 9. Sıcaklık serisinin SSA ile alt serilere ayrıştırılması




Şekil 10. Rölatif nem serisinin SSA ile alt serilere ayrıştırılması



Şekil 11. SGI 1 (t-1) serisinin SSA ile alt serilere ayrıştırılması



Şekil 12. SGI 1 (t-2) serisinin SSA ile alt serilere ayrıştırılması



Şekil 13. SGI 12 (t-1) serisinin SSA ile alt serilere ayrıştırılması

Tablo 20’de SGI1 değerlerinin test aşamasındaki ML ve SSA tabanlı ML tahmin sonuçları gösterilmiştir. Kurulan modellerin tahmin doğruluğu en düşük AIC ve hata değerleri ve R^2 , NSE, KGE, BF ve Pbias değerlerinin 1’ yakınlığına göre belirlenmiştir. Buna göre tekil modeller ve SSA1 tabanlı modeller arasında ANFIS modeli en doğru sonuçları gösterirken SSA2 tabanlı modellerde LSTM modeli en doğru sonuçları göstermiştir. Tekli modellerde ANFIS modeli, RMSE: 0.316, MAE: 0.262, AIC:-280.506, NSE: 0.650, KGE: 0.671, R^2 : 0.772, MBE: 0.170, BF: 1.191, Pbias: -15.525 değerleri ile en üstün sonuçları göstermiştir. SSA1 tabanlı modellerde ise ANFIS modeli RMSE: 0.236, MAE: 0.195, AIC: -354.255, NSE: 0.805, KGE: 0.883, R^2 : 0.843, MBE: -0.087, BF: 1.889, Pbias: 7.947 değerleri ile en doğru sonuçları göstermiştir. SSA2 tabanlı modellerde ise LSTM modeli RMSE: 0.217, MAE: 0.170, AIC: -

375.257, NSE: 0.835, KGE: -0.786, R^2 : 0.856, MBE: 0.074, BF: -0.099, Pbias: -6.763 değerleri ile en üstün sonuçları göstermiştir. Buna göre ANFIS tabanlı modellerin yapay sinir ağı ve bulanık mantık yaklaşımlarının birleştirilerek SGI tahminlerinde genel olarak öne çıktığı çıkarımı yapılabilmektedir. Ayrıca trend, mevsimsellik ve döngü alt bileşenlerinden oluşan SSA2 yaklaşımın ile kurulan tahminlerin genellikle tüm alt bileşenin girdi olarak sunulması ile kurulan SSA1 yaklaşımından daha doğru sonuçlar sergilediği ortaya çıkarılmıştır. Ek olarak SSA tabanlı modeller tekli ML modellerinin performansını genellikle artırdığı görülmüştür.

Tablo 20. Test aşamasına ait SGI1 tahmin sonuçları


	ANFIS	Autoencoder	Catboost	CNN	DNN	GRU	LSTM
RMSE	0.316	0.447	1.102	0.571	0.528	0.799	0.649
MAE	0.262	0.356	0.972	0.480	0.431	0.721	0.581
AIC	-280.506	-192.870	34.376	-131.413	-151.037	-46.580	-99.022
NSE	0.650	0.298	-3.261	-0.143	0.022	-1.241	-0.478
KGE	0.671	0.461	-0.442	0.275	0.496	0.129	0.129
R^2	0.772	0.660	0.029	0.738	0.563	0.719	0.571
MBE	0.170	0.294	0.968	0.441	0.393	0.715	0.546
BF	1.191	1.382	-14.812	1.586	1.430	2.991	1.256
Pbias	-15.525	-26.814	-88.239	-40.204	-35.805	-65.229	-49.789
	SSA1_ANFIS	SSA1_Autoe.	SSA1_Cat.	SSA1_CNN	SSA1_DNN	SSA1_GRU	SSA1_LSTM
RMSE	0.236	0.843	0.843	0.288	0.611	1.704	0.309
MAE	0.195	0.640	0.640	0.249	0.539	1.618	0.265
AIC	-354.255	-32.937	-32.937	-303.564	-113.981	144.334	-286.306
NSE	0.805	-1.497	-1.497	0.708	-0.313	-9.198	0.666
KGE	0.883	0.042	0.042	0.773	0.496	-1.108	-1.108
R^2	0.843	0.035	0.035	0.803	0.628	0.017	0.852
MBE	-0.087	0.542	0.542	-0.163	-0.503	1.618	0.229
BF	1.889	1.880	1.880	0.814	0.658	-2.101	1.482
Pbias	7.947	-49.468	-49.468	14.854	45.892	-147.581	-20.869
	SSA2_ANFIS	SSA2_Autoe.	SSA2_Cat.	SSA2_CNN	SSA2_DNN	SSA2_GRU	SSA2_LSTM
RMSE	0.335	0.256	1.112	0.255	0.398	1.500	0.217
MAE	0.295	0.214	0.988	0.189	0.325	1.404	0.170
AIC	-265.954	-333.402	36.821	-334.169	-222.128	112.210	-375.257
NSE	0.607	0.770	-3.344	0.771	0.444	-6.903	0.835
KGE	0.754	0.880	-0.459	0.711	0.558	-0.786	-0.786
R^2	0.842	0.782	0.037	0.806	0.774	0.037	0.856
MBE	-0.253	0.027	0.981	0.047	0.284	1.404	0.074
BF	0.787	1.077	-13.696	0.996	1.285	-3.623	-0.099
Pbias	23.043	-2.463	-89.480	-4.265	-25.910	-128.013	-6.763

Tablo 21’de SGI12 değerlerinin test aşamasındaki ML ve SSA tabanlı ML tahmin sonuçları sunulmuştur. İstatistiksel metriklere göre tekil modeller ve SSA tabanlı modeller arasında ANFIS modeli en doğru sonuçları sergilemiştir. Tekli modellerde ANFIS modeli, RMSE: 0.099, MAE: 0.083, AIC:-574.009, NSE: 0.965, KGE: 0.915, R^2 : 0.991, MBE: 0.082, BF: 1.093, Pbias: -7.059 değerleri ile en üstün sonuçları göstermiştir. SSA1 tabanlı modellerde ise ANFIS modeli RMSE: 0.212, MAE: 0.185, AIC:-381.054, NSE: 0.839, KGE: 0.821, R^2 : 0.961,

