



Uzun-Kısa Süreli Bellek Ağlarının Nehir Akım Tahmininde Farklı Optimizasyonlarla Karşılaştırılması ve Tekil Spektrum Analizinin Etkisi

Hüseyin Çağan Kılınç^{1*}

^{1*} İstanbul Esenyurt Üniversitesi, Mühendislik-Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0003-1848-2856), huseyincagankilinc@esenyurt.edu.tr

(İlk Geliş Tarihi 19 Ocak 2021 ve Kabul Tarihi 28 Mart 2021)

(DOI: 10.31590/ejosat.864496)

ATIF/REFERENCE: Kılınç, H. Ç. (2021). Uzun-Kısa Süreli Bellek Ağlarının Nehir Akım Tahmininde Farklı Optimizasyonlarla Karşılaştırılması ve Tekil Spektrum Analizinin Etkisi. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 248-253.

Öz

Su kaynaklarının sürdürülebilir olması için periyodik nehir akım ölçümlerinin yapılması gerekmektedir. Bunun için farklı tahmin yöntemlerine gereksinim duyulmaktadır. Bu çalışmada, Yapay Zeka yöntemlerinden Derin Öğrenme (DL) ile Aksu Nehri akımlarının LSTM (Uzun-Kısa Süreli Bellek) sinir ağı ile tahmini yapılmıştır. Çalışmada, Aksu Nehri üzerindeki D20A002 No'lu Başpınar Akım Gözlem İstasyonuna (AGİ) ait 2000-2019 yılları arasını kapsayan veriler analiz için girdi olarak kullanılmıştır. Ayrıca, Tekil Spektrum Analizi'nin (TSA) LSTM'ye olan performans etkisi irdelenmiştir. TSA-LSTM modeline iyileştirici olarak Adam, Adamax ve AdaGrad algoritmaları uygulanmıştır. Tahmin ve gerçek değerler karşılaştırılarak en doğru tahmin modeli belirlenmiştir. Akım tahmininde iyi performansı Adamax iyileştiricisinin sağladığı görülmüştür. TSA-LSTM modeli katsayısı (R^2) tayini test aşamasında 0,9851 bulunmuştur. Elde edilen sonuçlar incelendiğinde TSA-LSTM modelinin akım çalışmaları tahmininde daha iyi sonuçlar verdiği görülmüştür.

Anahtar Kelimeler: Uzun-Kısa Süreli Bellek Ağları, Tekil spektrum, Akım.

Comparison of Long-Short Term Memory Networks with Different Optimizations in River Flow Prediction and the Effect of Singular Spectrum Analysis

Abstract

Periodic river flow measurements are required to ensure sustainable water resources. For this, different estimation methods are required. In this study, Deep Learning (DL) and Aksu River flows were estimated by LSTM (Long-Short Term Memory) neural network, which is one of the Artificial Intelligence methods. In the study, the data belonging to Başpınar Flow Measurement Station (FMS) (D20A002) on Aksu River between 2000-2019 were used as input for analysis. In addition, the performance effect of Single Spectrum Analysis (TSA) on LSTM was examined. Adam, Adamax and AdaGrad algorithms were applied to the TSA-LSTM model. The most accurate estimation model has been determined by comparing the estimate and actual values. It has been observed that the Adamax optimizer provides the best performance in flow estimation. TSA-LSTM model coefficient (R^2) determination was found to be 0.9851 during the test phase. When the obtained results were examined, it was seen that the TSA-LSTM model gave better results in estimating flow studies.

Keywords: LSTM, Singular spectrum, Stream flow.

