

GAZİ

JOURNAL OF ENGINEERING SCIENCES

Estimating Streamflow Data with Machine Learning Techniques

Esra Aslı Çubukçu^{a*}, Vahdettin Demir^b, Mehmet Faik Sevimli^c

Submitted: 19.02.2022 Revised: 22.05.2022 Accepted: 20.06.2022 doi:10.30855/gmbd.0705009

ABSTRACT

Keywords: Stream Flow, Forecasting, Machine Learning, Lamas River.

^{a,*} KTO Karatay University, Faculty of Engineering and Natural Sciences, Dept. of Civil engineering, Konya- Türkiye
Orcid: 0000-0003-4159-205X
e mail: cubukcuasli@gmail.com

^b KTO Karatay University, Faculty of Engineering and Natural Sciences, Dept. of Civil engineering, Konya- Türkiye
Orcid: 0000-0002-6590-5658

^c KTO Karatay University, Faculty of Engineering and Natural Sciences, Dept. of Civil engineering, Konya- Türkiye
Orcid: 0000-0002-4676-8782

*Corresponding author:
cubukcuasli@gmail.com

Anahtar Kelimeler: Akarsu Akışı, Tahmin, Makine Öğrenmesi, Lamas Nehri.

Estimation of stream flows is very important in basin and flood management. It is a very difficult topic to predict hydrological events that do not show linearity and depend on many parameters. In this study, streamflow modeling has been made and compared by using Artificial Neural Networks (ANN), Support Vector Machines (SVM) and Deep Learning (DL) optimizations using monthly average streamflow data of Mersin Lamas River. When the results are examined, it has been observed that the best method in solving the problem is ANN and SVM methods, which give more unsuccessful results. Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Nash Sutcliffe model Efficiency coefficient (NSE), Mean Absolute Relative Error (MARE) and Coefficient of Determination (R^2) were used as comparison criteria. 1 input model of DL gave the best result (RMSE=0.7647, MAE=0.7370, NSE=0.9724, MARE=27.9326, R^2 =0.9962).

Akım Verilerinin Makine Öğrenmesi Teknikleriyle Tahmin Edilmesi

ÖZ

Akarsu akımlarının tahmini havza ve taşkın yönetiminde oldukça önemlidir. Doğrusallık göstermeyen ve birçok parametreye bağlı olan hidrolojik olayların tahminleri oldukça zor bir konudur. Bu çalışmada Mersin Lamas Nehri aylık ortalama akım verileri kullanılarak Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve Derin Öğrenme (DÖ) optimizasyonları kullanılarak akım modellemesi yapılmış ve karşılaştırılmıştır. Sonuçlar incelendiğinde problemin çözümünde en iyi yöntemin DÖ olduğu YSA ve DVM yöntemlerinin ise buna göre daha başarısız sonuçlar verdiği gözlemlenmiştir. Karşılaştırma kriteri olarak Karekök Ortalama Karesel Hata (KOKH), Ortalama Mutlak Hata (OMH), Nash Sutcliffe modeli verimlilik katsayısı (NSE), Ortalama Mutlak Bağlı Hata (OMBH) ve Determinasyon Katsayısı (R^2) kullanılmıştır. En iyi sonucu DÖ'ye ait 1 giriş modeli vermiştir (KOKH= 0.7647, OMH=0.7370, NSE=0.9724, OMBH=27.9326, R^2 =0.9962).

1. Giriş (Introduction)

Akarsuyun kesitinden birim zamanda geçen su miktarı akarsu debisi olarak tanımlanır. Bu debi büyük oranda yılın her mevsimi ya da ayında aynı akımı gösteremez. Yaşanılan bu değişim akarsuyun rejimini oluşturmaktadır. Akarsu rejimi temel olarak havzanın yağış miktarına göre değişkenlik göstermektedir. Yıl içinde değişen bu rejim yağış, sıcaklık, zemin tipi, havza morfolojisi ve buharlaşma gibi birçok parametreye bağlıdır. Doğal akış içerisinde bulunan rastgele parametrelerin etkisiyle akım doğrusal değildir ve dinamik davranış sergilemektedir [1]. Akarsu akışlarının öngörülmesi; havzada oluşabilecek taşkın, sel ve kuraklık durumlarında kullanılacak sel riski yönetim planları, alınabilecek önlemler, tahmin ve uyarı sistemleri, can ve mal kayıplarının öngörülebilmesi açısından havza tahliyesi ya da kuraklık durumunda gerekli su temini açısından oldukça önemli bir konudur [2]. Dünya'da küresel çapta iklim değişikliği sonucu olarak yine küresel çapta yağış rejimi değişikliği yaşanmaktadır. Ani yağışlar ve sıcaklık değişimleri sonucu eriyen karların oluşturabileceği taşkın ve sel sonucunda can ve mal güvenliğimiz için havza ve taşkın yönetimi oldukça önemlidir [3]. Akarsu akımının bilinmesi su kaynaklarının ve yapılarının doğru tasarımı ve ekonomik olarak doğru değerlendirilmesi açısından son derece önem taşımaktadır ve son yıllarda öne çıkan bir konu olmuştur. Ancak hidrolojik olaylar birçok parametreye bağlıdır ve çoğu zaman öngörülmesi oldukça zor bir konudur. Literatüre bakıldığında birçok parametreye ve doğal akışa bağlı olan hidrolojik olayların (buharlaşma, rüzgâr, yağış, akım vb.) tahmin ve modelleme çalışmalarında kapalı kutu ve makine öğrenmesi yöntemlerinin kullanıldığı görülmektedir. Detaylı bilgi için çalışmalar incelenebilir [4]–[6]. Akarsu akımının da genellikle makine öğrenmesi ve kapalı kutu yöntemleriyle kabul edilebilir ölçekte sonuçlar verdiğini görürüz [7]. Son yıllarda hayatımızın her alanında sürekli gelişen farklı makine öğrenmesi yöntemlerinin hidrolojik problemlerdeki çözümlerindeki başarısının karşılaştırılması bu çalışmanın amacını oluşturmaktadır.

Makine öğrenmesi, insan beyninin öğrenme şeklini taklit ederek, veri ve algoritmaları kullanarak, doğruluğunu tecrübelerle artıran bir yapay zekâ sistemidir [8]. İlk olarak uzman dama oyuncusu Robert Nailey'in bilgisayara karşı dama oynayarak kaybetmesi örneği ile hayatımıza girmiştir [9]. Makine öğrenmesi kullanılan veri dahilinde istatistiksel yöntemler, çeşitli algoritmalar ve tahminler ile içgüdüsel olarak eğitilir. Bu eğitim sonucunda da test yapılmak istenen verinin tahminsel modeli öğrenilen eğitim içgüdüsel sonucunda ortaya koyulmaktadır.


Derin öğrenme, verilere dayalı olarak insan beyninin tecrübe özelliğini temel alan ve yapay sinir ağı kullanan makine öğrenmesi sistemidir. Dijital sistemler, örneklerden faydalanarak davranışsal bir eğitim sürecinden geçerek tecrübeye dayalı bir öğrenim tamamlar ve ardından bu bilgileri kullanarak insanlar gibi tepki verir, davranış gösterir ve performans sergiler. Kısaca, derin öğrenme; makine öğrenmesinin yapay sinir ağı kullanılan halidir [10].

Makine öğrenmesi; bilgisayara verilen veri veya bilginin kendi içerisindeki kalıp veya fonksiyonları algılayabilen ve buna göre problemlere çözüm üretmeyi temel alan algoritma sistemleridir. Bu algoritmalar; içerisinde en az bir katmanlı YSA barındıran makine öğrenmesi sistemlerine ise derin öğrenme sistemleri adı verilmektedir. Aralarındaki temel fark bu şekilde ayırt edilebilir.

