

Seyhan Havzası'nda Yer Alan Üç İstasyon İçin Yapay Sinir Ağı Kullanarak Akış Modeli Geliştirilmesi Üzerine Bir Çalışma

Mehmet MERKEPÇİ^{1,a}

¹Gaziantep Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Gaziantep

^aORCID: 0000-0003-1536-1776

Makale Bilgileri

Geliş : 27.01.2025

Kabul : 25.06.2025

DOI: 10.21605/cukurovaumfd.1627430

Sorumlu Yazar

Mehmet MERKEPÇİ

mmerkepci@gantep.edu.tr

Anahtar Kelimeler

Yapay zekâ (YZ)

Tahmin

Yapay sinir ağları (YSA)

Akış hızı

Atıf şekli: MERKEPÇİ, M., (2025). Seyhan Havzası'nda Yer Alan Üç İstasyon İçin Yapay Sinir Ağı Kullanarak Akış Modeli Geliştirilmesi Üzerine Bir Çalışma. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 40(2), 453-461.

ÖZ

İnsan yaşamının devamlılığı açısından su hayati önem taşımaktadır. Dolayısıyla, var olan su kaynaklarının korunması ve bu kaynakların bilinçli bir şekilde kullanımı konusunda iyi bir strateji geliştirmektir. Bu stratejinin ilk basamağı ise geçmişten gelen verileri kullanarak gelecekte ne kadar su kaynağı potansiyeline sahip olacağımızın tahmin edilmesidir. Bu bağlamda, sahip olduğumuz nehir ve akarsu akış miktarlarının tahmini, su kaynakları yönetimi, sel kontrolü ve çevre dengesi açısından büyük önem taşımaktadır. Bu çalışmada, Türkiye'de Seyhan Havzası'nda yer alan Zamanti Nehri-Değirmenocağı, Zamanti Nehri-Ergenusağı ve Eğlence Nehri-Eğribük istasyonlarının uzun dönem günlük akış değerleri incelenmiştir. Geçmiş akış ölçüm değerlerinden ileri akış hızının tahmin edilmesi amacıyla Yapay Sinir Ağı modeli algoritmaları kullanılarak 3 farklı karakterdeki istasyon için eğitilmiş ve önemli sonuçlar elde edilmiştir. Bu sonuçlara göre; 1825-Eğlence istasyonunda anlık tepe noktaları görüldüğünden dolayı YSA modeli bu tepe noktalarını tahmin etmekte zorlanmıştır. 1826-Ergenusağı ve 1827-Değirmenocağı istasyonlarında akım debilerine ait artışlar sürekli bir zaman diliminde olduğundan YSA modelini bu tepe noktalarını daha rahat modelleyebilmiştir. Sonuç olarak çeşitli çevresel faktörler ve önceki akış verileri temel alınarak akış dinamiklerini modelleyen bu sistem, su yönetimi uygulamaları için stratejik veriler sağlamaktadır.

A Study on Developing A Flow Model Using Artificial Neural Networks For Three Stations in the Seyhan Basin

Article Info

Received : 27.01.2025

Accepted : 25.06.2025

DOI: 10.21605/cukurovaumfd.1627430

Corresponding Author

Mehmet MERKEPÇİ

mmerkepci@gantep.edu.tr

Keywords

Artificial intelligence

Prediction

Artificial neural network (ANN)

Stream flow

How to cite: MERKEPÇİ, M., (2025). A Study on Developing A Flow Model Using Artificial Neural Networks For Three Stations in the Seyhan Basin. Çukurova University, Journal of the Faculty of Engineering, 40(2), 453-461.