* Sorumlu Yazar: huseyincagankilinc@esenyurt.edu.tr

1. Giriş

İnsan yaşamının her döneminde gerekli olan suyun varlığı ve kalitesi oldukça önemlidir. İnsanoğlu, yaşamını devam ettirebilmesi için suyun özelliklerini tanımaya, kontrol altına almaya, hareketini yöneten kanunları belirlemeye, oluşabilecek tehlikeleri önlemeye ve sudan en iyi şekilde yararlanmaya çalışmışlardır (Yücerer ve Yılmaz, 2020). Küresel ısınma, kuraklık, iklim değişikliği, plansız tüketim, sanayileşme ve tarımsal kullanım nedeniyle su talebinin artması temiz su kaynakları üzerinde baskı yaratmaktadır. Bu riski azaltmanın yolu, mevcut kaynakların ve su yönetiminin etkin kullanımınıdır. Sürdürülebilir su kaynakları planlaması ve entegre nehir havzası etkin yönetimi mühendislere ve karar vericilere önemli faydalar sağlamaktadır. Su kaynakları potansiyelinin belirlenmesinde, taşkın veya kuraklık durumlarında baraj haznelerinin davranışlarının incelenmesinde büyük önem taşımaktadır. Sürdürülebilirliğin sağlanması için önemli noktalardan biri de nehir akımlarının ileriye dönük tahminidir (Kılınç, 2021). Nehir akımlarının doğru ve hassas tahmini için akarsu akımları ve havzaya ait hidrometrik ölçümlere ihtiyaç duyulmaktadır. Fakat sadece gözlemlenmiş değerler yeterli olmaz. Taşkın kontrol rezervuarlarının işletilmesi, kurak dönemlerde hidroelektrik verilerinin anlaşılması, içme suyu ve sulama suyunun dağıtımını ve nehir ulaşımının planlanması için gelecekteki nehir akımlarının öngörülmesi çok önemlidir. Bu veriler olması muhtemel değerlerdir (İstanbuluoğlu ve Konukçu, 2006). Bu değerler gözlenmiş olan veriler yardımıyla bulunurlar. Öte yandan, verisel tabanlı modeller deneyseldir, basittir ve uygulaması kolaydır. Ayrıca süreçle ilgili herhangi bir fiziksel bilgi gerektirmez (Küçükerdem vd., 2019).

Günümüzde eski yıllara göre sorunlar ve hesaplama problemleri katlanarak büyümüştür. Bu büyümeler aynı zamanda ortaya çok fazla verinin çıkmasına neden olmuştur. Süregelen bu süreçte çok miktarda verinin işlenmesi hatta eski veri yığınlarının içerisinde gelecek bir durum veya olay tahmini yapılması mümkün hale gelmiştir. Makine öğrenmesi bu büyük veri yığınlarının içerisinde belirli problemleri çözmek veya belirli durumlar için tahminlerde bulunabilmek için ortaya çıkmıştır. Derin öğrenme, yapay zekâ alanında yeni bir öğrenme yöntemidir ve yapısında bulunan algoritmaları sayesinde etkili özellik temsillerinin öğrenilmesine yardımcı olmaktadır. (Gemici vd., 2013). Derin öğrenme'nin belirleyici farkı ise katmanlar halinde çalışması ve bu katmanların birbirleri arasında bilgi aktarımı olmasıdır. Yani herhangi bir katman kendinden önceki katmanlardan bilgi alarak kendi bilgisini revize edebilir. Verilen bir veri kümesiyle çıktılar tahmin edebilmek için farklı öğrenme yöntemleri kullanılabilir ve sınıflandırma yapabilir (Ahi ve Soğukpınar, 2020). Nehir akım verileri yapısından dolayı lineer olmayan karakterdedir. Makine öğrenme yöntemleri bu verilerin tahmini için yaygın olarak kullanılmaktadır.

Bazı durumlarda veriler arasında zamana dayalı ya da ardışık türden ilişkiler olabilir. Bu tür durumlarda yapay sinir ağları yeterli performansı sağlayamamaktadır. Yinelenen sinir ağlarının bazı problemleri sebebiyle ortaya çıkan ve günümüzde sıkça kullanılan uzun kısa vadeli hafıza ağları (LSTM) bu durumlarda çözüm olmuştur. LSTM ilk olarak Hochreiter ve Schmidhuber tarafından geliştirilmiştir. Ek olarak, zaman serisi verilerinden niteliklerini manuel olarak belirlemek zor olduğu için derin yapay sinir ağları önerilmiştir. LSTM, zaman serileri tahmini için yaygın olarak kullanılmaktadır.

Sivapgrasam vd. (2001) yağış yüzey akış değerlerini tahmin etmek için destek vektör makinesi (SVM) ile birlikte TSA analizine dayalı bir yaklaşım modeli geliştirmiştir. Elde edilen sonuçlar doğrusal olmayan tahmin yöntemi doğal dil işleme (NLP) ile karşılaştırılmış ve önerilen modelin NLP'ninkinden önemli ölçüde daha yüksek bir doğruluk sağladığı görülmüştür. Chau ve Wu (2010) günlük nehir akım değerlerinin tahmini için TSA ile birleştirilmiş hibrit bir model geliştirmiştir. Modelleme sürecinde ilk olarak ham akım verilerini ayrıştırmak için TSA analizi yapılmıştır. Daha sonra veriler kümelenecek alt gruplara ayrılmıştır. Düşük ve orta yoğunluklu alt kümeleri eğitmek ve tahmin etmek için iki yerel yapay sinir ağı modeli, yüksek yoğunluklu alt kümeye ise yerel bir destek vektörü regresyon modeli uygulanmıştır. Veriler yapay sinir ağları (YSA) modeli ile kıyaslanmıştır. Sonuçlar, hibrit regresyon modelinin en iyi performansı gösterdiğini göstermiştir. Ayrıca, Tekil spektrum analiz modeli, akım tahmininde de yüksek bir doğruluk sergilemiştir. Bojang vd. (2020) aylık yağış değer tahmini için TSA bağlantılı makine öğrenimi modeli geliştirmiştir. Oluşturulan bu hibrit model, standart modeller ile karşılaştırılmıştır. Sonuçlar, hibrit modellerin yağışları aylık olarak verimli bir şekilde tahmin edebileceğini göstermiştir. Genel olarak, hibrit modellerin, standart modellerden önemli ölçüde üstün olduğu görülmüştür.