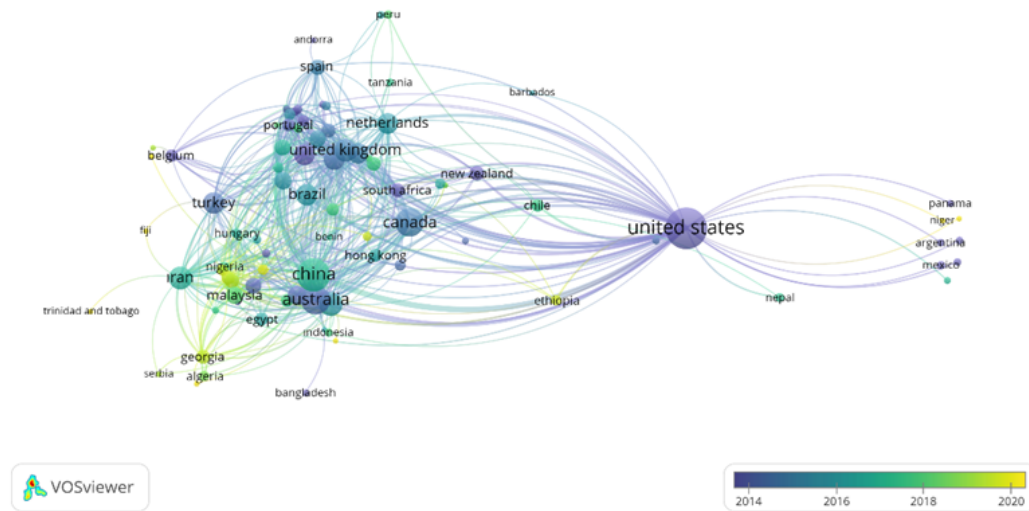
YSA'lar öğrenme işlemlerini örnekler yardımı ile gerçekleştiren, insanların tecrübe ederek öğrenme mekanizmasının makineye aktarılmış hali olarak tanımlanabilir. Bu öğrenme mekanizması, bilinenden farklı olarak ortama uyum sağlama, adapte olabilme, belirsizlik anında geçmiş tecrübeler veya eksik bilgilere göre çalışabilme yeteneğini kullanarak hesaplama özelliğini bilgisayara kazandırmaktadır [11].

Akım modellemesi ile ilgili literatürde yer alan bazı önemli çalışmalar incelendiğinde; Dibike ve arkadaşları 2001 yılındaki çalışmaları ile nehir sistemlerinin tasarımları, işletimi ve nehir akışlarının verilerini elde etmek için kullanılacak yağış-akış modellemesini YSA yöntemleriyle uygulamaya başlayanlardandır. YSA girdi ve çıktılar arasındaki doğrusal olmayan karmaşık yapıya sahip en başarılı makine öğrenme tekniği olarak görülmüştür. Çalışmada Çok Katmanlı YSA (ÇKYSA), Radyal Tabanlı YSA (RTYSA) ve Genelleştirilmiş YSA (GRYSA) kullanılarak modelleme yapılmıştır. Sonuçlar karşılaştırıldığında, YSA yöntemlerinin başarılı sonuçlar verdiği gözlemlenmiştir [12]. Hu ve arkadaşlarının 2009 yılındaki araştırmalarında YSA'ya dayalı yağış akış modelinin kullanılan, Back Propagation ağına kıyasla üç geliştirmenin yapıldığı, yağış sürecinin modellenmesi için değiştirilmiş

Şekil 1’de yer alan literatür çalışmalarının anahtar kelimeleri incelendiğinde, streamflow (akım) ve forecasting (tahmin) terimlerinin birbirleriyle ve son yıllarda iklim değişikliği, yapay zekâ ve makine öğrenmesi teknikleriyle oldukça ilişkili olduğu görülmektedir. Şekil 2 ise 2012-2018 yılları arasında ortak yayınlarda buluşan araştırmacıların isimlerini göstermektedir. Ayrıca kabarcık büyüklükleri araştırmacıların yayın sayısına göre oluşturulmuştur. Örneğin Wang Q. J.’nin toplam 54 adet çalışması bulunmaktadır.



Şekil 2. Akarsu akım çalışmalarını gerçekleştiren araştırmacıların dağılımı (Distribution of researchers who carried out stream flow studies)



Şekil 3. Akarsu akımı çalışmalarının ülkelere göre dağılımı (Distribution of stream flow studies by country)

Şekil 3’te yer alan ülkelerin dağılımı incelendiğinde, Amerika Birleşik Devletleri’nin en fazla (715) çalışmanın yapıldığı ülke olduğu görülmektedir. Ardından Çin (336), Avustralya (224), Kanada (198), Hindistan (105) ve Birleşik Krallık (103) gelmektedir. Türkiye’de ise 2014-2020 yılları arasında 79 adet çalışmanın yapıldığı tespit edilmiştir.

Bu çalışmada, Mersin Lamas (Limonlu) Nehri’nin 1967-2020 yılları arasındaki aylık akım verileri kullanılarak, Yapay Sinir Ağları (YSA) Destek Vektör Makineleri (DVM), ve Derin öğrenme (DÖ) yöntemlerinin farklı algoritma ve optimizasyonlarıyla modeller oluşturulup sonuçların karşılaştırılması yapılmıştır. Çalışmada aylık verilerin en eski %80’lik kısmı eğitim, en güncel %20’lik kısmı ise test aşamalarında kullanılmıştır. 2. Bölümde materyal ve yöntem detayları, 3. Bölümde uygulama ardından son bölümde ise çalışmanın nihai sonucu yer almaktadır.

2. Materyal ve Metot (Material and Method)

2.1. Materyal (Material)

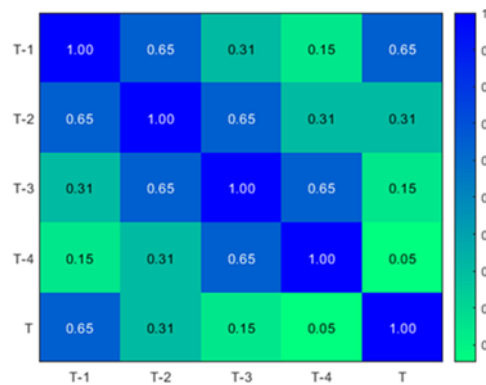
Çalışmada 1967 yılının Ekim ayından itibaren 2020 yılının Eylül ayına kadar 54 su yılının aylık akım verisi kullanılmıştır. Veriler Devlet Su İşleri Genel Müdürlüğünden temin edilmiştir [16]. Verilerin en eski %80'lik kısmı eğitim aşamasında, en güncel %20 verisi ise test aşamasında kullanılmıştır. Verilerin istatistiki bilgileri Tablo 1'de yer almaktadır. Buna göre T gözlenen akışı ve tahmin verisini, T-1; 1 aylık, T-2; 2 aylık, T-3; 3 aylık, T-4 ise 4 aylık geçmişe ötelemeyi ve giriş sıralamasını temsil eder. Veri setinin eğitim ve test olarak ayrı ayrı tanımlayıcı istatistiki bilgileri Tablo 2'de verilmiştir. Literatür çalışmaları incelendiğinde %80-%20 örnekleri olduğu görülür, detaylı bilgi için çalışma incelenebilir [17]. Ayrıca Şekil 4'te girişler arasındaki korelasyon grafiği verilmiştir.

