

Yeşilirmak Nehri Akış Verisi Tahmininin Yapay Sinir Ağları Kullanılarak Karınca Aslanı Algoritması ile Zaman Gecikmesi Boyutunun Optimizasyonu

Fatih Ahmet ŞENEL¹, Tülay Suğra KÜÇÜKERDEM ÖZTÜRK^{2,*}, Kemal SAPLIOĞLU³

¹ Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta.

^{2,3} Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Isparta.

e-posta: fatihsenel@sdu.edu.tr.

ORCID ID: <http://orcid.org/0000-0003-1918-7277>

Sorumlu yazar e-posta: tulaykucukerdem@sdu.edu.tr.

ORCID ID: <http://orcid.org/0000-0002-1102-1718>

e-posta: kemalsaplioglu@sdu.edu.tr.

ORCID ID: <http://orcid.org/0000-0003-0016-8690>

Geliş Tarihi: 02.01.2020

Kabul Tarihi: 24.03.2020

Öz

Günümüzde suya olan talebin artması, mevcut su kaynaklarının korunması ve projelendirilmesi konusunu çok önemli hale getirmiştir. Projelendirme aşamasının en uygun şekilde yapılabilmesi için veri toplama, analiz etme ve gelecek verilerin tahmini gereklidir. Gelecek verilerin tahmin edilebilmesi için pek çok yöntem geliştirilmiştir. Bu çalışmada Yeşilirmak Nehri üzerinde bulunan 3 adet istasyonun gelecek dönemdeki akış miktarlarının yapay sinir ağları ile tahmin edilmesi amaçlanmıştır. Yapay sinir ağları (YSA) ile zaman serisi analizi yapılırken geriye dönük olarak kaç dönemlik verinin kullanılması gerektiği problemin başarısını doğrudan etkilemektedir. Geriye dönük olarak bakılan veri sayısı (zaman gecikmesi) bir optimizasyon problemi olarak ele alınabilmektedir. Bu aşamada Karınca Aslanı Algoritması (KAA) kullanılarak, zaman gecikmesi boyutunun optimize edilmesi gerçekleştirilmiştir. Zaman gecikmesine ek olarak yapay sinir ağlarında kullanılan gizli katman sayısı da modele eklenerek optimize edilmiştir. Elde edilen sonuçlara bakıldığında; YSA ile birlikte sezgisel optimizasyon tekniklerinin kullanılmasının modelin başarısını artırdığı sonucuna varılmıştır.

Anahtar kelimeler

Karınca Aslanı;
Optimizasyon; Yapay
Sinir Ağları; Yeşilirmak;
Zaman Gecikmesi
Boyutu

Optimization of Time Delay Dimension by Ant Lion Algorithm Using Artificial Neural Networks for Estimation of Yeşilirmak River Flow Data

Abstract

Today, the increase in demand for water has made it very important to preserve and design the existing water resources. Data collection, analysis and forecasting of future data are required for optimum project planning. Many methods have been developed to predict future data. In this study, it is aimed to estimate the flow rates of 3 stations on Yeşilirmak River by artificial neural networks. The success of the problem directly affects how many periods of data should be used retrospectively when performing time series analysis with artificial neural networks. The number of data retrospectively (time delay) can be considered as an optimization problem. At this stage, time lag size optimization was performed by using Ant lion algorithm. In addition to time delay, the number of hidden layers used in artificial neural networks has been optimized by adding to the model. When the results obtained are examined; It was concluded that the use of heuristic optimization techniques together with ANN increased the success of the model.

Keywords

Ant Lion; Optimization;
Artificial Neural
Networks; Yesilirmak;
Time Delay Dimension