Xu vd. (2020) araştırmalarında nehirlerin akım tahmini için zaman serisi veri alanını hedefleyen LSTM ağını kullanmıştır. LSTM'nin tahminleri Destek Vektör Regresyonu (SVR) ve Çok Katmanlı Algı Modelleri ile (MLP) ile karşılaştırılmıştır. Ayrıca LSTM modeli üzerinde geliştirilmiş deneyler yapılarak performansın etki faktörleri araştırılmıştır. Performans sonuçlarında LSTM'nin daha iyi sonuçlar verdiği görülmüştür. Liu vd. (2020) çalışmalarında nehir akım değerleri tahmini için LSTM ağı bağlantılı Amprik Mod Ayırma (EMD) modelini oluşturmuştur. Modelin performansı Willmott indeksi (WI) ve Legates-McCabe's (LMI) indeksi ile değerlendirilmiştir. Sonuçlar, sel yıllarında ve uzun süreli sürekli tahminlerde bu yöntemin güvenilirliğini göstermiştir. Aylık akım verileri ile oluşturulan girdiler tahmin ve gözlemlenen değerler arasında yakın sonuçlar vermiştir. Literatür'de TSA ile LSTM analizini birlikte kullanan Latifoğlu ve Nuralan (2020), yapmış oldukları araştırmalarında LSTM ağlarını kullanarak nehir akım tahminini gerçekleştirmiştir. Tahmin verisi için TSA kullanarak oluşan yeni modelin performans analizi incelenmiştir.

Ayrıca literatürde LSTM analizi, nehir akımları tahmin analizi dışında oldukça başarılı olduğu görülmektedir. Kara (2019), günlük güneş ışınımı tahmininde etkin bir model oluşturmak için LSTM ağı önermiştir. Önerilen yöntemin etkinliği, makine öğrenme algoritmaları ile karşılaştırılmıştır. LSTM yönteminin diğer makine öğrenme modellerinden daha iyi performansa sahip olduğunu göstermiştir. Sagheer ve Kotb (2019), petrol fiyatlarını tahmin etmek için çalışmalarında LSTM algoritması kullanmıştır. Bouktif vd. (2018) LSTM parametre optimizasyonu için bir genetik algoritma yöntemi önermiştir. Ayrıca, finansal piyasadaki hisse senedi fiyatlarını tahmin etmek için LSTM algoritmasının performansı da incelenmiştir (Alpay, 2020). Balcı ve Oralhan (2020), LSTM kullanarak üç farklı eğitim serisi üzerinde 200 test uygulamış ve sistemi farklı koşullar altında çalışacak şekilde tasarlamıştır. Sistemin çeşitli optimizasyon algoritmaları kullanılarak gelişime açık olduğunu saptamışlardır. Süzen vd. (2019) LSTM tabanlı DSA ile bireylerin ölçülen ayak tabanı basınç değerleri ile vücut kitle indeksi durumlarını sınıflandıran bir model geliştirmiştir. LSTM tabanlı

DSA, sınıflandırma işlemlerinde yüksek başarı performansı göstermiştir.

2. Materyal ve Metot

2.1. Akım Gözlem İstasyonu Verileri


Aksu Nehri'nin Kahramanmaraş topraklarındaki uzunluğu 115 km'dir. Aksu Çayı Havzası, Ceyhan Nehri Havzası içerisinde bir alt havza konumunda olup bir açık havza olma özelliğine sahiptir. Nehir Sularını Kahramanmaraş üzerinden Sır Barajı'na bırakır. Sır Barajı'nı Ceyhan Nehri'nden sonra besleyen en büyük akarsudur (Sarıgül ve İnan, 2013).

Çalışmada Ceyhan havzası Gölbaşı Kahramanmaraş yolunun 60. km'sinden sağa ayrılan yolun 16. km'si üzerindeki Devlet Su İşleri (DSİ)'ye ait Aksu Nehri üzerinde yer alan D20A002 no'lu Başpınar AGİ'den alınan günlük akım verileri kullanılmıştır. Nehir günlük akım verileri 2000-2019 yılları arasına aittir. Verilerin işlendiği alana ait harita Şekil 1.'de verilmektedir. Akım verileri (DSİ) Genel Müdürlüğü'nden, sağlanmıştır (Bayazıt, 1999).