Tablo 1. Verilerin tanımlayıcı istatistiki bilgileri (Descriptive statistical information of the data)

Kriter/Sütun	T-1	T-2	T-3	T-4	T
Ortalama	5.124	5.125	5.121	5.117	5.122
Standart Hata	0.177	0.177	0.177	0.177	0.177
Ortanca	3.685	3.685	3.685	3.680	3.685
Standart Sapma	4.492	4.492	4.492	4.492	4.492
Basıklık	11.757	11.757	11.769	11.776	11.764
Çarpıklık	3.025	3.025	3.028	3.030	3.027
Aralık	33.546	33.546	33.546	33.546	33.546
En Büyük	0.854	0.854	0.854	0.854	0.854
En Küçük	34.400	34.400	34.400	34.400	34.400
Toplam	3300.162	3300.492	3297.702	3295.152	3298.642
Veri sayısı	644	644	644	644	644

Tablo 2. Eğitim ve test setinin istatistiki bilgileri (Statistical information of the training and test set)

Kriterler	Eğitim Verileri	Test Verileri
Ortalama	5.288	4.557
Standart Hata	0.197	0.412
Ortanca	3.930	2.890
Standart Sapma	4.459	4.623
Basıklık	12.598	9.451
Çarpıklık	3.098	2.892
Aralık	33.546	27.730
En Büyük	0.854	0.871
En Küçük	34.400	28.601
Toplam	2717.873	574.189
Veri Sayısı	514	126



Şekil 4. Verilerin korelasyon matrisi (Correlation matrix of data)


Şekil 4'te T anı ile T-n ayları arasındaki korelasyon değerleri renklendirilerek verilmiştir. Grafikte T-1'den T-4'e gidildikçe korelasyon katsayısının azaldığı gözlemlenmiştir. T-4'te sıfıra oldukça yaklaşıldığı için bu aydan geriye gidilmemiştir (son satır). Bu nedenle 4. girişe kadar modeller geliştirilmiştir.

2.1.1. Çalışma alanı (Work space)

Mersin, Adana'nın batısında, Karaman'ın güneydoğusunda, Niğde'nin güneybatısında, Konya'nın güneyinde ve Antalya'nın doğusunda yer almaktadır. Yüz ölçümü 15.853 km²'dir. Akdeniz havzasında

bulunur. Mersin ili, güneyde Akdeniz Anadolu'nun iç kesimlerinden yüksek Batı ve Orta Torosların yaylaları ve zirveleri Kuzeyden gelen dağlar ile çevrilidir [18-19].

Lamas Çayı olarak bilinen, Limonlu Çayı, Toroslardan kaynağını alan, Mersin ili sınırlarında bulunmaktadır. Karaaydin yöresinde Yüçlük Dağından kaynağını alır, Aksıfat Deresi ile birleşir Limonlu'da Akdenizi dökülür. Halk arasındaki adı Lamas Çayı'dır. Akarsu 1500 km² büyüklüğündeki alanın sularını toplar, uzunluğu 130 km'dir. Evdirek, Susma ve Akçay önemli kollarıdır. Kar erimelerinin yanında karstik kaynaklarda akarsuyu besler. Yıllık ortalama debisi 6,25 m³/s'dir [20].



Şekil 5. Çalışma alanı Mersin Lamas (Limonlu) Nehri (The study area is Mersin Lamas (Limonlu) River) [21]

Limonlu Çayı Havzası toprak özellikleri bakımından Akdeniz iklimi etkisini yansıtmaktadır. Saha içerisinde en geniş yayılışa sahip toprak zonal toprak grubunda yer alan Kırmızı Akdeniz Toprağı (Terra Rossa) dır [21]. Bu çalışma alanının seçilmesinde en büyük etken nehirde meydana gelen taşkınlardır. Geçmiş yıllarda Mersin Lamas nehrinde birçok taşkın meydana gelmiş ve bu taşkınlarda maddi-manevi kayıplar yaşanmıştır [3]. Bu nedenle nehir verilerinin tahmini ve takibi önem arz etmektedir.

2.2. Metot (Method)

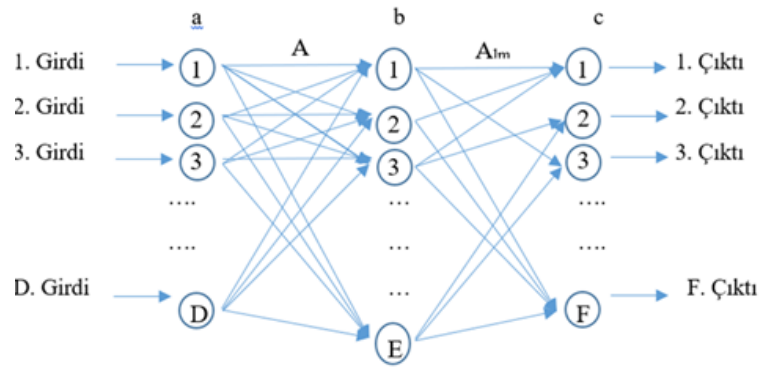
Bu çalışmada 3 farklı YSA yöntemi (ÇKYSA, RTYSA, GRYSA), 3 farklı DVM eğitim fonksiyonu (Polynomial, Gaussian ve Linear) ve 3 farklı DÖ optimizasyon algoritması; Adaptive Moment Estimation (Adam), Stochastic Gradient Descent With Momentum (SGDM) ve Root Mean Square Propagation (RMSProp) karşılaştırılmıştır.

2.2.1. Çok Katmanlı YSA (Multilayered ANN)

En yaygın kullanılan YSA modellerinden biri olan ÇKYSA, bir girdi katmanı, en az bir hücreli ara katman ve bir çıktı katmanından oluşur. Girdi katmanı, çözülecek problemi YSA'ya dahil edilmesini sağlar. Çıktı katmanı, işlenen bilgilerin ağda dışa aktarıldığı katmandır. İki katman arasında gizli katman bulunabilir. Tüm girdileri ve ağırlıkları çarparak toplayıp fonksiyondan geçirerek o nöronun çıktı değeri hesaplanır. ÇKYSA modelinde bilgi akışı ileri yönde gerçekleştiği için ileri beslemelidir. Hata minimum olana kadar geriye doğru yayılır. Sayısal optimizasyon yöntemlerini kullanan ve çözümlerde hızlı yakınsama sağlayan bu klasik algoritmaların yanı sıra Levenberg-Marquardt algoritmaları da sıklıkla tercih edilir hale gelmiştir [22]. Levenberg-Marquardt algoritması hakkında daha detaylı bilgiyi burada bulabilirsiniz [23].

Şekil 6'da b ve c tabakalarındaki her bir hücre, önceki tabakadan NET ağırlıklı toplam çıktıları girdi olarak almaktadır. NET değerleri Denklem 1'de eşitlikle bulunmaktadır.

$$NET_{xb} = \sum_{a=1}^D A_{ab} C_{xa} + \theta_b \quad (1)$$



Şekil 6. Üç Tabakalı/Katmanlı (a, b, c tabakaları) bir YSA yapısı (An ANN structure with three layers/layers (layers a, b, c)) [24]

θ_b taraflılık sabiti (bias), A_{ab} a ve b tabakaları arasındaki ağırlıklar kümesi, D girdi vektörünün boyutu, ζ_{xa} x örneği için a tabakasının çıktı kümesidir. İkinci tabaka olan b ve üçüncü tabaka c' den her bir hücre, NET değerini doğrusal olmayan bir tasnif fonksiyonundan geçirir. Bunun sonucunda Denklem 2'de $f(NET)$ çıktısı üretilir. Ardından hata ve gerçek çıktı değerleri hesaplanır.

$$f(NET) = \frac{1}{1+e^{-NET}} \quad (2)$$

2.2.2. Radyal tabanlı YSA (Radial based ANN)

Radyal Tabanlı YSA (RTYSA) kavramı literatüre 1988 yılında Broomhead ve Lave tarafından getirilmiştir. İnsanlarda görülen sinir sistemindeki nöron hücrelerinin temel alındığı bir YSA modelidir. Etki-tepki durumları dikkate alınarak geliştirilmiştir. RTYSA modelleri, eğitimlerini çok boyutlu uzayın bir boyutu olarak düşünülebilir. Bunu bir eğri uydurma yaklaşımı olarak görmek mümkündür [22], [25-26]. Böylelikle RTYSA örneğinin eğitim performansı, çıktı vektör uzayındaki verilere en yakın sonucu bulma ve dolayısıyla bir interpolasyon problemine dönüşmektedir [22]. RTYSA yapısı genel olarak YSA yapısına benzer şekilde giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Fakat diğer YSA'lardan farklı olarak girdi katmanından gizli katmana geçerken veriler radyal tabanlı aktivasyon fonksiyonlarına ve doğrusal olmayan bir küme analizine maruz kalmaktadır. Gizli katmanla çıktı katmanı arasındaki yapı diğer YSA tiplerinde olduğu gibi işler ve asıl eğitim bu katmanda gerçekleşir.

