

Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini

Ramazan Şentürk^{1,3*}, Rifat Kurban^{2,3}, Fatma Çakıroğlu⁴

¹Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü, Hesaplamalı Bilimler ve Mühendislik Anabilim Dalı, Kayseri, Türkiye

²Abdullah Gül Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

³Envest Enerji ve Su Teknolojileri, Kayseri, Türkiye

⁴ Kayseri Üniversitesi, Elektrik Elektronik Mühendisliği, Lisansüstü Eğitim Enstitüsü, Kayseri, Türkiye

*(ramazan.senturk@envest.com.tr)

Özet – Yeraltı su seviyelerinin izlenmesi ve tahmini, su kaynakları yönetimi için kritik bir öneme sahiptir. İklim değişikliği, nüfus artışı ve aşırı su çıkarma gibi etkenler, yeraltı suyu rezervlerine baskı oluşturabilir. Bu nedenle, yeraltı su seviyelerinin izlenmesi, akiferlerin sağlığının değerlendirilmesine, sorunların tespit edilmesine ve su yönetimi için bilinçli kararlar alınmasına yardımcı olacaktır. Yeraltı su seviyelerinin izlenmesi yeraltı su rezervlerinin kapasitesi, hassas tarım, yağmur suyu yönetimi ve karstik ortamlar gibi özel durumlar için önemlidir. Yapay sinir ağları (YSA) yeraltı suyu seviyesi tahmininde büyük ilgi görmüştür. Bu modeller, geçmiş verileri ve ilgili parametreleri kullanarak gelecekteki su seviyelerini tahmin etmek için kullanılmıştır ve yüksek başarı sağlamaktadır. Bu çalışmada, doğrusal olmayan otoregresif sinir ağı (NAR-NN) yaklaşımı ile AquiferAuser veri setindeki LT2 kuyusu için yeraltı su seviyesinin tahmini gerçekleştirilmiştir.

Anahtar kelimeler – yeraltı su seviyesi tahmini, yapay sinir ağı, doğrusal olmayan otoregresif sinir ağı

I. GİRİŞ

Yeraltı su seviyelerinin izlenmesi, su kaynakları yönetimi ve çevresel izlemenin önemli bir yönüdür. Kuyulardaki, akiferlerdeki ve diğer yeraltı su kaynaklarındaki yeraltı suyu seviyelerinin ölçülmesini ve analizini içerir. Bu bilgiler, yeraltı suyu kaynaklarının mevcudiyetini, kalitesini ve sürdürülebilirliğini anlamak için gereklidir [1].

Yeraltı suyu, içme suyu temini, sulama ve endüstriyel kullanım dahil olmak üzere çeşitli amaçlar için hayati bir öneme sahiptir. Ancak iklim değişikliği, nüfus artışı ve bilinçsiz tarımsa sulama gibi faktörler yeraltı suyu rezervleri üzerinde baskı oluşturmaktadır. Yeraltı suyu seviyelerinin izlenmesi, akiferlerin genel sağlığının değerlendirilmesine, su tahsisi ve yönetimi ile ilgili bilinçli kararlar alınmasına yardımcı olur [1].

Yeraltı su seviyelerini izlemek için çeşitli teknikler ve teknolojiler kullanılmaktadır. Bunlar arasında basınç transdüserleri veya su seviyesi kaydediciler gibi aletlerle donatılmış izleme kuyularının kullanımı yer almaktadır [1]. Uydu görüntüleri ve hava araştırmaları gibi uzaktan algılama teknolojileri de yeraltı suyu depolaması ve geniş alanlarda su mevcudiyetindeki değişiklikler hakkında önemli veriler sağlayabilmektedir [2]. Ayrıca, Sonlu Hacim Nokta Seyreltme Yöntemi (FVPDM) gibi yenilikçi yöntemler, yeraltı suyu akışlarının sürekli izlenmesi için umut vaat etmektedir [3]. Yeraltı su seviyelerinin izlenmesi, hassas tarım [1], yağmur suyu ve sıhhi kanalizasyon yönetimi [4] ve karstik ortamlar [5] gibi belirli bağlamlarda önemlidir.