Şekil 1. Ceyhan Havzası

Çalışmada akım verilerinin %80'i eğitim verisi %20'si ise test verisi olarak kullanılmıştır. Şekil 2' de kullanılan normalize eğitim ve test verileri görülmektedir.



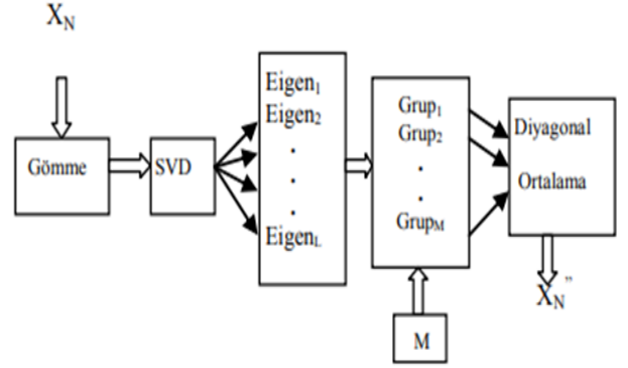
Şekil 2. Çalışmada kullanılan eğitim ve test verileri

2.2. Tekil Spektrum Analizi

Vautard vd. (1992) TSA'yı uyarlanabilir bir gürültü azaltma algoritması olarak tanımlamıştır. Zaman serisi analizlerinde güçlü bir teknik olan TSA, görüntü işleme, sistem tanımlama, modelleme gibi birçok alanda kullanılmaktadır.

Birçok bilimsel araştırma alanında kullanılan TSA, zaman serisi analizlerinde yenilikçi ve güvenilir bir tekniktir. İlk olarak Broomhead ve King (1986) tarafından önerildiğinden beri;

klimatoloji, meteoroloji ve jeofizik gibi alanlarda geniş ilgi görmüştür. TSA yöntemi, bir iletiyle ilgili parçalara bölmek için zaman bilgisini kullanan bir yöntemdir. Yöntem ayırma ve yeniden oluşma olmak üzere iki ana süreci içerir. Ayırıştırma, aşaması gömme ve tekil değer ayırıştırma işlemlerinden oluşmaktadır. Şekil 3'te işlem aşamaları gösterilmektedir. Denklem içinde ifade edilen N uzunluğundaki X (t) sinyali, belirli bir pencere aralığı (L) olan bir matris olarak ifade edilir. (Acer vd., 2014).




Şekil 3. Tekil spektrum analizi yönteminin aşamaları

Sinyali bir matris olarak ifade etme sürecine Hankelizasyon süreci denir. Şekil 4'te gibi elde edilen KxL boyutlu matrise yörünge matrisi denir. L, pencerenin uzunluğudur, K = NL + 1. Pencere uzunluğu, periyodik sinyalin süresidir. Gömme işleminden sonra, tekil değer ayırıştırma (TDA) uygulanır. A matrisi A=USVT olarak üç matrise ayrıştırılabilir. Burada (U) KxK, (V) LxL, ortogonal matrislerde ve (S) ise LxK boyutlarında köşegen matristir. S matrisinin köşegen elemanları A matrisinin tekil değerleri olarak adlandırılır. Ardından gruplandırarak oluşturduğumuz yeni matrisin diyagonal ortalaması alınarak oluşan zaman serisi ile işlem tamamlanmış olur. Tek spektrum analizinde (SSA) L spesifikasyon standardını kullanarak Hankelizasyon işlemini incelemek çok önemlidir. Özellikle, iki boyutlu SSA matrislerinde çapraz köşegenlerin temsil edilen değerleri, L'i en aza indirerek bulunabilmektedir (Acer vd., 2014; Huang ve Ling, 2019).


$$X = \begin{bmatrix} X_1 & X_2 & \dots & X_L \\ X_2 & X_3 & \dots & X_{L+1} \\ \vdots & \vdots & \ddots & \vdots \\ X_K & X_{K+1} & \dots & X_N \end{bmatrix}$$

Şekil 4. Gömme işlemine ait matris (Acer vd., 2014)

Çalışmada kullanılan veriler TSA ile iki ayrı gruba ayırıştırılmıştır. TSA analizinde gömme aşamasında ardışık akım değerlerinin benzerliğinden ötürü, pencere uzunluğu 16 olarak tanımlanmıştır. Alt bant verileri 1-8 özdeğerine ve 9-16 özdeğerine göre gruplandırılarak tekrar oluşturulmuştur. Şekil 5 ve Şekil 6'da TSA alt bant verileri eğitim ve test olarak ayrı ayrı gösterilmektedir.