2.2.3. Genelleştirilmiş YSA (Generalized ANN)

Specht (1991) tarafından önerilen genelleştirilmiş regresyon sinir ağı geri yayılım yöntemindeki gibi yinelemeli bir eğitim prosedürü gerektirmez [27]. GRYSA, eğitim verisini kullanarak girdi ve çıktı vektörleri arasındaki herhangi bir fonksiyonu tahmin etmektedir. Eğitim seti genişledikçe tahmin hatası sifra iner [28]. Tanım olarak bilindiği gibi regresyon, "x" ve eğitim seti verildiğinde bir "y" bağımlı değişkeninin en olası değerini bağımsız "x" değişkenine bağlı olarak tahmin eder. Regresyon metodu ortak kare hatasını en aza indirecek şekilde "y" yi tahmin eder. GRYSA, bir eğitim seti verildiğinde "x" ve "y" nin ortak Olasılık Yoğunluk Fonksiyonunu (OYF) tahmin eden bir metottur. OYF veriden bir ön kabul yapılmadan elde edildiği için sistem genel olarak idealdir [28].

2.2.4. Destek vektör makineleri (Support vector machines)

Destek vektör makineleri (DVM); lineer ve non-lineer karmaşık problemlerin ilişkisini makine öğrenimi yoluyla yakalayabilen, güçlü bir yöntemdir. Regresyon problemlerinin çözümünde de kullanılmaktadır. Yöntem temel olarak iki farklı sınıfla Lagrange çarpanlarına göre ayıran optimum ayırıcıyı bulmayı amaçlayan ve bu amaçla örnek verileri (eğitim seti) kullanan bir tekniktir. DVM genellikle doğrusal olmayan ilişkiyi tanımlamak için uygundur [2], [29-30].


$$l(x) = v^T x + y = 0 \quad (3)$$

Burada (x_1, \dots, x_n) hedef veri seti, v normal vektör ve y eşik değeridir. Hiper düzlemden başlayarak, $s_i \in (-1, +1)$ ile dikkate alınan bir veri, $v^T x_i + y \geq +1$ ise sınıf 1'dir ve $v^T x_i + y \leq -1$ ise sınıf 2'dir yi ($v^T x_i + b$) ≥ 1 i=1.....n. [29]. Hedef veriler doğrusal olarak ayrılamiyorsa, doğrusal olmayan DVM kullanılır. Bu

durumda eğitim verileri, birbirinden ayrılabilir daha yüksek uzayda haritalanır. SVMR modelinin yapısal konfigürasyonu Şekil 7'de gösterilmiştir. DVMR regresyon fonksiyonunun özeti aşağıdaki gibidir [31].

$$f(x) = w \times \phi(x) + b \quad (4)$$

Denklemden w ağırlık vektörü, b sapma ve ϕ transfer fonksiyonudur.



Şekil 7. Destek vektör makineleri şeması. (Schematic of support vector machines.)

2.2.5. Derin öğrenme ve LSTM mimarisi (Deep learning and LSTM architecture)

Derin Öğrenme, makine öğrenmesinin bir sonraki adımı olarak görülebilir, yapay zekâ ve görüntü işleme hayatımızın birçok alanında yaygın olarak kullanılmaktadır. Bu tür algoritmalar otomatikleştirilmiş bir model oluşturarak daha genelleştirilmiş bir model sağlama özellikleri vardır. İçerisinde çeşitli optimizasyonlar kullanılabilir. Bu çalışmada LSTM derin öğrenme mimarisine ait 'Adam', 'RMSProp' ve 'SGDM' optimizasyonları kullanılmıştır [7].

LSTM; Tekrarlayan Yapay Sinir Ağlarının (RNN) zayıf yanlarının revize edilerek geliştirilmiş versiyonu olarak tanımlanabilmektedir. RNN'lerin çalışma durumu bilgiyi LSTM mimarisine göre daha kısa süre saklayabilmesidir. LSTM bu yönüyle RNN'in gelişmiş halidir. Hücrelerin etkileşim sayısını artırarak bunu yapmıştır. LSTM öğrenilen bilgiyi uzun bir süre muhafaza ederek çalışır bu sebeple uzun süreli öğrenimler-tahminler konusunda başarı gösterdiği görülür. Genel olarak 4 hücreden meydana gelir. Bunlar giriş, çıkış ve unutma kapılarıdır. Bu unutma kapıları sayesinde bilgiler tek bir dosya ile uzun süreli olarak hatırlanır [10], [30], [32].

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (5)$$


$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (6)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (7)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (8)$$

$$C_t = f_t \otimes C_{t-1} + i_{t-1} \otimes \tilde{C}_t \quad (9)$$

$$h_t = o_t \otimes \tanh(C_{t-1}) \quad (10)$$



Şekil 8. LSTM mimarisi genel çalışma diyagramı (LSTM architecture general working diagram)

i_t , f_t ve o_t sırasıyla giriş kapısı, unutma kapısı ve çıkış kapısıdır; W_i , W_f ve W_o sırasıyla giriş, unutma ve çıkış kapılarını girişe bağlayan ağırlıkları gösterir; U_i , U_f ve U_o giriş, unutma ve çıkış kapılarından gizlenene kadar olan ağırlıkları temsil eder. Sırasıyla katman; b_i , b_f ve b_o giriş, unutma ve çıkış kapısı sapma vektörlerini belirtir, sırasıyla; t hücrenin önceki andaki durumudur; C_t hücrenin mevcut durumudur; h_{t-1} hücrenin önceki zaman noktasındaki çıktısını ifade eder; h_t , hücrenin çıktısını ifade eder [33].

Adam algoritması için denklemler aşağıdaki gibidir;

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (11)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (12)$$

$$m'_t = \frac{m_t}{1 - \beta_1^t}, v'_t = \frac{v_t}{1 - \beta_2^t} \quad (13)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v'_t + \epsilon}} m'_t \quad (14)$$

RMSProp algoritması için denklemler aşağıdaki gibidir;

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2 \quad (15)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (16)$$

$$g_t = \nabla_{\theta} J(\theta_t) \quad (17)$$

SGDM algoritması için denklemler aşağıdaki gibidir;

$$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J \quad (18)$$

$$\theta_{t+1} = \theta_t - v_{t+1} \quad (19)$$

$\theta \in \mathbb{R}^d$: Model parametreleri; η : Öğrenme katsayısı; $\nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$: Parametrelere bağlı olarak hedef fonksiyonunun eğimi; $g_{t,i}$: her bir köşegen elemanı, θ_i parametresine göre, t iterasyona kadar hesaplanmış eğim değerlerinin kareleri toplamı; ϵ : öğrenme katsayısının 0'a bölünmesini engellemek için atanan sabit değer [34].

3. Uygulama (Application)

Karşılaştırma kriteri olarak Karekök Ortalama Karesel Hata (KOKH), Ortalama Mutlak Hata (OMH), Nash Sutcliffe modeli verimlilik katsayısı (NSE), Ortalama Mutlak Bağıl Hata (OMBH), ve determinasyon katsayısı (R^2) kullanılmıştır. Karşılaştırma kriterlerinin formülleri Denklem 20-24' te verilmiştir.