Yeraltı su seviyelerinin tahmini, su kaynakları yönetimi ve planlamasının önemli bir adımdır. Yeraltı suyu seviyelerinin doğru tahmin edilmesi, bu hayati kaynağın mevcudiyeti ve

sürdürülebilirliği hakkında değerli bilgiler sağlamaktadır. Yeraltı su seviyelerine yönelik tahmin modelleri geliştirmek için yapay zekâ (YZ) ve veri odaklı modeller de dahil olmak üzere çeşitli teknikler kullanılmıştır [6-8].

Yapay sinir ağları (YSA) ve uyarlanabilir nöro-bulanık çıkarım sistemleri (ANFIS) gibi yapay zekâ yaklaşımlarını kullanan yeraltı suyu seviyesi tahmini son yıllarda büyük ilgi görmektedir [6]. Bu modeller, gelecekteki su seviyelerini tahmin etmek için diğer ilgili parametrelerle birlikte geçmiş yeraltı suyu seviyesi verilerini kullanmaktadır. YSA'lar ve ANFIS kullanılarak yapılan çalışmaların sonuçları, yeraltı suyu seviyelerini tahmin etmede umut verici doğruluk göstermektedir [9].

Bu amaçla kullanılan yaklaşımlardan biri doğrusal olmayan otoregresif sinir ağıdır (NAR-NN). NAR-NN, yalnızca bir serinin söz konusu olduğu zaman serisi tahmini için çok uygun olan dinamik bir sinir ağı modelidir [10]. Bu model, güneş radyasyonu tahmini [11], enerji tüketimi tahmini [12], rüzgâr hızı tahmini [13] ve yeraltı suyu seviyesi tahmini [10] gibi çeşitli alanlarda başarıyla uygulamaktadır. NAR-NN modeli, geçmiş yeraltı suyu seviyesi verilerini kullanarak ve potansiyel olarak çevresel girdileri dahil ederek gelecekteki yeraltı suyu seviyelerine ilişkin doğru tahminler sağlamıştır. Bu tahminler, etkili su kaynakları yönetimi, konjonktürel kullanım planlaması ve yeraltı suyu kaynaklarının sürdürülebilir kullanımı için gereklidir [14, 15].

Bu çalışmada, AquiferAuser veri setindeki LT2 kuyusu için yeraltı suyu seviyesinin tahmini NAR-NN modeli kullanılarak gerçekleştirilmiştir. Çalışmalarda, gizli katmanda farklı nöron sayıları ve farklı eğitim algoritmaları kıyaslanmıştır.

II. MATERYAL VE YÖNTEM

Bu bölümde kullanılan veri seti, klasik yapay sinir ağı modeli ve doğrusal olmayan otoregresif sinir ağı modeli kısaca tanıtmıştır.

A. Veri Seti

Kaggle'dan elde edilen AquiferAuser veri setinden Depth_to_Groundwater_LT2 veri olarak üzerinde simülasyon çalışmaları gerçekleştirilmiştir [16].

Bu su kütlesi KUZEY ve GÜNEY adı verilen iki alt sistemden oluşur; birincisi, ikincisinin davranışını kısmen etkiler etkilemektedir. Gerçekte, kuzey alt sistemi bir su tablası (veya sınırlanmamış) akiferi iken, güney alt sistemi bir artezyen (veya sınırlanmış) yeraltı su seviyesini temsil etmektedir. GÜNEY sektörün seviyeleri LT2 kuyusu tarafından temsil edilmiştir.

Test ve eğitim için kullanılacak olan verilerin ayrıştırılmasında ön işlem olarak eksik veriler bulunmuş ve bu veriler en yakın komşular ile enterpolasyon işlemi yapılmıştır. Enterpolasyon sonucunda oluşan datadan boş olan veriler ayıklanarak deneyde kullanılacak olan veri seti oluşturulmuştur.

B. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), son yılların en önemli teknolojik gelişmelerinden biri olarak kabul edilen derin öğrenme alanının temelini oluşturan güçlü bir matematiksel modeldir. Bu yapay zekâ yöntemi, biyolojik sinir sistemlerinden ilham alarak tasarlanmıştır ve karmaşık bilgi işleme görevlerini gerçekleştirmek için kullanılmıştır. Temelde nöronları taklit eden yapay sinir hücreleri, katmanlar halinde düzenlenmiş ve bu katmanlar arasındaki bağlantılar ağırlıklarla temsil edilmiştir. Eğitim sırasında, bu ağırlıklar, veri setine uygun hale getirilmiş ve ağ, verileri analiz edip desenleri öğrenerek görevlerini yerine getirmiştir.

Yapay Sinir Ağlarının en büyük avantajlarından biri, çok çeşitli uygulama alanlarında kullanılabilirliğidir. Görüntü ve ses tanıma, doğal dil işleme, oyunlar, finansal analiz, tıbbi teşhis, otomasyon ve daha birçok alanda bu teknoloji etkili bir şekilde kullanılmaktadır. Ayrıca, derin öğrenme yöntemleri ile büyük veri setlerinin işlenmesi ve örüntülerin tespit edilmesi gibi karmaşık görevlerde insan performansını aşabilme potansiyeline sahiptirler.

Ancak, yapay sinir ağları, büyük hesaplama kaynaklarına ve veri setlerine ihtiyaç duyan karmaşık yapılar olduğu için eğitimleri ve kullanımları bazen zorlu olmaktadır. Ayrıca, ağların iç işleyişi karmaşıktır ve sonuçlarını yorumlamak genellikle zorlu olmaktadır. Bu nedenle, yapay sinir ağlarının doğru bir şekilde tasarlanması, eğitilmesi ve uygulanması için uzmanlık gerektirmektedir. Yapay sinir ağları, gelecekte birçok alanda daha fazla yenilik ve ilerleme sağlama potansiyeli taşıdığı için bu alandaki araştırmalar ve geliştirmeler hızla devam etmektedir.

Doğrusal olmayan oto-regresif sinir ağı (Nonlinear Autoregressive Neural Network), kısaca NAR-NN olarak isimlendirilmiş bir derin öğrenme modelidir. Bu model, özellikle zaman serileri analizi ve tahmini gibi uygulamalarda

kullanılabilen bir tür yapay sinir ağıdır. Temel amacı, önceki zaman adımlarındaki girdilere dayalı olarak gelecekteki değerleri tahmin etmektir.

NAR-NN, geleneksel Autoregressive (AR) modellerinden farklı olarak, karmaşık ve doğrusal olmayan ilişkileri öğrenmek için derin öğrenme tekniklerini kullanılmıştır. Geleneksel AR modelleri, geçmiş zaman adımlarındaki veriler arasındaki doğrusal ilişkileri yakalamaya odaklanırken, NAR-NN, daha karmaşık ve esnek ilişkileri ifade etmektedir. Bu, zaman serilerinin karmaşıklığına ve dinamizmine daha iyi uyum sağlayabilmektedir.

Doğrusal olmayan otoregresif sinir ağı, özellikle finansal tahminler, doğal dil işleme ve çeşitli mühendislik uygulamaları gibi alanlarda başarılı bir şekilde kullanılmaktadır. Bu model, veri analitiği, tahmin ve kontrol sistemleri gibi birçok alanda önemli bir araç haline gelmektedir.