ABSTRACT

Water is vital for the continuity of human life. It is essential to conserve existing water resources and to develop a well-thought-out strategy for their conscientious use. The first step in this strategy is to use historical data to estimate the future potential of water sources. In this context, predicting the flow rates of rivers and streams is crucial for the management of water resources, flood control and the maintenance of ecological balance. In this study, the long-term daily flow values of the Zamanti River-Değirmenocağı, Zamanti River-Ergenusağı and Eğribük River-Eğribük stations in the Seyhan Basin in Türkiye were investigated. In order to estimate the future flow rate from past measurements, the artificial neural network model was trained for 3 different stations and significant results were determined. According to these results; Since instant peaks were seen at 1825-Eğlence station, ANN model had difficulty in estimating these peaks. Since the increases in flow rates at 1826-Ergenusağı and 1827-Değirmenocağı stations were continuous in time, ANN model was able to model these peaks more easily. As a results, this system models the flow dynamics based on various environmental factors and past flow data and provides strategic information for water management applications.

1. GİRİŞ

Yaşamamızın vazgeçilmez ve en hayati parçası olan su, yeryüzünde insanların yaşayabilmesi için en önemli ve yenilenebilir bir enerji kaynağıdır. Dünya'daki suyun yaklaşık %3,5'i göllerde, nehirlerde ve buzullarda bulunmakta iken geri kalan kısmı ise okyanuslarda bulunmaktadır. Ancak içilebilir su dediğimiz tatlı su oranı ise mevcut su miktarının sadece % 2,5'i civarındadır [1]. Dünya üzerinde bulunan bu tatlı su kaynakları ise küresel ısınmaya bağlı iklim değişikliği ve diğer doğa olayları nedeniyle tükenme ve kirlenme nedeniyle her geçen gün azalmaktadır.

Su kaynaklarının mevcut ve gelecekteki potansiyeli açısından en önemli tatlı su kaynaklarından olan akarsu ve nehirlerde akışın bilinmesi ve tahmin edilmesi oldukça önemlidir. Akarsu ve nehirlerde yağış, kar erimesi, yeraltı su kaynakları ve buharlaşma gibi birçok faktöre bağlı olarak akış durumları farklılık gösterir [2]. Dolayısı ile nehir akışını tahmin ederken, nehir sistemlerinin yapısı ve işleyişi ile ilgili çeşitli problemler hakkında temel bilgilerin sağlanması, mevcut su kaynaklarının korunması ve kullanımına yönelik rasyonel planlama yapılması gerekir [3]. Su kaynaklarının sürdürülebilir kullanımını, etkin planlanmasını ve yönetimini kolaylaştırmak için hidrolojik süreçlerde modelleme yöntemleriyle nehir akışının tahmin edilmesi özellikle son yıllarda büyük önem kazanmıştır. Genişletilmiş akış kayıtları ve iklim verileri temel alınarak yapılan akış tahmin modelleri ile akarsu akışı verileri elde edilebilir hale gelmiştir [4].

Nehirlerin mevcut akış durumları ölçüm istasyonlarından elde edilen verilerle ortaya konulurken akış değerlerinin tahmininde bulanık mantık, yapay sinir ağı (ANN-YSA) ve ANFIS vb. yapay zeka teknikleri, hem kolay modellenmesi hem de sonuçların tutarlılığı bakımından sıklıkla ve başarıyla kullanılmaya başlanmıştır. Söz konusu tahminleme çalışmaları, bir nehrin akış miktarını etkileyen faktörleri analiz ederek nehir akışının tahmini, sulama, hidroelektrik enerji üretimi, su temini ve suyun gelecek nesillere aktarılması gibi oldukça önemli konularda çeşitli faaliyetlerin planlanmasına ve yönetilmesine yardımcı olmaktadır [5,6].

Özkan ve Haznedar [7] çalışmalarında Seyhan Havzasında akarsu akış tahmini için ANFIS modeli ile karşılaştırmalı analiz yaparken Bisht ve arkadaşları [8] çalışmalarında nehirlerdeki akış tahmini için ANFIS ve Doğrusal Çoklu Regresyon (MLR) yöntemlerini geliştirmişlerdir.

Göçmen ve arkadaşları [9] çalışmalarında çoklu çıktılı yapay sinir ağı (YSA) modelini kullanarak Amik Ovası'nda aylık buharlaşma tahminini modellemişlerdir.