MBE: 0.182, BF: 1.316, Pbias: -15.708 değerleri ile en doğru sonuçları göstermiştir. SSA2 tabanlı modellerde ise LSTM modeli RMSE: 0.133, MAE: 0.107, AIC:-499.901, NSE: 0.936, KGE: 0.915, R²: 0.940, MBE: -0.024, BF: 0.964, Pbias: 2.108 değerleri ile en üstün sonuçları göstermiştir. Analizler sonucunda ANFIS tabanlı modellerin yapay sinir ağı ve bulanık mantık yaklaşımlarının birleştirilerek SGI tahminlerinde diğer ML modellerinden daha üstün sonuçlar gösterdiği ortaya çıkarılmıştır. Ayrıca trend, mevsimsellik, döngü ve gürültü alt bileşenlerinden oluşan SSA1 yaklaşımının ile kurulan tahminlerin genellikle gürültü alt bileşenin olmadığı SSA2 yaklaşımından daha zayıf sonuçlar sergilediği ortaya çıkarılmıştır. Buna göre gürültü bileşenlerinin atılarak modelleme yapılması gerektiği ortaya çıkarılmıştır.


Tablo 21. Test aşamasına ait SGI12 tahmin sonuçları

	ANFIS	Autoencoder	Catboost	CNN	DNN	GRU	LSTM
RMSE	0.099	0.528	0.921	0.349	0.279	0.549	0.480
MAE	0.083	0.432	0.779	0.276	0.215	0.490	0.446
AIC	-574.009	-150.969	-10.844	-254.973	-312.124	-141.125	-175.028
NSE	0.965	-0.002	-2.046	0.561	0.721	-0.083	0.172
KGE	0.915	0.371	-0.183	0.556	0.667	0.387	0.387
R²	0.991	0.746	0.279	0.952	0.938	0.955	0.912
MBE	0.082	0.414	0.779	0.273	0.209	0.490	0.446
BF	1.093	1.549	3.030	1.259	1.195	1.773	2.714
Pbias	-7.059	-35.810	-67.388	-23.621	-18.039	-42.376	-38.599
	SSA1_ANFIS	SSA1_Autoe.	SSA1_Cat.	SSA1_CNN	SSA1_DNN	SSA1_GRU	SSA1_LSTM
RMSE	0.212	0.706	1.139	0.473	0.494	1.863	0.253
MAE	0.185	0.594	1.009	0.417	0.403	1.787	0.216
AIC	-381.054	-77.900	42.885	-178.849	-167.857	166.776	-336.332
NSE	0.839	-0.789	-3.665	0.197	0.124	-11.471	0.770
KGE	0.821	0.248	-0.550	0.556	0.371	-1.064	-1.064
R²	0.961	0.459	0.002	0.853	0.902	0.003	0.898
MBE	0.182	0.585	1.009	0.417	0.391	1.787	0.189
BF	1.316	1.669	32.195	2.207	1.430	-1.834	1.272
Pbias	-15.708	-50.620	-87.233	-36.112	-33.845	-154.541	-16.318
	SSA2_ANFIS	SSA2_Autoe.	SSA2_Cat.	SSA2_CNN	SSA2_DNN	SSA2_GRU	SSA2_LSTM
RMSE	0.133	0.575	1.156	0.548	0.243	1.810	0.357
MAE	0.107	0.500	1.032	0.472	0.195	1.731	0.328
AIC	-499.901	-131.454	44.631	-143.782	-348.706	157.507	-251.754
NSE	0.936	-0.188	-3.806	-0.077	0.788	-10.772	0.543
KGE	0.915	0.396	-0.489	0.369	0.833	-1.054	-1.054
R²	0.940	0.682	0.021	0.911	0.820	0.000	0.932
MBE	-0.024	0.477	1.032	0.472	0.093	1.731	0.327
BF	0.964	1.354	0.590	1.668	1.088	-2.011	1.789
Pbias	2.108	-41.240	-89.253	-40.837	-8.052	-149.748	-28.242




Şekil 14. SGI 1 değerlerinin tekil ML yaklaşımları tahminlerine ait saçılma diyagramları

Şekil 14'te SGI 1 değerlerinin test aşamasına ait tekil ML tahminleri saçılma diyagramları ile ifade edilmiştir. Saçılma diyagramlarına göre tahmin edilen SGI değerleri ve gözlemlene SGI arasındaki ilişki ve dağılım değerlendirilmiştir. Buna ANFIS, GRU ve CNN tahminleri lineer regresyon hattı etrafında dağılması nedeniyle öne çıkmaktadır. Catboost modeli ise tahminlerin rastgele dağılması nedeniyle hataların yüksek olduğu söylene bilir. Ayrıca tahminlerin R^2 değerlerine göre ANFIS modeli en yüksek R^2 :0.77 ile en doğru sonuçları verdiği çıkarımı yapılabilir.




Şekil 15. SGI 12 değerlerinin tekil ML yaklaşımları tahminlerine ait saçılma diyagramları

Şekil 15'te SGI 12 değerlerinin test aşamasına saçılma diyagramları sunulmuştur. Saçılma diyagramlarına göre tahmin edilen SGI değerleri ve gözlemlene SGI arasındaki ilişki ve dağılım değerlendirilmiştir. Buna tüm modeller SGI 1 değerlerine göre lineer regresyon hattına daha yakı olması nedeniyle tekli ML modellerinin SGI12 değerlerini daha iyi tahmin edebildiği çıkarımı yapılabilmektedir. Ek olarak ANFIS, GRU ve CNN tahminleri lineer regresyon hattı etrafında dağılması nedeniyle umut verici tahminlerde bulunduğu söylenebilir. Catboost modeli ise tahminlerin rastgele dağılması modelin tahmin sapmalarının yüksekliği ve genelleme yeteneğinin zayıflığına işaret etmektedir. Ayrıca tahminlerin R^2 değerlerine göre ANFIS modeli en yüksek R^2 :0.99 ile en üstün model olduğu tespit edilmiştir.