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_p - Y_o)^2} \quad (20)$$

$$OMH = \frac{1}{N} \sum_{i=1}^N |Y_p - Y_o| \quad (21)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Y_o - Y_p)^2}{\sum_{i=1}^N (Y_o - Y_{avr})^2} \quad (22)$$

$$OMBH = \frac{1}{N} \left(\frac{\sum_{i=1}^N |Y_p - Y_o|}{Y_o} * 100 \right) \quad (23)$$

$$R^2 = \left(\frac{N * (\sum Y_o * Y_p) - (\sum Y_o) * (\sum Y_p)}{\sqrt{(N * \sum Y_o^2) - (\sum Y_o)^2 * (N * \sum Y_p^2) - (\sum Y_p)^2}} \right)^2 \quad (24)$$

Denklemlerde kullanılan N veri sayısı, Y_p modelde tahmin edilen akım değeri, Y_o gerçekte gözlenen akım değerini, Y_{avr} ise akım ortalamasını temsil etmektedir. Bu çalışmada kullanılan veriler Lamas nehri akım verileridir. Dolayısıyla birimler m^3/sn cinsindedir. Karşılaştırma kriterlerimizden Karekök ortalama karesel hata, Ortalama mutlak hata ve Ortalama mutlak bağıl hata; bkzn. Denklem (20-21-23) hata sonuçları olduğundan modeldeki hata sonuçlarının birimleri de aynı şekilde m^3/sn 'dir. Hata sonuçlarının yüksek olması modelin gerçek veriye göre uzakta yani kötü sonuç verdiğini anlatır. Düşük olması ise modelin gerçek veriye göre yakın, hatası düşük ve modelin uygun olduğunu göstergesidir. NSE verimlilik katsayısına baktığımızda 1'e yaklaştıkça modelin gerçeğe yakın tahmin sonucunun iyi olduğu gözlemlenir. Ancak (-) ve 1'den uzak sonuçlarda modelin güzel tahmin yapamadığı ve gerçekten uzak sonuçlar olduğu gözlemlenir. R^2 determinasyon katsayısı 0 – 1 arasında değer alabilmektedir. 1'e yaklaştıkça modelin gerçeğe uyumluluğu ve doğruluğu artar şeklinde yorumlanır.

Tablo 3'te 3 farklı YSA modelinin tahmin sonuçlarının karşılaştırılmasını göstermektedir. Test sonuçlarına bakıldığında ÇKYSA yönteminin 2 girişli modeli en iyi determinasyon katsayısını ve düşük hata oranını vermektedir. Aşağıda verilen tüm tablolarda renklendirme işlemi hatalarda en düşükler kırmızı, NSE ve R^2 'de 1'e en yakınlar kırmızı tonunda renklendirilmiştir. Bu renklendirmeye göre en kırmızı modeller en iyi model olarak seçilebilir.

Tablo 4'te Derin öğrenme yönteminin 3 farklı algoritmasının tahmin sonuçlarının karşılaştırılması gösterilmiştir. Sonuçlara bakıldığında Adam, RMSProp ve SGDM algoritmalarının modellerinin birbirine yakın ve kabul edilebilir sonuçlar verdiği, YSA modellerine göre daha başarılı olduğu gözlemlenir.

Tablo 5'te Vektör destek makinelerinin 3 farklı optimizasyonla akım modellemesi sonuçları gösterilmektedir. Sonuçlar incelendiğinde Polynomial algoritmasının 2 giriş sonucu en iyi sonucu verdiği gözlemlenir.

Tablo 3. YSA modeli eğitim ve test sonuçları (ANN model training and test results)

Yöntem	Algoritma	Değerlendirme Kriteri	Eğitim Aşaması				Test Aşaması				
			1 Giriş	2 Giriş	3 Giriş	4 Giriş	1 Giriş	2 Giriş	3 Giriş	4 Giriş	
YAPAY SİNİR AĞLARI	GRYSA	KOKH	3.065	1.202	0.203	0.057	3.316	3.872	5.110	4.229	
			ÇKYSA	2.821	2.927	2.013	2.011	3.349	2.607	4.362	3.815
				RTYSA	3.069	2.841	2.626	2.698	3.292	3.272	3.283
	GRYSA	OMH	1.800	0.759	0.080	0.007	2.028	2.117	2.664	2.347	
			ÇKYSA	1.512	1.507	1.077	1.067	1.780	1.508	1.998	1.867
				RTYSA	1.623	1.441	1.486	1.513	1.807	1.610	1.765
	GRYSA	NSE	0.527	0.927	0.998	1.000	0.481	0.293	-0.232	0.156	
			ÇKYSA	0.599	0.568	0.796	0.796	0.471	0.679	0.103	0.313
				RTYSA	0.526	0.593	0.653	0.633	0.489	0.495	0.492
	GRYSA	OMBH	35.857	17.627	2.159	0.218	52.523	46.114	58.267	49.001	
			ÇKYSA	27.135	26.779	21.649	20.784	35.347	34.480	43.272	35.558
				RTYSA	28.340	25.333	27.851	28.729	37.573	30.747	36.049
GRYSA	R^2	0.536	0.929	0.998	1.000	0.485	0.361	0.078	0.213		
		ÇKYSA	0.599	0.568	0.796	0.796	0.473	0.680	0.220	0.346	
			RTYSA	0.526	0.593	0.653	0.633	0.491	0.499	0.505	0.584

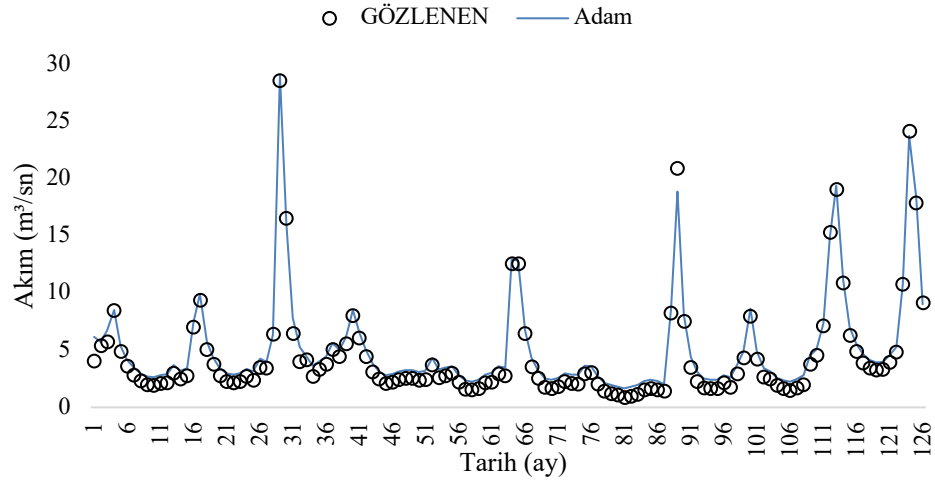
Tablo 4. Derin öğrenme modeli eğitim ve test sonuçları (Deep learning model training and test results)

Yöntem	Algoritma	Değerlendirme Kriteri	Eğitim Aşaması				Test Aşaması			
			1 Giriş	2 Giriş	3 Giriş	4 Giriş	1 Giriş	2 Giriş	3 Giriş	4 Giriş
DERİN ÖĞRENME (DEEP LEARNING)	ADAM	KOKH	0.169	0.332	0.214	0.303	0.708	0.690	0.696	0.774
	RMSPROP		0.075	0.243	0.120	0.185	0.765	0.770	0.781	0.863
	SGDM		0.184	0.138	0.147	0.366	0.812	0.778	0.749	0.574
	ADAM	OMH	0.128	0.275	0.183	0.181	0.656	0.613	0.626	0.713
	RMSPROP		0.054	0.202	0.090	0.139	0.737	0.674	0.753	0.730
	SGDM		0.109	0.092	0.096	0.310	0.751	0.733	0.712	19.888
	ADAM	NSE	0.999	0.994	0.998	0.995	0.976	0.978	0.977	0.972
	RMSPROP		1.000	0.997	0.999	0.998	0.972	0.972	0.971	0.965
	SGDM		0.998	0.999	0.999	0.993	0.969	0.972	0.974	0.985
	ADAM	OMBH	2.742	7.460	5.150	3.052	25.264	20.843	22.509	27.044
	RMSPROP		1.259	5.174	2.181	2.879	27.933	23.190	27.728	26.051
	SGDM		2.399	2.107	2.123	7.157	27.529	27.554	27.266	0.519
ADAM	R ²	0.999	0.997	0.999	0.999	0.996	0.994	0.993	0.994	
RMSPROP		1.000	0.999	0.999	0.999	0.996	0.987	0.995	0.987	
SGDM		0.998	0.999	0.999	0.998	0.994	0.995	0.996	0.995	