Tekin [10] tarafından yapılan çalışmada Çukurova Bölgesi'nden elde edilen rüzgar gücü verileri MPE-MAPE modelleri kullanılarak tahminleme çalışması yapılmıştır.

Bizimana ve arkadaşları [11] tarafından yapılan çalışmada Yuvacık Barajı su seviyesi kontrolü için YSA ve Bulanık Mantık teknikleri ile modeller oluşturulmuş ve çalışma sonunda bulanık mantık yönteminin farklı hidrolojik belirsizlikleri ele alması ve girdiler ile çıktılar arasındaki ilişkiyi daha iyi ortaya koyması nedeniyle seviye kontrolünde daha esnek ve güvenilir olduğu belirtilmiştir.

Gunathilake ve arkadaşları [12] çalışmalarında, Seethawaka Nehri Havzasının hidrolojik modellemesini, akışı simüle eden ve akışı veri odaklı tekniklerle karşılaştıran ANN (YSA) tekniği ile gerçekleştirmişlerdir. Geliştirilen YSA'ların eğitim sürecinde Levenberg-Marquardt (LM), Bayes düzenlileştirilmesi (BR) ve ölçekli eşlenik gradyan (SCG) gibi algoritmalar kullanılmıştır.

Riad ve arkadaşları [13] tarafından yapılan çalışmada Fas'ın yarı kurak iklimindeki bir havzada bulunan Aghbalou istasyonunda yağış akış ilişkisini modellemek için çok katmanlı algılayıcı (MLP) sinir ağı kullanılmış ve yağış ile akışın çok düzensiz olduğu bu tür kurak bölgelerde sinir ağı yönteminin klasik regresyon modelinden daha iyi sonuç verdiği ifade edilmiştir.

Mahabir ve arkadaşları [14] Kanada'daki Lodge Creek ve Middle Creek havaalanlarında mevsimsel akış tahmini ve su temini için ANNF ve bulanık mantık modelleme tekniklerini kullanmışlardır.


Nehir akışının doğru tahmin edilmesi, özellikle su kaynaklarının sınırlı olduğu ve su kıtlığının önemli bir sorun olduğu ülkemizde de etkili su yönetimi için gereklidir. Seyhan Nehri havzası da su kaynaklarının sınırlı olduğu, tarımsal faaliyetler ve kentleşme nedeniyle suya olan talebin yüksek olduğu bölgelerden

biridir. Seyhan Nehri, havzanın ana su kaynağıdır ve akışının doğru tahmin edilmesi, etkin su yönetimi açısından büyük önem taşımaktadır.

Bu çalışmada, Seyhan Nehri Havzasında akış hızının tahminlenmesinde yapay zekâ tekniklerinden biri olan Yapay Sinir Ağları (YSA) yönteminin uygulanabilirliğinin araştırılması ve nehir sistemindeki akış hızı tahmini için doğru ve güvenilir bir model geliştirilmesi amaçlanmıştır. Bu amaçla Yapay Sinir Ağı modeli algoritmaları kullanılarak 3 farklı karakterdeki istasyon için eğitilmiş ve önemli bulgular elde edilmiştir. Buna göre; 1825-Eğlence istasyonunda anlık tepe noktaları görüldüğünden dolayı YSA modeli bu tepe noktalarını tahmin etmekte zorlanmıştır. 1826-Ergenuşağı ve 1827-Değirmenocağı istasyonlarında akım debilerine ait artışlar sürekli bir zaman diliminde olduğundan YSA modelini bu tepe noktalarını daha rahat modelleyebilmiştir. Çeşitli çevresel faktörler ve önceki akış verileri temel alınarak akış dinamiklerini modelleyen bu sistem, su yönetimi uygulamaları için stratejik veriler sağlamaktadır.