Şekil 16. SGI 1 değerlerinin SSA1 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları

Şekil 16'da SGI 1 değerlerinin test aşamasına ait SSA1 tabanlı ML tahmin sonuçları gösterilmiştir. Saçılma diyagramalar değerlendirildiğinde SSA tabanlı modellerin tekli ML modellerine göre regresyon hattının üzerine daha yakın dağıldığı görülmektedir. Bu SSA1 analizinin SGI1 tahmin doğruluğunun önemli ölçüde geliştirdiğine işaret etmektedir. Ayrıca ANFIS, LSTM ve CNN tahminleri lineer regresyon hattı etrafında dağılması nedeniyle öne çıkmaktadır. Catboost, GRU ve Autoencoder modelleri rastgele dağılım sergilemesi nedeniyle yüksek hataya sahip olduğu tespit edilmiştir. Ayrıca LSTM modeli en yüksek R^2 :0.85 ile en üstün model olarak değerlendirilebilir.




Şekil 17. SGI 12 değerlerinin SSA1 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları

Şekil 17’de SGI 12 değerlerinin test aşamasına ait SSA1 tabanlı ML tahmin sonuçları sunulmuştur. Saçılma diyagramlar değerlendirildiğinde SSA tabanlı modellerin tekli ML modellerine benzer ancak biraz daha geniş dağılım sergilediği dikkat çekmektedir. Bu durum R^2 değerlerine göre SSA1 analizinin SGI12 tahminlerinde bir miktar zayıflama olabileceğine işaret etmektedir. Ayrıca ANFIS modeli en yüksek R^2 :0.96 ile en üstün model olarak değerlendirilebilir.




Şekil 18. SGI 1 değerlerinin SSA2 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları

Şekil 18’de SGI 1 değerlerinin test aşamasına ait SSA2 tabanlı ML tahmin saçılma diyagramları gösterilmiştir. Saçılma diyagramlar değerlendirildiğinde SSA tabanlı modellerin tekli ML modellerine benzer ancak biraz daha sıkı ve lineer regresyon hattına yakın dağılım sergilediği dikkat çekmektedir. Bu durum R^2 değerlerine göre SSA2 analizinin SGI1 tahminlerinde bir miktar güçlendirdiğini göstermektedir. Ayrıca LSTM modeli en yüksek R^2 :0.86 ile en üstün model olarak değerlendirilebilir. Şekil 19’da SGI 12 değerlerinin tahmin sonuçları gösterilmiştir. Tahmin sonuçları genel olarak SSA1 dağılımlarına benzerlik göstermektedir. Ayrıca ANFIS modeli en yüksek R^2 :0.94 ile en üstün model olarak değerlendirilebilir. İkinci en iyi model ise R^2 :0.93 ile LSTM olarak ifade edilebilir.




Şekil 19. SGI 12 değerlerinin SSA2 tabanlı ML yaklaşımları tahminlerine ait saçılma diyagramları




Şekil 20. SGI1 değerlerinin ML modelleri ile tahminlerine ait ısı haritaları

Şekil 20’ de SGI1 değerlerinin ML modelleri ile üretilen tahmin sonuçlarının gerçek veriler ile korelasyonlarına ait ısı haritaları gösterilmiştir. Her bir hücre iki model arasındaki korelasyon katsayısını göstermektedir. Korelasyon katsayısı 1'e yaklaştıkça, iki modelin tahminleri arasındaki ilişki kuvvetlenir; 0'a yaklaştıkça ilişki zayıflar; negatif değerler ise ters ilişkiyi gösterir. Bu kriterlere göre gerçek değerler ile en yüksek korelasyona (R:0.88) sahip olan ANFIS model en doğru sonuçları gösterirken en zayıf ilişkiye (R: 0.17) sahip olan Catboost modeli ise en düşük performans göstermiştir. Ayrıca derin öğrenme modelleri (R:0.75-0.86) arasında değerler ile tatmin edici SGI 1 tahminlerinde bulunduğu ifade edilmiştir. Ek olarak CNN ve ANFIS modelleri arasında yüksek bir korelasyon vardır (R: 0.96), bu da bu iki modelin benzer tahminler ürettiğini gösterir.




Şekil 21. SGI12 değerlerinin ML modelleri ile tahminlerine ait ısı haritaları

Şekil 21’de SGI12 değerlerinin ML modelleri ile üretilen tahmin sonuçlarının gerçek veriler ile korelasyonlarına ait ısı haritaları gösterilmiştir. Gerçek değerler ile en yüksek korelasyona (R:1) sahip olan ANFIS model en doğru sonuçları gösterirken en zayıf ilişkiye (R: 0.53) sahip olan Catboost modeli ise en düşük performans göstermiştir. Ayrıca derin öğrenme modelleri (R:0.86-0.98) arasında değerler ile tatmin edici SGI 12 tahminlerinde bulunduğu ifade edilmiştir. En düşük tahmin doğruluğu R: 0.86 ile Autoencoder modeli ile elde edilmiştir. Ayrıca ANFIS modeli ile CNN ve GRU modelleri arasında (R: 0.98) değeri ile çok yüksek bir ilişkinin olması tahminlerin benzer olduğunu işaret etmektedir.




Şekil 22. SGI1 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait ısı haritaları

Şekil 22’de SGI1 değerlerinin SSA1 tabanlı ML modellerine ait tahmin sonuçlarının karşılaştırılması yapılmıştır. Gerçek değerler ile en yüksek korelasyona (R:0.92) sahip olan ANFIS ve LSTM modelleri en doğru çıktıları üretirken en zayıf ilişkiye (R: 0.13) sahip olan GRU modeli ise en düşük tahmin doğruluğuna sahiptir. Ayrıca CNN ve DNN gibi derin öğrenme modelleri tatmin edici SGI 1 tahminleri gösterirken GRU ve Autoencoder modelleri oldukça zayıf tahmin sonuçları göstermiştir. Ayrıca ANFIS modeli ile CNN ve LSTM modelleri arasında (R: 0.94 ve 0.90) değeri ile çok yüksek bir ilişkinin olması tahminlerin benzer olduğun işaret etmektedir.