Tablo 5. Destek vektör makineleri modeli eğitim ve test sonuçları (Support vector machines model training and test results)

Yöntem	Algoritma	Değerlendirme Kriteri	Girişler (Eğitim)				Girişler (Test)			
			1 Giriş	2 Giriş	3 Giriş	4 Giriş	1 Giriş	2 Giriş	3 Giriş	4 Giriş
DESTEK VEKTÖR MAKİNE LERİ (SVM)	GAUSSIAN	KOKH	23.671	3.255	3.038	2.871	3.562	3.381	3.522	3.314
	LINEAR		3.457	3.456	3.441	3.446	3.633	3.597	3.575	3.579
	POLYNOMIAL		3.315	4.196	4.341	2.685	3.410	3.945	3.396	3.322
	GAUSSIAN	OMH	1.490	1.339	1.145	1.127	1.987	1.842	1.893	1.825
	LINEAR		1.813	1.782	1.782	1.779	2.146	2.092	2.076	2.076
	POLYNOMIAL		1.687	3.161	2.431	1.429	2.102	3.554	1.877	1.777
	GAUSSIAN	NSE	0.470	0.466	0.535	0.585	0.402	0.461	0.415	0.482
	LINEAR		0.398	0.398	0.403	0.402	0.377	0.390	0.397	0.396
	POLYNOMIAL		0.446	0.113	0.050	0.637	0.451	0.266	0.456	0.479
	GAUSSIAN	OMBH	23.671	20.460	16.741	17.058	50.233	44.814	46.531	45.281
	LINEAR		30.028	29.818	29.500	29.481	53.559	52.563	51.735	51.701
	POLYNOMIAL		27.728	82.567	47.486	25.265	55.779	129.580	35.717	38.131
GAUSSIAN	R ²	0.518	0.507	0.597	0.636	0.435	0.518	0.453	0.532	
LINEAR		0.420	0.433	0.433	0.434	0.400	0.427	0.426	0.428	
POLYNOMIAL		0.496	0.317	0.409	0.655	0.511	0.681	0.503	0.490	

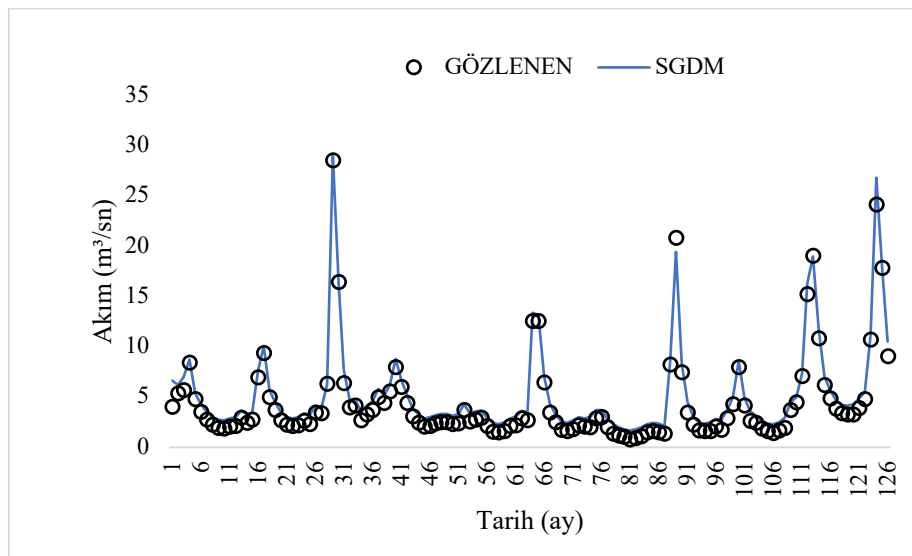
Tablolarda görüldüğü gibi en iyi model veren yöntem DÖ'dür. DÖ yöntemi için 3 farklı optimizasyonun tahmin ve gözlenen akım değerlerinin gidiş grafikleri aşağıdaki gibidir.



Şekil 9. DÖ yöntemi Adam optimizasyonu test sonuçları gidiş grafiği (DL method Adam optimization test results trend graph)



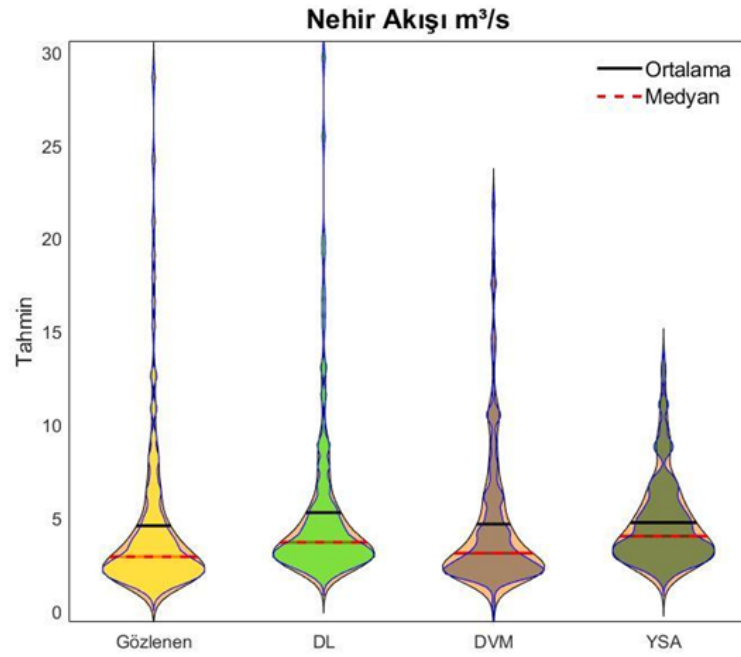
Şekil 10. DÖ yöntemi RMSProp optimizasyonu test sonuçları gidiş grafiği (DL method RMSProp optimization test results trend graph)



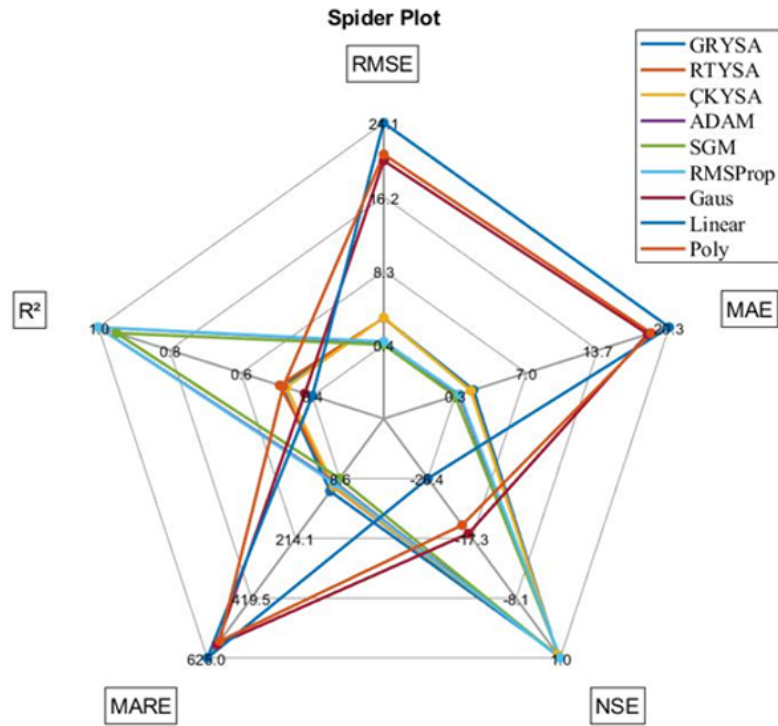
Şekil 11. DÖ yöntemi SGDM optimizasyonu test sonuçları gidiş grafiği (DL method SGDM optimization test results trend graph)

Şekil 9, 10 ve 11’de Derin öğrenme yönteminin 3 farklı optimizasyonunun test sonuçları ve gözlenen akım değerleri ile gidiş grafiği verilmiştir. Grafiklerde tahmin değerlerinin gerçek değerleri piklerde ve minimum noktalarda yakaladığı modellerin oldukça başarılı olduğu gözlemlenmiştir.