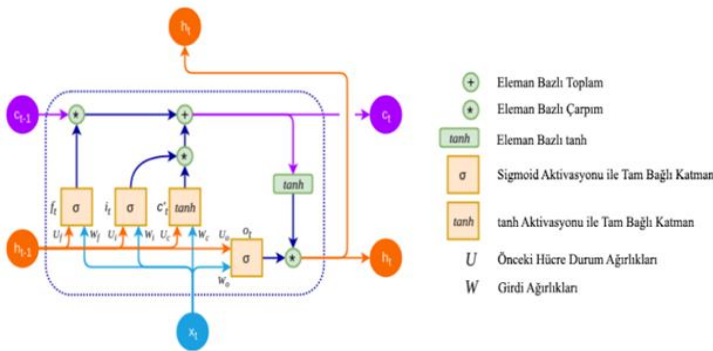
Şekil 5. Tahmin çalışmasında kullanılan TSA 1. altbant verisi



Şekil 6. Tahmin çalışmasında kullanılan TSA 2. altbant verisi

2.3. Uzun-Kısa Süreli Bellek Ağları

Uzun-Kısa Süreli Bellek ağları (derin bir sinir ağı olarak gösterilebilir), gradyan bozma ve gradyan patlama problemi çözmek için kullanılmaktadır. Uzun ve kısa süreli bellek ağları, temel olarak geçmişteki bilgilerin mevcut bilgiyi açıklamasında ve gelecek bilginin tahmin edilmesinde etkili bir yöntemdir. Uzun ve kısa süreli depolama katmanının ana bileşeni, depolama bloğu verilen bir birimdir. Uzun ve kısa süreli bellek bloklarının giriş, çıkış ve unutma kapıları olmak üzere üç kapısı vardır. Bu kapılar hücrenin yazılmasını, okunmasını ve sıfırlanmasını gerçekleştirir. Uzun ve kısa bellek hücre durumu, uzun ve kısa süreli belleğin her bloğu arasında bilgi aktarımı için anahtar bir bileşendir. Bütün hücreler bu üç kapı tarafından kontrol edilir. (Singh ve diğ., 2017). Giriş kapısı açık hücreye giriş bilgileri kontrol eder, geçmiş geçidi kullanarak yeni verilere ne kadar bilgi aktarılacağını belirler ve çıkış geçidini kullanarak çıktıyı hesaplarken ne kadar bilgi kullanılacağını kontrol eder. (Tokgöz ve Ünal, 2018).



Şekil 7. LSTM yapısı

Yapıda yer alan i , o , f ve c terimleri sırasıyla giriş kapısı, çıkış kapısı, unut kapısı ve hafıza hücrelerini ifade etmektedir. LSTM mimarisinde öncelikle girdi olarak X_t ve $ht-1$ bilgileri kullanılarak hangi bilgilerin silineceğine karar verilir. Unut kapısı, kararı bir önceki $ht-1$ hücresinin çıktısına ve mevcut x_t girdisine dayandırmaktadır.

Çalışmada en sık kullanılan aktivasyon fonksiyonu olan sigmoid kullanılmıştır. Bahsi geçen işlem, Denklem 1'deki eşitlik yardımıyla gösterilmiştir.

$$f_t = \sigma(W_f \cdot x_t + W_{f,h} \cdot ht-1 + b_f) \quad (1)$$

İkinci adımda yeni bilgilerin belirleneceği girdi katmanı devreye girer ve öncelikle (1) Eşitlik (2) kullanılarak sigmoid fonksiyonu ile bilgiler güncellenir. Ardından Eşitlik (3) ile yeni bilgiyi oluşturacak aday bilgiler tanh fonksiyonu tarafından belirlenir.

$$i_t = \sigma(W_i \cdot x_t + W_{i,h} \cdot ht-1 + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot x_t + W_{c,h} \cdot ht-1 + b_c) \quad (3)$$

Eşitlik (4) tarafından yeni bilgiler oluşturulur. Unut ve girdi kapıları, yeni ve eski durumun hangi kısımlarının dâhil edileceğini seçerek yeni hücre durumuna karar vermektedir.

$$C_t = C_{t-1} * f_t + i_t * \tilde{C}_t \quad (4)$$

Çıktı kapısı, toplam hücre çıktısının ne olacağına karar vermektedir. Hücre belleğinin her bir bloğu için $ht-1$ ve x_t 'yi girdi olarak alır. Son olarak Eşitlik (5) ve (6) kullanılarak çıktı verileri elde edilir. Uzun-Kısa Süreli Bellek çıktısı bir tanh fonksiyonu ile transfer edilmektedir.