Şekil 23. SGI12 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait ısı haritaları


Şekil 23'te SGI12 değerlerinin SSA1 tabanlı ML modelleri ile elde edilen çıktıların ısı haritası gösterilmiştir. Gerçek değerler ile en yüksek korelasyona (R:0.98) sahip olan ANFIS modeli en doğru sonuçları gösterirken en zayıf ilişkiye (R: 0.13) sahip olan Catboost modeli ise en düşük performans göstermiştir. Ayrıca CNN, LSTM ve DNN gibi derin öğrenme modelleri tatmin edici SGI 12 tahminleri gösterirken GRU modeli oldukça zayıf tahmin sonuçları göstermiştir. Ayrıca ANFIS modeli ile DNN ve LSTM modelleri arasında (R: 0.96 ve 0.92) değeri ile çok yüksek bir ilişkinin olması tahminlerin benzer olduğun işaret etmektedir. SSA1_Catboost ve SSA1_GRU gibi modeller, gerçek değerlerle düşük korelasyonları nedeniyle bu tahmin görevi için uygun değildir.



Şekil 24. SGI1 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait ısı haritaları


Şekil 24'te SGI1 değerlerinin SSA2 tabanlı ML modelleri ile elde edilen çıktılarının ısı haritası gösterilmiştir. Gerçek değerler ile en yüksek korelasyona ($R:0.93$) sahip olan LSTM modeli en doğru sonuçları gösterirken en zayıf ilişkiye ($R: 0.19$) sahip olan GRU ve Catboost modeli ise en düşük performans göstermiştir. Ayrıca CNN, Autoencoder ve DNN gibi derin öğrenme modelleri tatmin edici SGI 1 tahminleri göstermiştir. Ayrıca LSTM modeli ile ANFIS modeli ile ($R: 0.91$) değeri ile çok yüksek bir ilişkinin olması tahminlerin benzer olduğunu işaret etmektedir. Şekil 25'te ise SGI 12 değerlerinin SSA2 tabanlı tahmin sonuçları görselleştirilmiştir. Gerçek değerler ile en yüksek korelasyona ($R:0.97$) sahip olan ANFIS ve LSTM modelleri en üstün model olarak bulunurken en zayıf ilişkiye ($R: -0.01$) sahip olan GRU modeli ise en zayıf tahmin doğruluğuna sahiptir.

SGI 12 değerlerinin tahmini




Şekil 25. SGI12 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait ısı haritaları

Kutu diyagram




Şekil 26. SGI1 değerlerinin ML modelleri ile tahminlerine ait kutu diyagramları

Şekil 26’da SGI1 değerlerinin tekli ML modelleri ile tahminlerine ait test aşamasındaki kutu diyagramları sunulmuştur. Her kutu grafiği, farklı bir modeli temsil eder ve tahminlerini gerçek değerlerle karşılaştırır. Kutu diyagramları ile verilerin dağılımı ve yüzdelik dilimleri kıyaslanmıştır. Gerçek verilere en yakın dağılım sergileyen modeller en iyi model olarak değerlendirilmiştir. Buna göre gerçek veriler ile ANFIS modelini dağılımın en yakın olması ile en doğru olduğu çıkarımı yapılmıştır. Buna göre gerçek verilerin medyan değeri -1.1 civarı iken buna en yakın olan ANFIS modeli -1 iken ve ikinci en iyi olan Autoencoder ise medyan değerleri -0.8 civarındadır. Kutu değerlerin 25. yüzdelik dilimi ile 75. yüzdelik dilimi arasındaki dağılımı gösterir. Buna göre gerçek veriler ve ANFIS modeli çok yakın çeyreklik dilime sahip olası açısından en üstün modeldir. Bıyıklar (Whiskers) genel dağılımını, en düşük ve en yüksek değerleri temsil eder. Autoencoder ve GRU modelinde aykırı değerler bazı tahminler üst sınırın üzerinde yer almaktadır. DNN modelinde aykırı değerler alt sınır altında yer almaktadır. Şekil 27’de SGI12 değerlerinin tekli ML modelleri ile tahminlerine ait test aşamasındaki kutu diyagramları gösterilmiştir. Buna göre gerçek veriler ile ANFIS modelini dağılımın en yakın olması ile en doğru olduğu çıkarımı yapılmıştır. Buna göre gerçek verilerin medyan değeri -1.3 civarı iken buna en yakın olan ANFIS modeli -1.2 iken ve ikinci en iyi olan DNN ise medyan değerleri -1.1 civarındadır. ANFIS modelinin tahminlerinin genel dağılımı, gerçek değerlerin dağılımına yakındır ancak tahminler genellikle daha yüksek değerlere sahiptir. DNN modelinin tahminleri, geniş bir aralıkta dağılmış ve gerçek değerlere oldukça yakın tahminlerde bulunmasına rağmen daha yüksek tahminler üretmesi açısından sapmalarda mevcuttur. Catboost ve CNN modelinin tahminleri, gerçek değerlere göre daha yüksek tahminler göstermektedir ve bazı aykırı değerler üst sınırları üzerindedir.