2. YÖNTEM

Seyhan Havzası Nehir akış hızı tahmini için yapay sinir ağı modellemesi yapılmıştır. Yapay Sinir Ağları (Artificial Neural Network (ANN)) insan beynindeki sinir ağı sisteminden esinlenilerek geliştirilmiş bir matematiksel modellemedir [15]. Bu sistem insan bedenindeki biyolojik sinir ağı yapısını taklit ederek çalışır [16]. Biyolojik sinir ağı (Şekil 1) dendrit, çekirdek, akson ve sinaps olmak üzere 4 ana bölümden oluşur. Ağaç kökü görünümünde olan dendritler, sinir hücresinin ucunda bulunur ve nöronlardan veya duyu organlarından gelen sinyalleri çekirdeğe iletir. Çekirdek, dendritten gelen sinyalleri bir araya toplar ve aksona iletir. Akson toplanan bu sinyalleri işleyerek nöronun diğer ucunda bulunan sinapslara gönderir. Sinapslar ise yeni üretilen sinyalleri diğer nöronlara iletir [17].



Şekil 1. Biyolojik sinir ağı modeli [17]

Biyolojik sinir ağlarında olduğu gibi yapay sinir ağlarında da birbirine bağlı nöronlar bulunmaktadır. Yani YSA'nın temel bileşeni aslında yapay nöronlardır. Bir Yapay Sinir Ağı (YSA) yapısı 5 ana bölümden oluşmaktadır. Bunlar girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır. Yapay bir sinir ağı modeli (Şekil 2'de) verilmiştir.



Şekil 2. Yapay sinir ağı modeli [18]


Çizelge 1'de biyolojik sinir sitemi ile yapay sinir ağı sistemi arasındaki ilişki aşağıdaki verilmiştir.

Çizelge 1. Biyolojik sinir sitemi ile yapay sinir ağı sistemi arasındaki ilişki [11]

Biyolojik sinir ağı sistemi	Yapay sinir ağı sistemi
Nöron	İşlemci eleman
Dentrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Yapan nöron çıkışı
Sinapslar	Ağırlıklar

Çalışmada, YSA yöntemlerinin günlük nehir akışı tahmininde kullanılabilmesi için Türkiye'de bulunan Seyhan Havzası'nda yer alan Zamanti Nehri-Değirmenocağı (1827), Zamanti Nehri-Ergenuşağı (1826) ve Eğlence Çayı-Eğribük (1825) istasyonlarının günlük akış değerleri kullanılmıştır. Kullanılan veriler DSİ (Devlet Su İşleri) verilerinden elde edilmiştir. Seyhan Havzası'nın üst kısmı İç Anadolu'da, orta ve alt kısmı Akdeniz Bölgesi'nde, Adana ilinin kuzeyinde, 36° 30' ve 39° 15' kuzey enlemleri ile 34° 45' ve 37° 00' doğu boylamları arasında yer almaktadır. 560 km uzunluğa ve 22.035 km² yüzey alanına sahiptir [19].

Veri setindeki tüm değerler günlük nehir akış değerlerini içermektedir. Karşılaştırılan modellerin tahmin potansiyelini kontrol etmek için Seyhan havzasının çeşitli hidrolojik koşullarını taşıyan 3 adet akış ölçüm istasyonu (AÖİ) kullanılmıştır. Seyhan Havzası'ndaki ilgili istasyonların Türkiye haritasındaki konumları (Şekil 3'de) verilmiştir. Bu istasyonlardan günlük uzun dönem ve 24 yıllık dere akış verileri de elde edilebilmektedir.



Şekil 3. Seyhan nehri havzasındaki çalışma alanları [6]

Modellerin eğitim aşamasında veri setinin yüzde 80'i olan 7143 günlük akış verisi, test aşamasında ise kalan yüzde 20'lik kısım olan 1785 günlük akış verisi kullanılmıştır. Çizelge 2'de tüm istasyonların koordinatları ve kullanılan verilerin zaman aralığı gösterilmektedir.