1. Giriş

Su kaynaklarının geliştirilmesi, planlanması ve projelendirilmesinde hidrolojik verilerin gelecekteki tahmini çok önemli bir yer tutmaktadır. Planlama ve projelendirme aşamalarında optimum boyutlandırma için uzun periyoda sahip verilerin yanı sıra, bunların gelecekte alacağı değerlerin de tahmin edilmesi gerekmektedir (Raman ve Sunilkumar 1995, Küçükdem vd. 2018, Arslan 2018, Guclu ve Sen 2016). Klasik veri toplama ve değerlendirme yöntemleri ile yapılan projelendirmeler hem ihtiyaçların karşılanması noktasında hem de maliyetler konusunda optimum sonuçlardan çok uzak bir noktada kalabilmektedir (Küçük ve Ağralıoğlu 2006). Bununla birlikte; hidrolojik olaylar hem yerküresindeki ve atmosferdeki değişikliklerden hem de kendinden önceki olaylardan etkilenirler (Salas vd. 1980, Çıtakoğlu vd. 2017). Bu sebeple pek çok araştırmacı hidrolojik verilerin zaman serileri üzerine çalışma yapmışlardır (Çevik ve Yürekli 2003). Karabörk ve Kahya (1999), Sakarya havzasında ölçülen aylık veriler için çok değişkenli otoregresif (AR) ve çok değişkenli otoregresif hareketli ortalama (ARMA) ile modeller oluşturmuş, ARMA modelinin AR modeline göre daha başarılı olduğu ifade edilmiştir. Keskin ve Taylan (2007) tarafından, aylık akım verileri için stokastik modeller geliştirilmiş ve bu modellerin tahminlemede başarılı olduğu belirtilmiştir. Topçuoğlu vd. (2005) tarafından, yağış verilerinin gelecek değerlerini tahmin etmede sentetik ARIMA modeli kullanılmıştır. Terzi ve Köse (2012) tarafından, yapılan çalışmada Göksu Nehri'nin akım tahminini YSA kullanarak gerçekleştirilmiştir. 5 farklı zaman gecikmesi ile çalışmalar yapılmış ve sonuçları karşılaştırılmıştır. Makas ve Karaatlı (2016) tarafından, Isparta ili Aksu ilçesinde bulunan Yenice deresinden beslenen bir hidroelektrik santralinin elektrik üretimi tahmini işlemi YSA kullanarak gerçekleştirilmiştir. Modelde girdi olarak; aylık ortalama yağış, aylık ortalama nisbi nem ve aylık ortalama debi verileri kullanılmıştır. Nacar vd. (2018) tarafından, Doğu Karadeniz Havzası'nda yer alan Haldizen Deresinin akım verilerinin tahmin edilmesi amaçlanmıştır. Tahmin işleminde çok değişkenli uyarlanabilir regresyon eğrileri yöntemi ve klasik regresyon analizi yöntemleri kullanılarak karşılaştırma yapılmıştır. Elde ettikleri sonuçlarla çok değişkenli uyarlanabilir regresyon eğrileri yöntemi ile akım verilerinin daha doğru bir şekilde tahmin edilebildiği gösterilmiştir. Taşar ve vd. (2018) tarafından, Massachusetts'te bulunan bir hazneye ait buharlaşma verilerinin tahmin edilmesi problemi

ele alınmıştır. Geleneksel yöntemlere ek olarak YSA modeli ile tahmin işlemi gerçekleştirilmiştir. Günlük ortalama buharlaşma miktarı tahmini için rüzgar hızı, ortalama günlük hava sıcaklığı, güneşlenme miktarı ve bağıl nem verileri girdi olarak kullanılmıştır. Çalışma sonucunda YSA modeli ile en iyi tahmin elde edilmiştir. Yukarıdaki çalışmalar incelendiğinde YSA ile zaman serileri analizi işlemi gerçekleştirilirken, zaman gecikmesinin yani geçmiş kaç döneme ait veri kullanarak şu anki durumun tahmin edileceğinin net bir uygulaması yoktur. Deneme yanılma yöntemleri kullanılarak en iyi zaman gecikme sayısı tespit edilmeye çalışılmaktadır (Kaynar vd. 2011).

Bu çalışmada; zaman gecikmesi için geçmiş dönemlerden kaç tanesinin girdi parametresi olarak kullanılması gerektiğinin belirlenmesi ve YSA modelinin gizli katman sayısı ile bu katmanlara ait nöron sayılarının tespit edilmesi için karınca aslanı algoritmasından yararlanılmıştır. YSA modelleri karınca aslanı algoritması tarafından oluşturulmuş, kıstas fonksiyonları dikkate alınarak irdelenmiştir. Bu modellerden en iyi sonuçları verenler bu algoritma tarafından belirlenmiştir. En iyi sonucu veren modele ait girdi sayısı, gizli katman sayısı ve nöron sayısına ait tahmin modelleri grafik ve tablolar halinde sunulmuştur.

2. Materyal ve Metot

Çalışmada Yeşilirmak nehri üzerinde bulunan 3 adet gözlem istasyonu (1401, 1402 ve 1413) çalışılmıştır. Ayrıca modelleme YSA ile yapılmış olup, YSA modelleri kurulurken ve veri sayıları girilirken optimum durumun bulunması amacı ile KAA kullanılmıştır. Çalışmada kullanılan veriler ve modeller hakkındaki bilgiler bu bölümde verilmiştir.