Şekil 27. SGI12 değerlerinin ML modelleri ile tahminlerine ait kutu diyagramları

Şekil 28’de SGI1 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait test aşamasındaki kutu diyagramları sunulmuştur. Bu diyagramlar göre tahmin değerleri gerçek değerler oldukça yakın bir dağılım sergilemiştir. Bu durum SSA analizinin tekil ML modellerinin doğruluğunun artırdığına işaret etmektedir. Modellerin dağılımları incelendiğinde ANFIS modelinin yüzdelik dilimleri, medyan değeri ve bıyık değerleri gerçek verileri en iyi temsil etmesi nedeniyle optimum model olduğu ortaya çıkarılmıştır. Buna göre gerçek verilerin medyan değeri -1.1 civarı iken buna en yakın olan ANFIS modeli -1.2 iken ve ikinci en iyi olan CNN ve LSTM ise medyan değerleri sırası ile -1.4 ve -1 civarındadır. Şekil 29’da SGI12 değerlerinin SSA1 ile birleştirilmesi sonucunda en iyi tahminler LSTM modeli ile üretilirken ikinci olarak ANFIS modeli oldukça yüksek tahmin doğruluğu göstermiştir. Tüm tahmin sonuçları gerçek verilerden az da olsa daha yüksek SGI12 değerlerine sahip olduğu görülmüştür. Bu durum tahmin modellerinin daha sulak tahminler üretmeye eğilimli olduğuna işaret etmektedir.




Şekil 28. SGI1 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları




Şekil 29. SGI12 değerlerinin SSA1 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları

Şekil 30’da SGI1 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait test aşamasındaki kutu diyagramları gösterilmiştir. Bu diyagramlar göre tahmin değerleri gerçek değerler oldukça yakın bir dağılım sergilemiştir. Bu durum SSA2 analizinin tekil ML modellerinin doğruluğunun artırdığına işaret etmektedir. Kutu ve bıyıkların dağılımları karşılaştırıldığında gerçek verilere en benzer yapıya sahip olan LSTM ve Autoencoder modeli en doğru sonuçları göstermiştir. Bu modellerin ardından ANFIS modeli gelmektedir. Şekil 31’de SGI12 değerlerinin SSA2 tabanlı DNN ve ANFIS modelleri elde edilirken bu modellerden sonra LSTM modeli oldukça yüksek tahmin doğruluğu göstermiştir. Tüm tahmin sonuçları gerçek verilerden az da olsa daha yüksek SGI12 değerlerine sahip olduğu görülmüştür. Bu durum tahmin modellerinin daha sulak tahminler üretmeye eğilimli olduğunu göstermiştir.



Şekil 30. SGI1 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları



Şekil 31. SGI12 değerlerinin SSA2 tabanlı ML modelleri ile tahminlerine ait kutu diyagramları


Tablo 22’de SGI 1 değerlerinin tahmininde kullanılan en iyi model olan ANFIS çıktılarına göre kullanılan girdi parametrelerinin etkileri Sobol duyarlılık analizi ile belirlenmiştir. Buna göre SGI 1(t) değerlerinin tahmin etmek için rölatif nem değerleri birinci derece indeks: 0.3089 ve toplam indeks: 0.3090 değerleri ile en yüksek etkiye sahipken SGI-1 (t-1) değerleri ise birinci derece indeks: 0.3083 ve toplam indeks: 0.3081 değerleri ile ikinci yüksek etkiye sahiptir. Ayrıca yağış değerleri birinci derece indeks: 0.0119 ve toplam indeks: 0.0119 değerleri ile en düşük etkiye sahiptir.

Tablo 22. SGI 1 ANFIS çıktılarına göre parametre etkileri

Değişken	Birinci derece indeks	Toplam indeks
Yağış	0.0119	0.0119
Sıcaklık	0.1224	0.1224
Rölatif Nem	0.3089	0.3090
SGI-1 (t-2)	0.2485	0.2482
SGI-1 (t-1)	0.3083	0.3081

Not: Koyu karakter en yüksek ilişkiyi gösteriyor.

Şekil 32’de SGI 1 tahmindeki girdilerin etkileri Sobol duyarlılık analizi sonuçları sütun diyagramlar ile gösterilmiştir. Bu analize göre SGI 1 değerlerinin tahmininde en yüksek etkiye sahip olan parametreler sırası ile rölatif nem, SGI-1 (t-1), SGI-1 (t-2), sıcaklık ve yağıştır.




Şekil 32. SGI 1 tahmindeki girdilerin etkileri

Tablo 23’te SGI 12 değerlerinin tahmininde kullanılan en iyi model olan ANFIS çıktılarına göre girdi parametrelerinin etkileri Sobol duyarlılık analizine göre belirlenmiştir. Buna göre SGI 12(t) değerlerinin tahmin etmek için rölatif nem değerleri birinci derece indeks: 0.99964 ve toplam indeks: 0.99964 değerleri ile en yüksek etkiye sahiptir. Diğer parametreler ise çok düşük etkiye sahip olduğu tespit edilmiştir.

Tablo 23. SGI 12 ANFIS çıktılarına göre parametre etkileri

Değişken	Birinci derece indeks	Toplam indeks
Yağış	0.00004	0.00004
Sıcaklık	0.00002	0.00002
Rölatif Nem	0.00032	0.00032
SGI-12 (t-1)	0.99964	0.99964

Şekil 33'te SGI 12 tahminindeki girdilerin etkileri Sobol duyarlılık analizi sonuçları sütun diyagramları ile gösterilmiştir. SGI 12 değerlerinin tahmininde en yüksek etkiye sahip olan parametre ise SGI-12 (t-1) olup diğer parametrelerin etkisi yok denecek kadar azdır.



Şekil 33. SGI 12 tahminindeki girdilerin etkileri

5. SONUÇLAR

5.1 TARTIŞMA VE SONUÇ

Bu çalışma kapsamında SSA veri ayrıştırma tekniği ile çeşitli meteorolojik ve hidrolojik değişken alt bileşenlere ayrılarak gürültüye duyarlı hibrit AI modelleri ile yeraltı suyu kuraklığının tahmin edilmesi amaçlanmıştır. Bu çalışma ANFIS modeli genellikle aylık ve 12 aylık zaman ölçeğindeki SGI değerlerinin en doğru tahmin etmiştir. Ayrıca LSTM modellide benzer şekilde yüksek doğrulukta ve umut verici tahminler üretmiştir. Derin öğrenme modellerinin genellikle ANFIS ten zayıf sonuçlar göstermesi veri setinin yeterince uzun olmaması ile açıklayabilmektedir. Çünkü derin öğrenme modelleri genellikle büyük veri ile uyumlu olarak yüksek performans göstermektedir.