$$o_t = \sigma(W_o \cdot x_t + W_{o,h} \cdot ht-1 + b_o) \quad (5)$$

$$ht = o_t * \tanh(C_t) \quad (6)$$

Bu işlemler doğrultusunda süreç tekrarlanarak devam eder. Ağırlık parametreleri (W) ve bias parametreleri (b) gerçek eğitim değerleri ile LSTM çıktı değerleri arasındaki farkı minimize edecek şekilde model tarafından öğrenilmektedir (Sakarya ve Yılmaz, 2019).

2.4. Performans Yöntemleri

2.4.1. Ortalama Mutlak Hata

Ortalama Mutlak Hata (OMH) iki sürekli değişken arasındaki farkın ölçüsüdür. OMH, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir.

2.4.2. Ortalama Karesel Hata

Ortalama Karesel Hata (OKH), bir makine öğrenmesi modelinin, tahminleyicinin performansını ölçer, her zaman pozitif değerlidir ve OKH değeri sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdiği söylenebilir.

2.4.3. Determinasyon Katsayısı

Regresyonda bağımlı değişkenin yüzde olarak ne kadarının açıklayıcı değişkenler tarafından açıklandığını gösterir. Determinasyon katsayısı R^2 ile gösterilir.

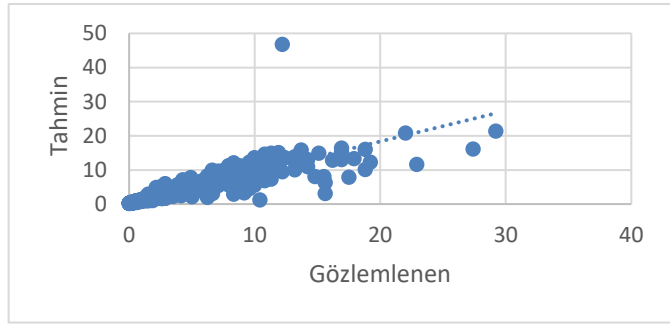
2.4.4. Standart Sapma

Standart sapma varyansın kareköküdür. Daha matematiksel bir ifade ile standart sapma veri değerlerinin aritmetik ortalamadan farklarının karelerinin toplamının veri sayısı -1'e bölümünün kareköküdür, yani verilerin ortalamadan sapmalarının kareler ortalamasının karekökü olarak tanımlanır.


3. Araştırma Sonuçları ve Tartışma

3.1. Uzun-Kısa Süreli Bellek Ağları


Nehir akım verileri normalize edilmiş ve LSTM metodu ile bir ötelemeli tahmin işlemi uygulanmıştır. Derin Sinir Ağı Modeli dört girdi katmanı kullanılarak oluşturulmuştur. LSTM katmanı da bu girdiler arasında yer almaktadır. Ağı eğitimi aşamasında maksimum iterasyon sayısı 100, öğrenme oranı ise 0,2 olarak belirlenmiştir. Ağı eğitimi için 'Adam', 'Adamax' ve 'AdaGrad' optimizasyon algoritması kullanılarak performansları karşılaştırılmıştır. Tablo 1'deki performans değerlendirme kriterlerine göre en düşük OKH, OMH değerlerinin ve en yüksek R^2 değerinin Adamax optimizasyon algoritmasından elde edildiği görülmüştür. Şekil 8, Şekil 9, Şekil 10 gözlemlenen değerlerle, tahmin edilen değerlerin karşılaştırıldığı en önemli grafiklerden olan saçılma grafiği eğitim ve test sonuçlarına göre gösterilmiştir. Bu tip saçılma grafiklerinde gösterilen gerçek ve tahmin edilen değerler ne kadar doğrusalsa değerler birbirine o kadar yakındır.



Şekil 8. LSTM Modeli Adam test veri setine ait saçılma grafiği



Şekil 9. LSTM modeli Adamax test veri setine ait saçılma grafiği



Şekil 10. LSTM modeli AdaGrad test veri setine ait saçılma grafiği

Tablo 1. Optimizasyon algoritmalarının performans değerleri

OPTİMİZASYONLAR	STD	MSE	MAE	R^2
LSTM				
Adam	3,3566	6,8644	0,4625	0,8353
Adamax	3,2015	2,4161	0,3910	0,8741
AdaGrad	3,1780	1,5311	0,4382	0,8691


3.2. TSA-Uzun Kısa Süreli Bellek Ağları

Normalize edilen dataset eğitim ve test datasetleri olarak ayrıştırılmış ve her iki dataset de TSA ile iki alt bantta gruplandırılmıştır. Alt bantlar kullanılarak yapılan tahminlerde LSTM modeline benzer bir yapı oluşturulmuştur. TSA-LSTM yönteminde, LSTM yöntemi ile aynı parametreler kullanılmış ve LSTM yöntemindeki en iyi performans sonucuna ait olan Adamax iyileştiricisi kullanılmıştır. TSA-LSTM modeli ile bir ötelemeli tahmin işleminin performans sonuçları Tablo 2 de görülmektedir.