Klasik ileri beslemeli yapay sinir ağı (Feedforward NN) ile doğrusal olmayan otoregresif sinir ağı (NAR-NN) arasındaki temel farklardan biri bağlantı yapısıdır. Klasik ileri beslemeli yapay sinir ağı, bilgi akışının yalnızca bir yönde olduğu bir yapıya sahiptir. Girdiler, gizli katmanlar ve çıkışlar arasında doğrusal olmayan aktivasyon fonksiyonlarıyla birleştirilmiştir, NAR-NN, zaman serileri analizi için tasarlanmıştır ve geçmiş zaman adımlarındaki verilere dayalı olarak gelecekteki değerleri tahmin etmek amacıyla özel olarak tasarlanmıştır. Bu nedenle, NAR-NN'nin bir otoregresif (kendini geri besleyen) yapısı vardır, yani her çıkış, önceki çıkışları veya girdileri geri beslemesi mümkün olmaktadır.

Bir diğer önemli fark, bu modellerin kullanım alanlarındadır. Klasik ileri beslemeli yapay sinir ağı, genellikle statik verilerin işlenmesi ve sınıflandırma veya regresyon gibi görevler için kullanılmaktayken, NAR-NN özellikle zaman serilerinin analizi ve tahmini için tasarlanmaktadır. Geçmiş zaman adımlarındaki verilere dayalı olarak gelecekteki değerleri tahmin etme yeteneği ile öne çıkmaktadır.

Aktivasyon fonksiyonları açısından, klasik ileri beslemeli yapay sinir ağı doğrusal olmayan aktivasyon fonksiyonları (ReLU, Sigmoid, vb.) kullanılmaktadır, ancak bu fonksiyonlar önceden belirlenmekte ve sabit kalmaktadır. Doğrusal olmayan otoregresif sinir ağı ise genellikle geleneksel RNN (Recurrent Neural Network) hücrelerini kullanmakta ve bu hücreler daha esnek ve zaman serilerine uygun aktivasyon fonksiyonlarını öğrenme yeteneği sağlamaktadır.

$$y = f(b + \sum_i w_i x_i) \quad (1)$$

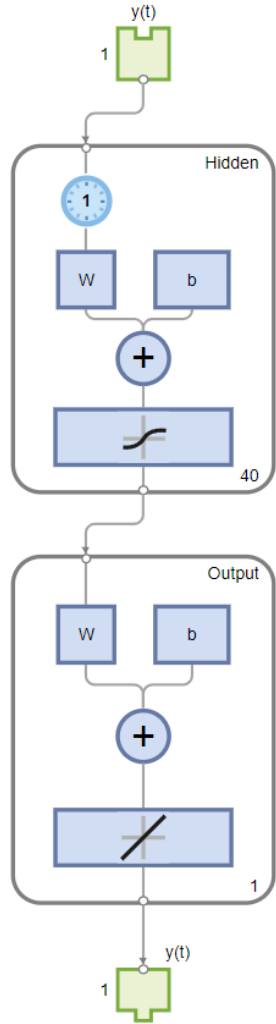
burada b nöron için bias değerini, f aktivasyon fonksiyonunu, w ağırlık katsayılarını, x giriş verisini ve y ise nöron çıkışını ifade etmektedir [16].

$$\hat{y}(t) = f(y(t-1) + y(t-2) + \dots + y(t-d)) \quad (2)$$

burada f doğrusal olmayan fonksiyon, d çıkış sinyalinin önceki değerlerini ifade etmektedir. \hat{y} ise tahmin edilen çıkışı ifade etmektedir [17].

C. Önerilen Model

Deneylerde kullanılan NAR-NN modeli Şekil 1'de verilmiştir. Modelde $y(t)$ girişine 1 adım gecikme uygulanmıştır. Gizli katmanda sırasıyla 2, 10 ve 40 nöron bulunan modeller ile farklı yapılar oluşturularak sonraki bölümde kıyaslamalar yapılmıştır. Gizli katmanda tanjant-sigmoid ve çıkış katmanında ise doğrusal transfer fonksiyonu kullanılmıştır.



Şekil 1 Deneylerde kullanılan NAR-NN modeli.