Yeganeh vd. (2023) İran'daki Meşhed ovası akiferi üzerindeki GWL'yi tahmin etmek için LSTM dahil olmak üzere çeşitli makine öğrenmesi tekniklerin performansını karşılaştırmıştır. Kapsamlı simülasyonlar ve modellemeler yapılarak en iyi model seçilmekte ve duyarlılık ve belirsizlik analizleri uygulanmıştır. Simülasyonlar sonucunda LSTM modelleri, diğer ML tekniklere kıyasla önemli ölçüde daha iyi performans göstermiştir. Ayrıca alternatiflere göre %13 daha yüksek doğruluk elde ettiği ortaya çıkarılmıştır. Analiz sonuçları yapılan çalışma ile LSTM modelinin yeraltı suyu tahminindeki etkinliği açısından örtüşmektedir. LSTM modeli uzun süreli bağımlılıkları geçmiş verilerden yola çıkarak etkili bir şekilde ortaya çıkartma kapasitesi sayesinde öne çıkmıştır.

Cui vd. (2024) SHAP analizi ile yeraltı suyu seviyesi değerlerin parametrelerin ağırlıkları ortaya çıkarılmıştır. GWL'yi tahmin etmek için ikincil modal ayrıştırma Slime kalıp algoritması (SMA) ve uyarlanabilir ağırlık modülüne (AWM) sahip LSTM ve CNN modelleri uygulanmıştır. LSTM'nin CNN ile kombinasyonu, değişen hidrolojik koşullar altında yeraltı suyu seviyelerini tahmin etmede de ümit verici çıktılar üretmiştir. Sonuç olarak hibrit modeller tekil modellerden daha doğru sonuçlar üretmiştir. Analiz sonuçları yapılan çalışmayı desteklemektedir. Yani hibrit derin öğrenme modelleri genellikle tekil derin öğrenme modellerinden daha üstün sonuçlar üretmiştir.

Liu vd. (2021) Hexi Koridoru, Çinde GWL tahmini için veri pro-işleme, özellik seçimi, derin öğrenme ve belirsizlik analizini entegre eden yeni topluluk derin öğrenme yaklaşımlarının birleştirmiştir. Bunun için tam topluluk deneysel mod ayrıştırması (CEEMDAN), özellik seçimi için genetik algoritma (GA), derin inanç ağı (DBN) modeli ve belirsizlik değerlendirmesi için kantil regresyon (QR) entegre edilerek CEEMDAN-GA-DBN hibrit yaklaşımı üretilmiştir.

Analiz sonuçları hibrit CEEMDAN-DBN ve bağımsız DBN modeliyle karşılaştırılmıştır. Sonuç olarak tüm zaman periyotlarında hibrit CEEMDAN-GA-DBN modelinin GWL tahmininde en iyi olduğu ortaya çıkmıştır. Çalışmanın sonuçları özellik seçimi ve veri ayrıştırma teknikleri derin öğrenme modellerinin performanslarını önemli ölçüde geliştirmesi açısından mevcut çalışmayı desteklemektedir. Bu gelişmiş modellerin potansiyeline rağmen, veri kullanılabilirliği ve yeraltı suyu sistemlerinin karmaşıklığı konusunda zorluklar nedeniyle yenilikçi yaklaşımlar ile güçlendirilmesi gerekmektedir. Bunun için gelecekteki çalışmalarda derin öğrenme modelleri meta sezgisel optimizasyon algoritmaları, farklı veri ayrıştırma ve özellik seçimi yaklaşımları ile hibritleşerek farklı kombinasyonların farklı iklim bölgelerinde denenerek doğrulanması önerilmektedir.

5.2. SONUÇ ve ÖNERİLER

Bu çalışmada Erzincan ilindeki yeraltı suyu kuraklıklarının tahmini için SSA veri ayrıştırma tekniği ve çeşitli ML tekniği birleştirilerek yenilikçi ve hibrit bir yaklaşım önerilmiştir. Tahmin modelinin kurulması için yağış, rölatif nem, sıcaklık ve gecikmeli SGI değerleri girdi olarak kullanılmıştır. Modelin kurulumunda, SSA ile girdilerin trend, mevsimsellik, döngüsel bileşenler ve gürültü gibi çeşitli alt bileşenlere ayrılmış ve bu bileşenler AI modellerine sunulmuştur. Model performansları çeşitli istatistiksel ve görsellere göre değerlendirilmiştir. Çalışmanın temel sonuçlar aşağıdaki gibi özetlenmiştir:

- SSA tekniği derin öğrenmesi modellerinin SGI tahmin performansının genel olarak artırmıştır.
- Yağış, rölatif nem, sıcaklık ve gecikmeli SGI değerleri girdi olarak kullanılması ile SGI değerlerinin etkili bir şekilde tahmin edilebileceği ortaya çıkarılmıştır.
- Tüm trend, mevsimsellik, döngü ve gürültü alt bileşenlerin AI modeline girdi olarak kullanılması ile kurulan hibrit yaklaşımlar aylık SGI tahmin doğruluğunu çoğunlukla artırırken, 12 aylık SGI tahminlerini ise artış ve azalışlar gözlenmiştir.
- Tüm trend, mevsimsellik ve döngü bileşenlerinin gridi olarak kullanıldığı SSA2 yaklaşımı, genellikle gürültü bileşenlerinin atılarak kurulduğu SSA1 den daha üstün sonuçlar göstermiştir. Buna göre gürültü alt bileşenlerinin ML modellerinden çıkarılarak ML modellerinin genelleme yeteneğinin artırabileceği ortaya çıkarılmıştır.
- Gürültü bileşenlerinin atılarak kurulan SGI tahminlerin doğruluğunun azda olsa azaldığı ortaya çıkarılmıştır.

- Yapay sinir ağıları ve bulanık mantık sistemlerini birleştiren ANFIS modelinin derin öğrenme ve Catboost modelinden daha üstün sonuçlar gösterdiği tespit edilmiştir.
- Sobol duyarlılık analizi sonucunda SGI 1 (t) değerlerinin tahmininde en yüksek etkiye sahip olan parametreler sırası ile rölatif nem, SGI-1 (t-1) iken SGI 12 (t) değerlerinin tahmininde en yüksek etkiye sahip olan parametre ise SGI-12 (t-1) olarak tespit edilmiştir.