Şekil 12’de yer alan Violin grafiği, tahminlerin gözlenen değer ile yorumlanma gücünü istatistiksel parametrelerle çizilmiş şekillerle ifade etmektedir [35]–[37]. Bu açıdan Şekil 12 incelendiğinde DÖ yönteminin YSA ve DVM yöntemlerine göre gözlenen değerleri daha iyi ifade ettiği tespit edilmiştir. Gözlenen veriye en yakın diyagramın DÖ yönteminin verdiği görülmüştür. DVM ve YSA kıyaslamasında DVM daha iyi sonuç vermiştir ancak ikisi de ortalamalara bakıldığında daha uzak sonuçlar vermiştir. Yapay zekâ kullanımında önce YSA sonra DVM sonra teknoloji ilerledikçe DÖ ile gözlenen değerlere daha da yaklaşıldığı sonucu çıkarılır.



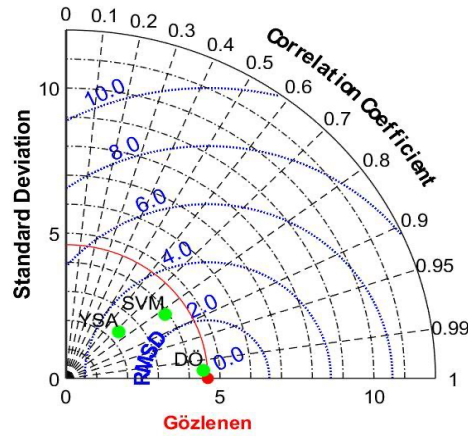
Şekil 12. Sonuçların Violin diyagramı (Violin diagram of results)



Şekil 13. Tüm yöntemlerin 1 giriş için sonuçların Spider grafiği (Spider graph of results for 1 input of all methods)

Şekil 13'te tüm yöntemlerin 1 giriş için karşılaştırma kriterlerinin Spider diyagramı olarak verilmiştir. Çizgilerin renklerine bakıldığında DÖ optimizasyonlarının diğerlerine göre R²'si yüksek hata miktarları düşük olarak gözlemlenmektedir.

Şekil 14'te yöntemlerin en iyi sonuç veren modellerinin korelasyon katsayılarının grafiği Taylor diyagramı şeklinde verilmiştir. RMSProp modelinin en yüksek korelasyon katsayısı ile model sonucu verdiği gözlemlenmiştir. Ayrıca RMSProp'un gözlenen değere en yakın model olduğu görülmektedir.



Şekil 14. Tüm yöntemlerin en iyi sonuçlarının Taylor diyagramı (Taylor diagram of the best results of all methods)

4. Sonuçlar (Conclusion)

Bu çalışmada, Mersin Lamas (Limonlu) Nehri'nin 1967-2020 yılları arasındaki aylık akım verileri kullanılarak, YSA, DVM ve DÖ yöntemlerinin farklı algoritma ve optimizasyonlarıyla tahminler oluşturulup sonuçların karşılaştırılması yapılmıştır. Çalışmada aylık verilerin en eski %80'lik kısmı eğitim, en güncel %20'lik kısmı ise test aşamalarında kullanılmıştır. KOKH, OMH, NSE, OMBH, ve R^2 kullanılmıştır. Ayrıca sonuçlar Taylor, Violin ve Spider grafikleri ile yorumlanmıştır.

Sonuçlar incelendiğine;

DÖ yönteminin 3 farklı algoritmasının da birbirine yakın ve en iyi sonuçları verdiği görülmektedir. RMSProp 1 giriş sonuçları; (KOKH= 0.7647, OMH= 0.7370, NSE= 0.9724, OMBH=27.9326, $R^2= 0.9962$), Adam 1 giriş sonuçları; (KOKH= 0.7077, OMH= 0.6557, NSE= 0.9764, OMBH=25.2640, $R^2= 0.9956$), SGDM 1 giriş sonuçları; (KOKH= 0.8119, OMH= 0.7506, NSE= 0.9689, OMBH= 27.5292, $R^2= 0.9935$).

YSA ve DVM yöntemleri DÖ kötü sonuçlar vermesine rağmen kendi aralarında yakın sonuçlar vermiştir. ÇKYSA 2 giriş (KOKH= 3.3489, OMH= 1.7800, NSE= 0.4710, OMBH=35.3472, $R^2=0.4729$), Polynomial 2 giriş (KOKH= 3.9447, OMH=3.5538, NSE= 0.2660, OMBH=129.5801, $R^2=0.6809$)

Tablosal sonuçların ardından model değerleri ve gözlenen değerlerle oluşturulan Taylor ve Violin diyagramları incelendiğinde, akım modellemesinde YSA sonra DVM sonra teknoloji ilerledikçe DÖ ile gözlenen değerlere daha da yaklaşıldığı sonucu çıkarılmıştır.

Simgeler (Symbols)

Simge	Açıklama
x_1, \dots, x_n	hedef veri seti
v	normal vektör
y	eşik değeri
i_t	giriş kapısı
f_t	unutma kapısı
o_t	çıkış kapısı
W_i	giriş kapısını girişe bağlayan ağırlık
W_f	unutma kapısını girişe bağlayan ağırlık
W_o	çıkış kapısını girişe bağlayan ağırlık
U_i	giriş kapısından gizlenene kadar olan ağırlığı
U_f	unutma kapısından gizlenene kadar olan ağırlığı
U_o	çıkış kapısından gizlenene kadar olan ağırlığı
B_i	giriş kapısı sapma vektörü
b_f	unutma kapısı sapma vektörü
b_o	çıkış kapısı sapma vektörü
t	hücrenin önceki andaki durumu
C_t	hücrenin mevcut durumu
h_{t-1}	hücrenin önceki zaman noktasındaki çıktısı
h_t	hücrenin çıkışı
θ_b	tarafılık sabiti (bias)

A_{ab}	a ve b tabakaları arasındaki ağırlıklar kümesi
D	girdi vektörünün boyutu
ζ_{xa}	x örneği için a tabakasının çıktı kümesi
N	veri sayısı
Y_p	modelde tahmin edilen akım değeri
Y_o	gerçekte gözlenen akım değerini
Y_{avr}	akım ortalaması

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Makalenin yazarları arasında çıkar çatışması bulunmamaktadır.

Kaynaklar (References)