Çizelge 2. Seyhan nehrindeki akış ölçüm istasyonlarının yerleşimi [6]

	Koordinatlar		Yükseklik (metre)	Gözlem aralığı
	Doğu (° ' ")	Kuzey (° ' ")		
Eğribük	35 11 35	37 21 50	222	1988-2011
Ergenuşağı	35 34 47	37 39 55	360	1988-2011
Değirmenocağı	35 29 10	37 51 18	740	1988-2011

Akarsu akış değerlerini tahmin etmek için performans metrikleri [20] kullanılmıştır. Kullanılan performans metrikleri; RMSE (kök ortalama karesel hata), MAE (ortalama mutlak hata), R² (determinasyon katsayısı) ve MAPE (ortalama mutlak yüzde hata) [21] olup izleyen eşitliklerde verilmiştir. Söz konusu eşitliklerde hata değerlerinin 0'a ve R²'nin 1'e yaklaşması tahminin doğruluğunun arttığını gösterir [22].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{o,i} - Q_{p,i})^2} \quad (1)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{o,i} - Q_{p,i}| \quad (2)$$

$$R^2 = \frac{\sum_{i=1}^n (Q_{o,i} - Q_{o,avg})^2 - \sum_{i=1}^n (Q_{o,i} - Q_{p,i})^2}{\sum_{i=1}^n (Q_{o,i} - Q_{o,avg})^2} \quad (3)$$

$$MAPE = \frac{\sum_{i=1}^n \frac{|Q_{o,i} - Q_{p,i}|}{Q_{o,i}}}{n} \quad (4)$$

Eşitliklerde $Q_{o,i}$: Günlük akarsu akışının gözlemlenen değerlerini, $Q_{p,i}$: günlük akarsu akışının tahmin edilen değerlerini, $Q_{o,i} - Q_{p,i}$: hata (artık) terimlerinin değerini, $Q_{o,avg}$: Q değerlerinin ortalamasını ve n : veri sayısını belirtir. Ayrıca, r tahmin edilen ve gözlemlenen akışlar arasındaki korelasyon katsayısını, c tahmin edilen akarsu akışlarının standart sapmasının gözlemlenen akarsu akışlarının standart sapmasına oranını ve b , tahmin edilen ortalama akarsu akışlarının gözlemlenen ortalama akarsu akışlarına oranını ifade eder.

Şekil 4'te görüldüğü gibi nehrin akış analizi sırasında her üç istasyonun günlük akış potansiyelleri incelenmiş ve istasyonların en düşük ve en yüksek akışları m^3/s cinsinden verilmiştir. Üç istasyon birlikte incelendiğinde ve dere akışı kontrol edildiğinde en düşük dere akışı $0,95 m^3/s$ ile Ağustos 2008'de Eğribük istasyonunda görülmüştür. En yüksek debi $434 m^3/s$ ile Aralık 2002'de Ergenuşağı istasyonunda gözlenmiştir.



Şekil 4. a) Eğribük (1825) b) Ergenuşağı (1826) c) Değirmenocağı (1827) istasyonları günlük debisi

Nehir akış tahminlemesi için Yapay Sinir Ağı (YSA) modelinin oluşturulmuş ve yapılandırılmıştır [23]. Model yapısı; giriş değişkenlerinin seçilmesi, katman sayılarının belirlenmesi, katmanlarda kullanılan


transfer fonksiyonlarının belirlenmesi, YSA modelinin eğitiminde kullanılan öğrenme algoritmasının ve algoritmanın koşacağı iterasyon sayısının seçilmesi gibi adımları içermiştir.

Bu kapsamda yapılan simülasyon çalışmaları neticesinde, 3 girişli giriş katmanı, 1 gizli katman ve 1 düğümlü çıkış katmanından oluşan bir YSA modeli oluşturulmuştur. Modelin gizli katmanlarında “tansig”, çıkış katmanında ise “purelin” transfer fonksiyonları kullanılmıştır. Modelin eğitiminde Levenberg–Marquardt (LM) algoritması kullanılmış ve algoritma 1000 iterasyon boyunca çalıştırılmıştır.