III. DENEYSEL BULGULAR

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

Deneylerde Levenberg-Marquardt geri yayılım (backpropagation) (trainlm) ve Bayesian Regularization geri yayılım (trainbr) yapay sinir ağları eğitim algoritmaları kullanılmıştır. Ayrıca her bir eğitim fonksiyonu (trainlm ve trainbr) için farklı katman boyutları (2, 10 ve 40) kullanılarak deneyler gerçekleştirilmiştir.

Levenberg-Marquardt, yapay sinir ağları ve özellikle ağırlık güncellemesi için kullanılan bir optimizasyon algoritmasıdır. Bu algoritma, ağırlık eğitim verilerine uyum sağlamasını hedefleyerek ağırlıkları güncellemektedir. Levenberg-Marquardt, özellikle regresyon problemleri gibi ağırlık öğrenmesi gereken karmaşık işlevleri içeren problemlerde etkili olmuştur. Bu yöntem, geleneksel geri yayılım algoritmasının yanı sıra Hesaplanan Gradyan ve Gauss-Newton algoritmalarının bir kombinasyonunu kullanmaktadır. Ağırlık güncellemelerini, hatanın küçülmesini hedeflerken aynı zamanda aşırı uyarlamayı (overfitting) önlemek için düzenleme (regularization) sağlamaktadır. Levenberg-Marquardt, karmaşık ve yüksek boyutlu veri setleriyle başarılı bir şekilde çalışabilen bir optimizasyon algoritmasıdır ve özellikle doğrusal olmayan işlevlerin yakınlştırılmasında kullanılmaktadır.

Bayesian Regularization, yapay sinir ağı eğitiminde kullanılan bir optimizasyon yöntemi ve düzenleme tekniğidir. Bu yöntem, ağırlık öğrenme sürecinde ağırlıkları güncellemek için Bayes teorisine dayalı bir yaklaşım kullanmaktadır. Bayesian Regularization, ağırlıkların belirsizliklerini modellemek ve bu belirsizlikleri ağırlık eğitimi sırasında düzenlemek için bir Bayes çerçevesi içinde çalışmaktadır. Bu sayede, ağırlık aşırı uyarlamayı (overfitting) önlemesine ve daha genelleyici sonuçlar üretmesine yardımcı olmaktadır. Bu yöntem, veri seti karmaşıklığının ve boyutunun arttığı durumlarda özellikle etkili olabilir ve ağırlık güvenilir tahminler yapmasını sağlamak için belirsizlikleri dikkate almaktadır. Bayesian Regularization, ağırlık güncellemeleri sırasında hem veriye dayalı bilgiyi hem de ağırlıkların dağılımı hakkındaki bilgiyi dengeli bir şekilde kullanarak ağırlık performansını iyileştirmektedir.

Root Mean Square Error (RMSE), bir tahmin modelinin veya algoritmanın gerçek değerlerle ne kadar uygunluk gösterdiğini ölçmek için kullanılan istatistiksel bir metriktir. RMSE, özellikle regresyon analizi gibi problemlerde yaygın olarak kullanılır kullanılmaktadır. Bu metrik, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerini alır alıp, bu farkların ortalamasını alır alıp ve son olarak bu değer karekökünü alarak hesaplanır hesaplanmaktadır. RMSE, daha düşük değerlere sahip olduğunda modelin daha iyi tahminler yaptığını, yani gerçek değerlerle daha yakın uyum sağladığını gösterir göstermektedir. Dolayısıyla, bir tahmin modelinin doğruluğunu ve başarısını değerlendirmek için kullanılan önemli bir ölçüttür.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

Deneyde 5294 adet veri bulunan veri seti kullanılmıştır. Bu verinin %70'i yapay sinir ağlarının eğitimde ve kalan %30'u ise test verisi olarak kullanılmıştır.

Deneyler 30 kez tekrarlanmış ve bu tekrarlarının ortalaması ile standart sapmaları hesaplanmıştır.