Tablo 2. Modellerin tahmini performans değerleri

	STD	MSE	MAE	R^2
LSTM				
1 giriş-1 çıkış	3,2015	2,4161	0,3910	0,8741
TSA-LSTM				
1 giriş-1 çıkış	3,4194	1,5122	0,1772	0,9851

Tablo 2'de TSA-LSTM yönteminin LSTM yönteminden daha başarılı olduğu görülmektedir. Şekil 11' de ise gözlemlenen değerler ile TSA-LSTM modelinden elde edilen tahmin değerleri gösterilmiştir.



Şekil 11. TSA-LSTM Modeli test veri setine ait saçılma grafiği

4. Sonuç

Akış boyunca havzaya yerleştirilen ölçüm istasyonlarının değerleri tahmini destekleyen en önemli etkidir. Akış verilerinin yüksek hassasiyetli değerlerinin tahmin edilmesi, nehir havzası yönetimini ve planlamasını kolaylaştıracaktır. Kullanıldığı çalışmalarda etkin sonuçlar veren yapay zekâ yöntemlerinden biri olan Derin Öğrenme Modeli incelendiğinde çözüm metodu olarak uygun bulunmuştur.

Bu çalışmada, günlük akım verilerine uygulanan TSA yönteminin akım tahminlerinde kullanılan derin sinir ağları performansına etkisi incelenmiştir. LSTM modeli Adam, Adamax ve AdaGrad iyileştiricileri kullanılarak uygulanmıştır. En iyi performans, Adamax iyileştiricisi kullanılarak eğitilen ağda görülmüştür. LSTM modelinde çıkan sonuçlarda: MSE değeri 2.4161, MAE değeri 0.3910 ve R^2 değeri ise 0.8741 iken TSA-LSTM modelinde çıkan sonuçlarda: MSE değeri 1.5122, MAE değeri 0.1772 ve R^2 değeri 0.9851'dir. Sonuçlara bakıldığında,

TSA veri ön işleme çalışmasının modelin performansını önemli ölçüde etkilediği ve TSA-LSTM modelinin nehir akış tahmin araştırmalarında kullanılabilecek önemli bir yöntem olduğu görülmektedir. Akım değerleri tahmininde kullanılabilecek bu metod, Aksu Nehri yakınında yapılması planlanan barajların tasarımı ve fizibilitesi için önemli bir kaynak olacaktır.