Model mimarisine ilişkin katman sayısı, her katmandaki nöron sayısı ve transfer fonksiyonları gibi parametreler, literatürde benzer problemlerde önerilen yapıların incelenmesi ve deneysel analizler doğrultusunda belirlenmiştir. Özellikle, nehir akış tahminine yönelik önceki çalışmalarda sıkça kullanılan tek gizli katmanlı yapılar referans alınmış, farklı nöron sayıları ile yapılan denemeler sonucunda en düşük hata oranı ve en yüksek doğruluk elde edilen yapı tercih edilmiştir. Bu kapsamda, gizli katmanda 3 nöron içeren yapı, doğruluk ve genelleme başarımı açısından en iyi sonucu verdiği için tercih edilmiştir. Gizli katmanda kullanılan ‘tansig’ (hiperbolik tanjant sigmoid) fonksiyonu, doğrusal olmayan örüntüleri öğrenme kapasitesi açısından uygun bulunmuş; çıkış katmanındaki ‘purelin’ fonksiyonu ise sürekli değer çıktısı üretme gerekliliği nedeniyle seçilmiştir. Transfer fonksiyonu ve nöron sayısı seçimleri, çapraz doğrulama ve farklı mimari denemeleri sonucunda optimize edilmiştir.

3. ARAŞTIRMA BULGULARI


YSA modelinin nehir akış tahminindeki performansını kıyaslamak için elde edilen sonuçlar, literatürde yer alan Özkan ve Haznedar’a ait [7] aynı istasyonlar için uygulanan ANFIS yöntemi ile elde edilen sonuçlar ile kıyaslanmıştır. Her bir istasyona ait gerçek ölçüm değerler ile YSA modeli ile elde edilen tahmin değerlerine ilişkin veriler Şekil 5-7’de verilmiştir.



Şekil 5. YSA modelinin 1825-Eğlence istasyonuna ait performansı



Şekil 6. YSA modelinin 1826-Ergenüşağı istasyonuna ait performansı



Şekil 7. YSA modelinin 1827-Değirmenocağı istasyonuna ait performansı

Performans metriklerine ilişkin eşitliklerden elde edilen YSA (ANN) sonuçları ile Özkan ve Haznedar tarafından elde edilen ANFİS sonuçları Çizelge 3'te verilmiştir. Çizelgeden YSA (ANN) ve ANFİS performans sonuçlarının birbirine oldukça yakın olduğu görülmektedir. Önerilen ANN modelinin tahmin performansının MAE değerleri, sırasıyla 1,1846, 3,1133, 1,7895 iken, RMSE olarak ANN modeli tarafından 5,0014, 6,9007 ve 3,4368 değerleri tespit edilmiştir. Modeller için en iyi MAPE değerleri sırasıyla 10,4268, 5,1373 ve 16,1989 olarak bulunmuştur. Sonuç olarak, R^2 kriterine göre de ANN modelinin değerleri sırasıyla 0,6696, 0,9237 ve 0,9348 olduğu bulunmuştur. Sonuçlar açısından, önerilen ANN modeli nehir akış tahmininde istatistiksel ölçümleriyle yüksek bir tahmin başarısı sağlamıştır. Tüm RMSE, MAE, MAPE ve R^2 istatistikleri dikkate alındığında, ANFİS modeline göre ANN modeli bir alternatif olarak seçilebilecektir.

YSA modeli MAPE ve MAE metriklerinde bir miktar düzeltme yapmış olsa da, ANFİS modeli de R^2 değerlerinde YSA modeline göre önde görülmektedir. YSA modelinin kendisine göre üstünlüklere sahip ANFİS modeli ile benzer sonuçlar vermesi, önerilen modelin başarısını ortaya koymuştur. Ayrıca, ANFİS ve YSA modellerinin sinirsel ağlar olmasından dolayı benzer performanslar göstermesi de yapay zekâ yöntemleri olarak önemli olduklarını bir kez daha göstermiştir.