Tablo 1. 30 tekrara ait RMSE değerlerinin ortalama değerleri

	Katman 2	Katman 10	Katman 40
Levenberg-Marquardt	0,0717	0,0345	0,0348
Bayesian Regularization	0,0350	0,0344	0,0346


Tablo 1'deki sonuçlar incelendiğinde katman sayısı 10 olduğunda daha iyi sonuçlar elde edildiği, en iyi sonucun Bayesian Regularization eğitim algoritması ile katman boyutu 10 seçildiğinde elde edildiği ve Bayesian Regularization eğitim algoritmasının tüm katman boyutları dikkate alındığında Levenberg-Marquardt eğitim algoritmasından daha iyi olduğu gözlemlenmiştir.

Tablo 2. 30 tekrara ait RMSE değerlerinin standart sapmaları.


	Katman 2	Katman 10	Katman 40
Levenberg-Marquardt	2,01E-01	1,27E-05	1,03E-05
Bayesian Regularization	2,20E-03	1,79E-05	3,66E-05

Tablo 2'deki sonuçlar incelendiğinde en düşük standart sapmanın Levenberg-Marquardt eğitim algoritması ve katman boyutu 40 olduğunda gözlemlenmiştir.


Şekil 2-4 de Levenberg-Marquardt eğitim algoritmaları ve Şekil 5-7 da Bayesian Regularization eğitim algoritmaları için farklı katman boyutlarıyla elde edilen test ve yapay sinir ağı sonuçlarının değerlerini gösteren grafikler bulunmaktadır. Grafikler, her eğitim fonksiyonunun katman boyutlarına göre performansını daha açık bir şekilde göstermektedir.




Şekil 2 Levenberg-Marquardt Backpropagation Katman 2




Şekil 3 Levenberg-Marquardt Backpropagation Katman 10




Şekil 4 Levenberg-Marquardt Backpropagation Katman 40



Şekil 5 Bayesian Regularization Backpropagation Katman 2



Şekil 6 Bayesian Regularization Backpropagation Katman 10



Şekil 7 Bayesian Regularization Backpropagation Katman 40

IV. SONUÇ VE TARTIŞMA

Bu çalışmada doğrusal olmayan otoregresif sinir ağı (NAR-NN) ile AquiferAuser veri setindeki LT2 kuyusu için yeraltı suyu seviyesinin tahmini gerçekleştirilmiştir. Deneylerde NAR gizli katmanında bulunan nöron sayısı, sırasıyla, 2, 10 ve 40 olarak belirlenmiştir. Ayrıca, eğitim algoritması olarak Levenberg-Marquardt eğitim algoritması ve Bayesian Regularization eğitim algoritması kullanılmıştır. Tüm deneyler sinir ağlarının rastgele yapısından dolayı 30'ar kez tekrar edilmiştir. Simülasyon sonuçlarına göre ortalama RMSE değeri için en iyi sonuç 0,0344 olarak gizli katmanda 10 nöron ve Bayesian Regularization eğitim algoritması ile

elde edilmiştir. İleriki çalışmalarda, literatürdeki farklı veri setleri de dahil edilerek NAR-NN yanı sıra uzun-kısa süreli bellek (LSTM) modeli ile kıyaslama yapılması planlanmıştır.

TEŞEKKÜR

Bu çalışmayı 2210-D Sanayiye Yönelik Yurtiçi Yüksek Lisans Burs Programı kapsamında destekleyen TÜBİTAK'a ve Envest Enerji ve Su Teknolojileri Ltd. Şti.'ne teşekkür ederiz.