Kaynakça

- Acer, Ç. G., Latifoğlu, F., Eset, K., & Kuduz, H. (2014). Elektromiyogram Sinyallerinden Tekil Spektrum Analizi Kullanarak Öznitelik Çıkarımı, Tıp Teknolojileri Ulusal Kongresi, Biyomedikal Mühendisliği Bölümü, Erciyes Üniversitesi.
- Ahi, Ş.N., Soğukpınar, I. (2020). Derin Öğrenme Modelleri İle Kimlik Avı E-Posta Tespiti, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, cilt 13, no. 2, pp. 17-31, 2020.
- Alpay, Ö. (2020). LSTM Mimarisi Kullanarak USD/TRY Fiyat Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 452-456, 2020.
- Balcı, F., Oralhan, Z. (2020). LSTM ile EEG Tabanlı Kimliklendirme Sistemi Tasarımı. *Avrupa Bilim ve Teknoloji Dergisi*, (Special Issue), 135-141, 2020.
- Bayazit, M. 1996. İnşaat Mühendisliğinde Olasılık Yöntemleri (I. Basım), İTÜ Rektörlüğü Yayın No: 1573, 245 s.
- Bojang, P. O., Yang, T. C., Pham, Q. B., Yu, P. S. (2020). Linking Singular Spectrum Analysis and Machine Learning for Monthly Rainfall Forecasting. *Applied Sciences*, 10(9), 3224.
- Bouktif, S., Fiaz, A., Ouni, A., Serhani, M. (2018). Optimum deep learning lstm model for electric charge prediction using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11 (7), 1636
- Broomhead, D., King, G. (1986). Deriving qualitative dynamics from experimental data. *Physica D: Nonlinear Events*, 20 (2-3), 217-236.
- Chau, K. W., Wu, C. L. (2010). A hybrid model coupled with singular spectrum analysis for daily rainfall prediction. *Journal of Hydroinformatics*, 12(4), 458-473.
- DSİ, (1994). Türkiye Akarsu Havzaları Maksimum Akımlar Frekans Analizi, DSİ Etüd ve Plan Dairesi Başkanlığı, Ankara.
- Gemici, E., Ardiçlıoğlu, M., Kocabaş, F. (2013). Akarsular Debinin Yapay Zeka Yöntemleri İle Modellenmesi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, cilt 2, no. 29, pp. 135-143, 2013.
- Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory, *Neural computation*, cilt 9, no. 8, pp. 1735-1780, 1997.
- Huang, Z., Ling, B. (2019). Hankelization of singular spectrum analysis matrices with L 1 norm criterion. *Signal, Image and Video Processing*, 13 (5), 933-940.
- İstanbuluoğlu, A., Konukçu, F. (2006). Trakya Bölgesi Su Kaynaklarının Geliştirilmesi ve Sulu Tarım Uygulamaları, *Tekirdağ Ziraat Fakültesi Dergisi*, cilt 3, no. 2, pp. 139-152, 2006.
- Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri, *Gazi Üniversitesi Fen Bilimleri Dergisi*, cilt 7, no. 4, pp. 882-892, 2019.
- Kılınç, H.Ç. (2021). Nehir Akımlarının Derin Öğrenme İle Tahmini ve Akımların Demiryolları Güzergahına Etkisi, *Demiryolu Mühendisliği*, no. 13, pp. 106-114
- Küçükerdem, T.S, Kilit, M., Saphoğlu, K. (2019). Bulanık çıkarım sistemlerinde kullanılan küme sayılarının K-ortalamar, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 8, no. 25, pp. 962-967
- Latifoğlu, L., Nuralan K.B. (2020). Tekil Spektrum Analizi ve Uzun-Kısa Süreli Bellek Ağları ile Nehir Akım Tahmini.” *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 376-381, 2020.
- Liu, D., Jiang, W., Mu, L., Wang, S. (2020). Streamflow Prediction Using Deep Learning Neural Network: Case Study of Yangtze River. *IEEE Access*, 8, 90069-90086.
- Sagheer, A., Kotb, M. (2019). Time series prediction of oil production using deep LSTM recurrent networks. *Neuro calculation*, 323, 203-213.
- Sakarya, Ş., Yılmaz, Ü. (2019). Derin Öğrenme Mimarisi Kullanarak BİST30 İndeksinin Tahmini. *European Journal of Educational and Social Sciences*, 4(2), 106-121.
- Sarıgül, O., İnan, N. (2013). *Aksu Çayı havzası (K. maraş)'nın fiziki coğrafyası* (Master's thesis, Necmettin Erbakan Üniversitesi).
- Singh, D., Merdivan, E., Psychoula, I., Kropf, J., Hanke, S., Geist, M., Holzinger, A. (2017). Human Activity Recognition Using Recurrent Neural Networks. Paper presented at the International Cross-Domain Conference for Machine Learning and Knowledge Extraction.
- Sivapragasam, C., Liong, S. Y., & Pasha, M. F. K. (2001). Rainfall and runoff forecasting with SSA-SVM approach. *Journal of Hydroinformatics*, 3(3), 141-152.
- Süzen, A.A., Yıldız, Z., Yılmaz, T. (2019). “LSTM tabanlı Derin Sinir Ağı ile Ayak Taban Basınç Verilerinden VKİ Durumlarının Sınıflandırılması.” *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 8(4), 1392-1398, 2019.
- T.C. Çevre ve Şehircilik Bakanlığı, (2016). Çevre Yönetimi Genel Müdürlüğü, Ceyhan Havzası Kirlilik Önleme Eylem Planı
- Tokgöz, A. ve Ünal, G. (2018). Türkiye elektrik yükünü tahmin etmek için RNN tabanlı bir zaman serisi yaklaşımı. In *2018 26 Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU)* (s. 1-4). IEEE.
- Vautard, R., Yiou, P., Ghil, M. (1992). Singular spectrum analysis: A toolkit for short, noisy chaotic signals. *Physica D: Nonlinear Events*, 58 (1-4), 95-126.
- Xu, W., Jiang, Y., Zhang, X., Li, Y., Zhang, R., & Fu, G. (2020). Using long short-term memory networks for river flow prediction. *Hydrology Research*, 51(6), 1358-1376.
- Yücerer, B., Yılmaz, T. (2020). Küresel Su Hakları ve Türkiye, *Çukurova Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, cilt 39, no. 7, pp. 124-132