YSA tabanlı modelin yanında, literatürde zaman serisi verilerinde başarılı sonuçlar verdiği bilinen Uzun Kısa Süreli Bellek (LSTM) ağı da uygulanmıştır. LSTM modeli, 3 zaman adımı ve 1 girdi özelliği içeren bir giriş yapısıyla oluşturulmuştur. Modelde 50 nöron içeren tek bir LSTM katmanı ve ardından 1 düğümlü bir çıkış katmanı kullanılmıştır. Aktivasyon fonksiyonu olarak 'tanh', optimizasyon için ise 'adam' algoritması tercih edilmiştir. Model 100 epoch boyunca, 32'lik mini-batch'lerle eğitilmiştir. LSTM modeliyle elde edilen sonuçlar da karşılaştırmalı olarak Çizelge 3'te verilmiştir.

Çizelge 3. Performans analiz tablosu

	Yöntem	'RMSE'	'MAPE'	'MAE'	'R ² '
1825	ANFİS [6]	4,9082	13,0560	1,2900	0,6854
	LSTM	4.9356	12.3900	1.1893	0.6757
	YSA	5,0014	10,4268	1,1846	0,6696
1826	ANFİS [6]	6,8502	5,1395	3,1550	0,9242
	LSTM	6.8131	5.3300	3.1545	0.9232
	YSA	6,9007	5,1373	3,1133	0,9237
1827	ANFİS [6]	3,3904	16,5770	1,8070	0,9373
	LSTM	3.6029	17.4000	1.8871	0.9282
	YSA	3,4368	16,1989	1,7895	0,9348

4. SONUÇLAR

Bu çalışmada, Türkiye'de Seyhan Havzası'nda yer alan Zamanti Nehri-Değirmenocağı, Zamanti Nehri-Ergenuşağı ve Eğlence Nehri-Eğribük istasyonlarının günlük akış değerlerinin yapay zekâ yöntemlerinden yapay sinir ağı (YSA-ANN) tekniği ile tahminlenmesi ve daha önce aynı havza için başka bir çalışmada elde edilen ANFIS tekniği ile kıyaslanarak YSA yönteminin doğruluk oranı araştırılmıştır. Ayrıca aynı zaman serisine YSA modelinin yanında Uzun Kısa Süreli Bellek (LSTM) ağı da uygulanmış ve YSA modelinin daha doğru sonuçlar verdiği görülmüştür. Modeller, verinin %80'i eğitim kısmında, %20'si test kısmında kullanılacak şekilde eğitilmiştir.

YSA modeli 3 farklı karakterdeki istasyona ait nehir akış verilerini benzer performanslar ile tahmin etmiştir. Ancak, 1825-Eğlence istasyonunda anlık tepe noktaları görüldüğünden dolayı YSA modeli bu tepe noktalarını tahmin etmekte zorlanmıştır. 1826-Ergenuşağı ve 1827-Değirmenocağı istasyonlarında akım debilerine ait artışlar sürekli bir zaman diliminde olduğundan YSA modelini bu tepe noktalarını daha rahat modelleyebilmiştir.

YSA modelinin nehir akış debisinin en tepe noktalarına ulaştığı değerleri tahmin etmekte eksik kaldığı görülmektedir. Bu kapsamda, YSA modelinin farklı yapay zekâ algoritmaları ile eğitilmesine yönelik gelecek çalışmalar yapılması planlanmaktadır.