KAYNAKÇA

- Alam, M. F., Pavelic, P., Villholth, K. G., Sikka, A., & Pande, S. (2022). Impact of high-density managed aquifer recharge implementation on groundwater storage, food production and resilience: A case from Gujarat, India. *Journal of Hydrology: Regional Studies*, 44, 101224.
- Ao, X., Eloranta, J., Huang, C., Santoro, D., Sun, W., Lu, Z., Li, C. (2021). Peracetic acidbased advanced oxidation processes for decontamination and disinfection of water: A review. *Water Resources*, 188, (116479).
- Barthel, R., & Banzhaf, S. (2016). Groundwater and surface water interaction at the regional-scale—a review with focus on regional integrated models. *Water resources management*, 30(1), 1-32.
- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937-1967.
- Bidwell, V. J. (2005) Realistic forecasting of groundwater level, based on the eigenstructure of aquifer dynamics. *Mathematics and Computers in Simulation*, 69, 12–20.
- Bloomfield, J. P., & Marchant, B. P. (2013). Analysis of groundwater drought building on the standardised precipitation index approach. *Hydrology and Earth System Sciences*, 17(12), 4769-4787.
- Bowes, B. D., Sadler, J. M., Morsy, M. M., Behl, M., & Goodall, J. L. (2019). Forecasting groundwater table in a flood prone coastal city with long short-term memory and recurrent neural networks. *Water*, 11(5), 1098.
- Bui, Q. T., Chou, T. Y., Hoang, T. V., Fang, Y. M., Mu, C. Y., Huang, P. H., ... & Meadows, M. E. (2021). Gradient boosting machine and object-based CNN for land cover classification. *Remote Sensing*, 13(14), 2709.
- Bui, Q. T., Chou, T. Y., Hoang, T. V., Fang, Y. M., Mu, C. Y., Huang, P. H., ... & Meadows, M. E. (2021). Gradient boosting machine and object-based CNN for land cover classification. *Remote Sensing*, 13(14), 2709.
- Cao, Y., Yin, K., Zhou, C., & Ahmed, B. (2020). Establishment of landslide groundwater level prediction model based on GA-SVM and influencing factor analysis. *Sensors*, 20(3), 845.

- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *ArXiv:1406.1078*.
- Cho, M., Kim, C., Jung, K., & Jung, H. (2022). Water level prediction model applying a long short-term memory (lstm)–gated recurrent unit (gru) method for flood prediction. *Water*, 14(14), 2221.
- Cui, X., Wang, Z., Xu, N., Wu, J., & Yao, Z. (2024). A secondary modal decomposition ensemble deep learning model for groundwater level prediction using multi-data. *Environmental Modelling & Software*, 175, 105969.
- Escalante, E. F., Stefan, C., Brown, C. J., & Hutchinson, A. (2023). Managed Aquifer Recharge: A Key to Sustainability. *Water*, 15(23), 4183.
- European Union (EUROPA). (2018). Groundwater, <http://ec.europa.eu/environment/water/waterframework/groundwater/resource.htm>, (Erişim Tarihi: 20.01.2021).
- Golyandina, N., Korobeynikov, A., & Zhigljavsky, A. (2018). *Singular spectrum analysis with R*. Springer Berlin Heidelberg.
- Goodarzi, M. Fatehifar, A. Avazpoor, F. (2019) Bivariate analysis of the impact of climate change on drought with SPEI index and Coppola functions (Case study: Dugonbadan). *Iran-Water Resources Research*, 15, 352–365.
- Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: an interdisciplinary review. *Journal of big data*, 7(1), 94.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685.
- Kang, D., & Byun, K. (2024). Development of a Multi-Scale Groundwater Drought Prediction Model Using Deep Learning and Hydrometeorological Data. *Water*, 16(14), 2036.
- Kartal, V., Katipoglu O. M., Karakoyun, E., Simsek, O., Yavuz, V. S., Ariman, S. (2024). Prediction of Groundwater Drought Based on Hydro-Meteorological Insights via Machine Learning Approaches. *Physics and Chemistry of the Earth, Parts A/B/C*, 136, 103757.
- Khadri, S. F. R., & Pande, C. (2016). Ground water flow modeling for calibrating steady state using MODFLOW software: a case study of Mahesh River basin, India. *Modeling Earth Systems and Environment*, 2(1), 17.

- Khan, J., Lee, E., Balobaid, A. S., & Kim, K. (2023). A comprehensive review of conventional, machine learning, and deep learning models for groundwater level (GWL) forecasting. *Applied Sciences*, 13(4), 2743.
- Kumar, R. Musuza, J. L. Van Loon, A. F. Teuling, A. J. Barthel, R. Ten Broek, J. Mai, J. Samaniego, L. Attinger, S. (2016). Multiscale Evaluation of the standardized precipitation index as a groundwater drought indicator. *Hydrology and Earth System Sciences*, 20, 1117–1131.
- Kumari, S., Kumar, D., Kumar, M., & Pande, C. B. (2023). Modeling of standardized groundwater index of Bihar using machine learning techniques. *Physics and Chemistry of the Earth, Parts A/B/C*, 130, 103395.
- Le, X. H., Ho, H. V., & Lee, G. (2020). *Application of gated recurrent unit (GRU) network for forecasting river water levels affected by tides*. In APAC 2019: Proceedings of the 10th International Conference on Asian and Pacific Coasts, 2019, Hanoi, Vietnam (pp. 673-680). Springer Singapore.
- Le, X. H., Nguyen, D. H., Jung, S., & Lee, G. (2023). Deep neural network-based discharge prediction for upstream hydrological stations: a comparative study. *Earth Science Informatics*, 16(4), 3113-3124.
- Li, B., & Rodell, M. (2020). Groundwater Drought: Environmental Controls and Monitoring. NASA Technical Reports Server. Published November 11. <https://ntrs.nasa.gov/citations/20205010325>.
- Liu, W., Yu, H., Yang, L., Yin, Z., Zhu, M., & Wen, X. (2021). Deep learning-based predictive framework for groundwater level forecast in arid irrigated areas. *Water*, 13(18), 2558.
- Malekzadeh, M., Kardar, S., & Shabanlou, S. (2019). Simulation of groundwater level using MODFLOW, extreme learning machine and Wavelet-Extreme Learning Machine models. *Groundwater for Sustainable Development*, 9, 100279.
- Marques, C. A. F., Ferreira, J. A., Rocha, A., Castanheira, J. M., Melo-Gonçalves, P., Vaz, N., & Dias, J. M. (2006). Singular spectrum analysis and forecasting of hydrological time series. *Physics and Chemistry of the Earth, Parts A/B/C*, 31(18), 1172-1179.
- Mendicino, G., Senatore, A., Versace, P. A. (2008). groundwater resource index (GRI) for drought monitoring and forecasting in a Mediterranean climate. *Journal of Hydrology*, 357, 282–302.
- Mishra, A. K., & Singh, V. P. (2010) A Review of Drought Concepts. *Journal of Hydrology*, 391, 202- 216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>