REFERANSLAR

- [1] Vuran, M., Salam, A., Wong, R., & Irmak, S. (2018). Internet of underground things in precision agriculture: architecture and technology aspects. *Ad Hoc Networks*, 81, 160-173. <https://doi.org/10.1016/j.adhoc.2018.07.017>
- [2] Masood, A., Tariq, M. A. U. R., Hashmi, M. Z. u. R., Waseem, M., Sarwar, M. K., Ali, W., ... & Ng, A. W. M. (2022). An overview of groundwater monitoring through point-to satellite-based techniques. *Water*, 14(4), 565. <https://doi.org/10.3390/w14040565>
- [3] Jamin, P. and Brouyère, S. (2018). Monitoring transient groundwater fluxes using the finite volume point dilution method. *Journal of Contaminant Hydrology*, 218, 10-18. <https://doi.org/10.1016/j.jconhyd.2018.07.005>
- [4] Raza, U. and Salam, A. (2020). Wireless underground communications in sewer and stormwater overflow monitoring: radio waves through soil and asphalt medium. *Information*, 11(2), 98. <https://doi.org/10.3390/info11020098>
- [5] Wu, J., Chen, S., Zheng, K., Tian, L., Tai, S., Huang, Y., ... & Ye, J. (2023). Monitoring methodology study of a reservoir built on the karst depression: a large scale laboratory simulation test. *ACS Omega*, 8(16), 14520-14530. <https://doi.org/10.1021/acsomega.3c00072>
- [6] Rajae, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572, 336-351. <https://doi.org/10.1016/j.jhydrol.2018.12.037>
- [7] Sureshkumar, V., Rajasomashekar, S., & Sarala, B. (2022). An efficient underground water prediction using optimal deep neural network. *Concurrency and Computation: Practice and Experience*, 35(1). <https://doi.org/10.1002/cpe.7421>
- [8] Najafabadipour, A., Kamali, G., & Nezamabadi-pour, H. (2022). Application of artificial intelligence techniques for the determination of groundwater level using spatio-temporal parameters. *ACS Omega*, 7(12), 10751-10764. <https://doi.org/10.1021/acsomega.2c00536>
- [9] Samani, S., Vadiati, M., Azizi, F., Zamani, E., & Kişi, Ö. (2022). Groundwater level simulation using soft computing methods with emphasis on major meteorological components. *Water Resources Management*, 36(10), 3627-3647. <https://doi.org/10.1007/s11269-022-03217-x>
- [10] Wünsch, A., Liesch, T., & Broda, S. (2018). Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (narx). *Journal of Hydrology*, 567, 743-758. <https://doi.org/10.1016/j.jhydrol.2018.01.045>
- [11] Boussaada, Z., Curea, O., Remaci, A., Camblong, H., & Bellaaj, N. M. (2018). A nonlinear autoregressive exogenous (narx) neural network model for the prediction of the daily direct solar radiation. *Energies*, 11(3), 620. <https://doi.org/10.3390/en11030620>
- [12] Ruiz, L. G. B., Cuéllar, M. P., Calvo-Flores, M. D., & Pegalajar, M. (2016). An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. *Energies*, 9(9), 684. <https://doi.org/10.3390/en9090684>
- [13] Blanchard, T. and Samanta, B. (2019). Wind speed forecasting using neural networks. *Wind Engineering*, 44(1), 33-48. <https://doi.org/10.1177/0309524x19849846>
- [14] Mohanty, S., Jha, M. K., Kumar, A., & Sudheer, K. P. (2009). Artificial neural network modeling for groundwater level forecasting in a river island of eastern india. *Water Resources Management*, 24(9), 1845-1865. <https://doi.org/10.1007/s11269-009-9527-x>
- [15] Kurban, R. (2023). Su Temin ve Dağıtım Sistemlerinin Otomasyonunda Endüstri 4.0, Nesnelerin İnterneti, Bulut Bilişim, Makine Öğrenimi ve Optimizasyon Uygulamaları, Mühendislikte Araştırma ve Değerlendirmeler - II, 49-70, Gece Kitaplığı.
- [16] Acea Smart Water Analytics (2023, October), <https://www.kaggle.com/competitions/acea-water-prediction/data>
- [17] Benmouiza, K., & Cheknane, A. (2013). Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models. *Energy Conversion and Management*, 75, 561-569.