5. KAYNAKLAR

1. Tübitak Bilim Genç Dergisi, <https://bilimgenc.tubitak.gov.tr/makale/gelecekteki-tehlike-su-kitligi>, Erişim Tarihi: 25.10.2024.
2. Beven, K.J. (2011). *Rainfall-runoff modelling: the primer*. 2nd Edition. John Wiley & Sons.
3. Storck, P., Bowling, L.C., Wetherbee, P. & Lettenmaier, P.D. (1998). Application of a GIS-based distributed hydrology model for prediction of forest harvest effects on peak stream flow in the Pacific Northwest. *Hydrological Processes*, 12, 889-904.
4. Dibike, Y.B. & Solomatine, D.P. (2001). River flow forecasting using artificial neural networks. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26(1), 1-7.
5. Liu, Y., Gupta, H.V., Springer, E. & Wagener, T. (2008). Linking science with environmental decision making: Experiences from an integrated modeling approach to supporting sustainable water resources management. *Environmental Modelling & Software*, 23, 846-858.
6. Firat, M. (2008). Comparison of artificial intelligence techniques for river flow forecasting. *Hydrology and Earth System Sciences*, 12(1), 123-139.
7. Özkan, F. & Haznedar, B. (2023). Comparative analysis of ANFIS models in prediction of streamflow: the case of Seyhan basin. *International Journal of Applied Mathematics Electronics and Computers*, 11(2), 72-78.
8. Bisht, C.S. & Ashok, J. (2011). Discharge modelling using adaptive neuro-fuzzy inference system. *International Journal of Advanced Science and Technology*, 31(1), 99-114.
9. Göçmen, S., Üneş, F., Taşar, B. ve Cansız, Ö.F. (2025). Amik ovasında buharlaşma tahmini için çoklu çıktılı yapay sinir ağları modeli. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 40(1), 1-15.
10. Tekin, P. (2022). Çukurova bölgesi için kısa vadeli yapay zeka tabanlı rüzgar gücü tahmini. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 1143-1154.
11. Bizimana, H., Demir, F. & Sonmez, O. (2016). Modeling of Yuvacık dam water level changes with fuzzy logic. In *4th International Symposium on Innovative Technologies in Engineering and Science (ISITES2016)* Alanya, Antalya, Türkiye.
12. Gunathilake, M.B., Karunanayake, C., Gunathilake, A.S., Marasingha, N., Samarasinghe, J.T., Bandara, I.M. & Rathnayake, U. (2021). Hydrological models and artificial neural networks (ANNs) to simulate streamflow in a tropical catchment of Sri Lanka. *Applied Computational Intelligence and Soft Computing*, 6683389, 9.
13. Riad, S., Mania, J., Bouchaou, L. & Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40, 839-846.
14. Mahabir, C., Hicks, F.E. & Robinson, F.A. (2003). Application of fuzzy logic to forecast seasonal runoff. *Hydrological processes*, 17(18), 3749-3762.
15. Kabalcı, E. (2013). *Yapay sinir ağları*. Ders Notları. <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>

16. Egrioglu, E., Aladağ, Ç.H., Yolcu, U., Uslu, V.R. & Basaran, M.A. (2009). A new approach based on artificial neural networks for high order multivariate fuzzy time series. *Expert Systems With Applications*, 36(7), 10589-10594.
17. Yapay sinir ağları ve tek katmanlı ağlarda öğrenme, <https://tr.linkedin.com/pulse/yapay-sinir-a%C4%9Flar%C4%B1-ve-tek-katmanl%C4%B1-a%C4%9Flarda-%C3%B6%C4%9Frenme-tanju-do%C4%9Fan>, Erişim tarihi: 15.11.2024.
18. Yapay sinir ağları ve R programıyla uygulama, <https://www.veribilimiokulu.com/yapay-sinir-aglari>, Erişim tarihi: 25.11.2024.
19. Fujihara, Y., Tanaka, K., Watanabe, T., Nagano, T. & Kojiri, T. (2008). Assessing the impacts of climate change on the water resources of the Seyhan river basin in Turkey: use of dynamically downscaled data for hydrologic simulations. *Journal of Hydrology*, 353(1-2), 33-48.
20. Haznedar, B. (2023). Adaptif ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS) kullanılarak nehir akışının tahmini: Sakarya havzası örneği. In *9th International Congress on Engineering and Technology Management*, İstanbul, Türkiye.
21. Taylor, K.E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research*, 106, 7183-7192.
22. Dawson, C.W. & Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Hydrological Science Journal*, 43, 47-66.
23. Tulun, Ş., Akgül, G., Alver, A. & Celebi, H. (2021). Adaptive neuro-fuzzy interference system modelling for chlorpyrifos removal with walnut shell biochar. *Arabian Journal of Chemistry*, 14(12), 103443.