- Naghibi, S. A., Ahmadi, K., & Daneshi, A. (2017). Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping. *Water Resources Management*, 31, 2761-2775.
- NASA. (2021). Turkey Experiences Intense Drought. <https://earthobservatory.nasa.gov/images/147811/turkey-experiences-intensedrought>. (Erişim Tarihi: 20.01.2021).
- Olah, C. (2015), Understanding LSTM Networks.
- Osman, A. I. A. Ahmed, A. N. Chow, M. F. Huang, Y. F. El-Shafie, A. (2021) extreme gradient boosting (Xgboost) model to predict the groundwater levels in Selangor Malaysia. *Ain Shams Engineering Journal*, 12, 1545–1556.
- Pande, A., Mun, B. G., Khan, M. Rahim, W. Lee, D. S. Lee, G. M. Al Azawi, T. N. I. Hussain, A. Yun, B. W. (2022). Nitric Oxide Signaling and Its Association with Ubiquitin-Mediated Proteasomal Degradation in Plants. *International Journal of Molecular Sciences*, 23, 1657.
- Pande, C. B., Moharir, K. N. (2021). Groundwater resources development and planning in the semi-arid region, 1. Springer, Cham, p. 571. <https://doi.org/10.1007/978-3-030-68124-1>.
- Pourmorad, S., Kabolizade, M., & Dimuccio, L. A. (2024). Artificial Intelligence Advancements for Accurate Groundwater Level Modelling: An Updated Synthesis and Review. *Applied Sciences*, 14(16), 7358.
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in neural information processing systems*, 31.
- Rahim, A. Khan, K. Akif, A. Jamal, R. (2015). The geostatistical approach to assess the groundwater drought by using standardized water level index (SWI) and standardized precipitation index (SPI) in the Peshawar regime of Pakistan. *Scientific International*, 27, 4111–4117.
- Raju, D., Sumalatha, M., & Ramani, Lakshmi, K. V. (2011). Solving uncertain problems using ANFIS. *International Journal of Computer Applications*, 29 (11),14–21.
- Seo, J. Y., & Lee, S. I. (2019). Spatio-temporal groundwater drought monitoring using multi-satellite veri based on an artificial neural network. *Water*, 11 (9), 1953.
- Saltelli, A., Tarantola, S., & Chan, K. S. (1999). A quantitative model-independent method for global sensitivity analysis of model output. *Technometrics*, 41.1 39-56.

- Shahbazi, M., Zarei, H. & Solgi, A. (2023). De-noising groundwater level modeling using data decomposition techniques in combination with artificial intelligence (case study Aspas aquifer). *Appl Water Sci* 13, 88. <https://doi.org/10.1007/s13201-023-01885-7>.
- Smith, J. M. (1975). Mass transfer in packed ebbs with two-phase flow. *Industrial and Engineering Chemistry Process Design and Development*, 14(2), 473-485.
- Taye, M. M. (2023). Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions. *Computation*, 11(3), 52.
- UK Groundwater Forum (2018). The Use Groundwater. <http://www.groundwateruk.org/Image-Gallery.aspx> (Erişim Tarihi: 20.01.2021).
- Yang, X., & Zhang, Z. (2022). A CNN-LSTM model based on a meta-learning algorithm to predict groundwater level in the middle and lower reaches of the Heihe River, China. *Water*, 14(15), 2377.
- Yeganeh, A., Ahmadi, F., Jie Wong, Y., Shadman, A., Barati, R., & Saeedi, R. (2023). Implementation of Machine Learning Techniques for Groundwater Level Forecasting Under the Integrated Data. Available at SSRN: <https://ssrn.com/abstract=4539358> or <http://dx.doi.org/10.2139/ssrn.4539358>.
- Yun, S. M., Jeong, J. H., Jeon, H. T., Cheong, J. Y., & Hamm, S. Y. (2023). Determining Groundwater Drought Relative to the Opening of a River Barrage in Korea. *Water*, 15 (14), 2658.
- Zhang XY, Trame MN, Lesko LJ, Schmidt S. Sobol Sensitivity Analysis: (2015). A Tool to Guide the Development and Evaluation of Systems Pharmacology Models. *CPT Pharmacometrics Syst Pharmacol*. 4(2), 69-79. doi: 10.1002/psp4.6. PMID: 27548289; PMCID: PMC5006244.
- Zhou, T., Wang, F., & Yang, Z. (2017). Comparative analysis of ANN and SVM models combined with wavelet preprocess for groundwater depth prediction. *Water*, 9(10), 781.
- Zounemat Kermani, M., Mahdavi-Meymand, A., Fadaee, M., Batelaan, O., & Hinkelmann, R. (2022). Groundwater quality modeling: On the analogy between integrative PSO and MRFO mathematical and machine learning models. *Environmental Quality Management*, 31 (3), 241-25.