- [1] Z. M. Yaseen, A. El-shafie, O. Jaafar, H. A. Afan, and K. N. Sayl, "Artificial intelligence based models for stream-flow forecasting: 2000-2015," *J. Hydrol.*, vol. 530, pp. 829–844, November 2015. doi:10.1016/j.jhydrol.2015.10.038
- [2] F. Tosunoğlu, S. Hanay, E. Çintaş, and B. Özyer, "Monthly Streamflow Forecasting Using Machine Learning," *Erzincan Univ. J. Sci. Technol.*, vol. 13, no. 3, pp. 1242–1251, 2020. doi:10.18185/erzifbed.780477
- [3] V. Demir, A. Alptekin, M. Ö. Çelik, and M. Yakar, "2D Flood modeling with the help of GIS : Mersin / Lamas River," in *2nd Intercontinental Geoinformation Days (IGD) - 5-6 May 2021*, pp. 176–178, 2021.
- [4] H. Çitakoğlu, A. Aydemir, "Determination of Monthly Wind Speed of Kayseri Region With Gray Estimation Method," in *2019 IEEE Jordan International Joint Conference on Electrical Engineering*, pp. 415–420, 2019.
- [5] H. Citakoglu, B. Babayigit, and N. A. Haktanir, "Solar radiation prediction using multi-gene genetic programming approach," *Theor. Appl. Climatol.*, vol. 142, no. 3–4, pp. 885–897, 2020. doi:10.1007/s00704-020-03356-4
- [6] H. Çitakoğlu and Y. Özeren, "Sakarya Havzası Su Kalitesi Parametrelerinin Yapay Sinir Ağları ile Modellenmesi," *Eur. J. Sci. Technol.*, no. 24, pp. 10–17, 2021. doi:10.31590/ejosat.898046
- [7] C. Boyraz and S. N. Engin, "Streamflow prediction with deep learning," in *6th International Conference on Control Engineering and Information Technology*, pp. 25–27, 2018. doi:10.1109/CEIT.2018.8751915
- [8] S. B. Kotsiantis, I. D. Zaharakis, and P. E. Pintelas, "Machine learning: A review of classification and combining techniques," *Artif. Intell. Rev.*, vol. 26, no. 3, pp. 159–190, 2006. doi:10.1007/s10462-007-9052-3
- [9] A. L. Samuel, "Some studies in machine learning using the game of checkers," in *IBM Journal of Research and Development*, vol. 44, no. 1.2, pp. 206–226, Jan. 2000. doi:10.1147/rd.441.0206
- [10] M. Rahimzad, A. Moghaddam Nia, H. Zolfonoon, J. Soltani, A. Danandeh Mehr, and H. H. Kwon, "Performance Comparison of an LSTM-based Deep Learning Model versus Conventional Machine Learning Algorithms for Streamflow Forecasting," *Water Resour. Manag.*, vol. 35, no. 12, pp. 4167–4187, 2021. doi:10.1007/s11269-021-02937-w
- [11] E. Oztemel, *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim, 2012.
- [12] Y. B. Dibike and D. P. Solomatine, "River flow forecasting using artificial neural networks." *Physics and Chemistry of the Earth, Part B: Hydrology*, vol. 26, no. 1, pp. 1–7, 2001. doi:10.1016/S1464-1909(01)85005-X
- [13] T. S. Hu, K. C. Lam, and S. T. Ng, "A Modified Neural Network for Improving River Flow Prediction / Un Réseau de Neurones Modifié pour Améliorer la Prédiction de L'Écoulement Fluvial flow prediction," *Hydrol. Sci. J. ISSN*, vol. 50, no. 2, pp. 298–318, 2009. doi:10.1623/hysj.50.2.299.61794
- [14] M. Ren, B. Wang, Q. Liang, and G. Fu, "Classified real-time flood forecasting by coupling fuzzy clustering and neural network," *Int. J. Sediment Res.*, vol. 25, no. 2, pp. 134–148, 2011. doi:10.1016/S1001-6279(10)60033-9
- [15] M. Asaad, "Aylık Ortalama Akım Verilerinin Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi," Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2021.
- [16] DSİ, "Faaliyetler," Devlet Su İşleri, [Online]. Available: <https://www.dsi.gov.tr/Sayfa/Detay/692>. [Accessed: May. 22, 2022].
- [17] H. C. Kilinc and B. Haznedar, "A Hybrid Model for Streamflow Forecasting in the Basin of Euphrates," *Water (Switzerland)*, vol. 14, no. 1, 2022. doi:10.3390/w14010080
- [18] Enerji Atlası, "Lamas Çayı," enerjیاتlasi.com, [Online]. Available: <https://www.enerjیاتlasi.com/akarsular/lamas-cayi.html>. [Accessed: May. 22, 2022].
- [19] Wikipedia, "Limonlu Çayı," tr.wikipedia.org, Mar. 26, 2022 [Online]. Available: https://tr.wikipedia.org/wiki/Limonlu_Çayı. [Accessed: May. 22, 2022].

- [20] T.C. Orman Ve Su İşleri Bakanlığı Su Yönetimi Genel Müdürlüğü Taşkın Ve Kuraklık Yönetimi Dairesi Başkanlığı, "Doğu Akdeniz Havzası Kuraklık Yönetim Planı Nihai Rapor Özeti," Ankara, 2018.
- [21] İ. Özalp, "Limonlu (Lamas) Çayı Havzası'nın Fiziki Coğrafyası," Yüksek Lisans Tezi, Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum, 2009.
- [22] U. Okkan and H. Y. Dalkılıç, "Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi," *İMO Tek. Dergi*, vol. 23, no. 112, pp. 5957–5966, 2012.
- [23] M. A. Çavuşlu, Y. Becerikli, and C. Karakuzu, "Levenberg- Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi," *Türkiye Bilişim Vakfı Bilgi. Bilim. ve Mühendisliği Derg.*, vol. 5, no. 5, pp. 1–7, 2012.
- [24] E. A. Çubukçu, "Yıllık Anlık Maksimum Akımların, Coğrafi Veri Bileşenleri Ve Yapay Sinir Ağları İle Modellenmesi," Yüksek Lisans Tezi, Kto Karatay Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2019.
- [25] T. Partal, E. Kahya, and K. Cıgızoğlu, "Yağış Verilerinin Yapay Sinir Ağları ve Dalgacık Dönüşümü Yöntemleri ile Tahmini," *İtü Mühendislik Derg.*, vol. 7, no. 3, pp. 73–85, 2008.
- [26] T. Poggio and F. Girosi, "Regularization Algorithms for Learning That Are Equivalent to Multilayer Networks," *Science*, vol. 247, no. 4945, pp. 978–982, 1990. doi:10.1126/science.247.4945.978
- [27] A. Sürel, "Genelleştirilmiş Regresyon Yapay Sinir Ağının Su Kaynakları Mühendisliğinde Kullanımı," Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2006.
- [28] M. Alp and K. Cıgızoğlu, "Farklı Yapay Sinir Ağı Metodları ile Yağış-Akış İlişkinin Modellenmesi," *İtü Mühendislik Derg.*, vol. 3, no. 1, pp. 80–88, 2004.
- [29] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," *Proc. fifth Annu. Work. Comput. Learn. theory*, pp. 144–152, 1992. doi:10.1145/130385.130401
- [30] H. Citakoglu, "Comparison of multiple learning artificial intelligence models for estimation of long-term monthly temperatures in Turkey," *Arab. J. Geosci.*, vol. 14, no. 20, 202. doi:10.1007/s12517-021-08484-3
- [31] N. M. Eldakhly and M. Aboul-Ela, "A Novel Approach of Weighted Support Vector Machine with Applied Chance Theory for Forecasting Air Pollution Phenomenon in Egypt," *Int. J. Comput. Intell. Appl.*, vol. 17, no. 1, pp. 1–29, 2018. doi:10.1142/S1469026818500013
- [32] D. Zhang, J. Lin, Q. Peng, D. Wang, T. Yang, S. Sorooshian, ... and J. Zhuang, "Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm," *J. Hydrol.*, vol. 565, pp. 720–736, 2018. doi:10.1016/j.jhydrol.2018.08.050
- [33] M. Liu, Y. Huang, Z. Li, B. Tong, Z. Liu, M. Sun, ... and H. Zhang, "The applicability of lstm-knn model for real-time flood forecasting in different climate zones in China," *Water (Switzerland)*, vol. 12, no. 2, pp. 1–21, 2020. doi:10.3390/w12020440
- [34] G. Ser and C. T. Bati, "Determining the best model with deep neural networks: Keras application on mushroom data," *Yuz. Yil Univ. J. Agric. Sci.*, vol. 29, no. 3, pp. 406–417, 2019. doi:10.29133/yutbd.505086
- [35] J. L. Hintze and R. D. Nelson, "Violin plots: A box plot-density trace synergism," *Am. Stat.*, vol. 52, no. 2, pp. 181–184, 1998. doi:10.1080/00031305.1998.10480559
- [36] K. E. Taylor, "Summarizing multiple aspects of model performance in a single diagram," *J. Geophys. Res.*, vol. 106, pp. 7183–7192, 2001.
- [37] Legouhy A., "al_goodplot - boxplot & violin plot," www.mathworks.com, Dec. 17, 2021 [Online]. Available: https://www.mathworks.com/matlabcentral/fileexchange/91790-al_goodplot-boxplot-violin-plot. [Accessed: May. 22, 2022].

This is an open access article under the CC-BY license