2.1 Kullanılan veriler

Türkiye'nin kuzeyinde bulunan Yeşilirmak havzası 25 havzadan birisidir (Şekil 1). Çalışmada bu havzada yer alan 1401, 1402 ve 1413 nolu istasyonlar kullanılmıştır. 1401 nolu istasyona ait toplam 720 adet veriden 576 adedi eğitim için 144 adedi test için, 1402 nolu istasyona ait toplam 168 adet veriden 136 adedi eğitim için 32 adedi test için ve 1413 nolu istasyona ait toplam 528 adet veriden 422 adedi eğitim için 106 adedi test için kullanılmış olup bu verilere ait istatistiksel bilgiler Çizelge 1' de verilmiştir. Veriler incelendiğinde çoğu çalışmada (Dabanlı vd. 2016, Güçlü 2018) kullanılmış olan %95

güven düzeyine göre dağılıma uygun olduğu kabul edilmiş ve kullanılabilir olduğuna karar verilmiştir.



Şekil 1. Yeşilirmak nehri yerbulundu haritası (EİE).


Çizelge 1. İstasyonlara ait verilerin istatistiksel analizi

	1401 nolu istasyon	1402 nolu istasyon	1413 nolu istasyon
Y- koordinatları	40°28'42"	40°46'18"	40°44'40"
X- koordinatları	36°59'56"	36°30'45"	36°06'43"
Yağış Alanı(km ²)	10048.8	33904.0	21667.2
Rakım (m)	375	190	301
Ortalama	70.66	151.33	63.90
Standart Hata	3.42	5.58	2.38
Ortanca	39.40	110.00	46.10
Standart Sapma	76.81	125.23	53.52
Örnek Varyans	5899.65	15682.93	2864.77
Basıklık	3.46	2.54	3.13
Çarpıklık	1.90	1.54	1.64
Aralık	443.77	751.50	347.53
En Küçük	5.23	13.50	2.47
En Büyük	449	765	350
Toplam	35611.66	76271.80	32204.54
Güvenirlilik Düzeyi(%95)	6.72	10.96	4.68

2.2 Karınca aslanı algoritması

Karınca Aslanı Algoritması, 2015 yılında karınca aslanlarının larvalık dönemlerindeki avlanma stratejilerinden esinlenilerek Seyedali Mirjalili tarafından geliştirilmiş bir sezgi ötesi optimizasyon algoritmasıdır (Mirjalili 2015). Karınca aslanları yaşamlarının büyük çoğunluğunu toprak altında larva olarak geçirirler. Yetişkin oldukları yaşam dönemleri kısadır ve bu dönemde çoğalmaktadırlar. Larva dönemindeki karınca aslanları avlanmak için topraktan koni biçiminde bir tuzak oluştururlar.

Toprağın altında koninin uç kısmında, oluşturdukları bu tuzağın içine karıncaların düşmesini beklerler (Şekil 2). Tuzağa düşen bir karınca algıladıklarında, koninin uç köşesinden dışarı doğru küçük kum parçaları fırlatarak, tuzağa düşen karıncaların ayaklarının kaymasını sağlarlar. Böylece karıncalar tuzaktan dışarı çıkamaz ve kayarak koninin dibine kadar düşerler. Koninin dibine düşen karıncaları, karınca aslanları büyük çeneleri ile yiyerek beslenirler. Avlanma işlemi bittikten sonra, karınca aslanları tekrar tuzağı yenileyerek avlarını beklemeye başlarlar.



Şekil 2. Karınca aslanı ve koni şeklindeki tuzak görüntüsü (Mirjalili 2015).

KAA'da arama uzayında karıncaların rastgele yürüyüş yaptıkları ve yiyecek aradıkları varsayılır. Karıncaların rastgele yürüyüşleri Denklem 1'de ifade edilmiştir.

$$X(t) = [0, c(2r(t_1) - 1), c(2r(t_2) - 1), \dots, c(2r(t_n) - 1)] \quad (1)$$

Burada, c fonksiyonu kümülatif toplamı, n maksimum iterasyon sayısını, t rastgele yürüyüşlerin adımlarını, $r(t)$ ise rastgele yürüyüşleri temsil etmektedir. Denklem 2'de $r(t)$ 'in hesaplanması verilmiştir.

$$r(t) = \begin{cases} 1 & \text{Eğer } rand(0,1) > 0.5 \\ 0 & \text{Eğer } rand(0,1) \leq 0.5 \end{cases} \quad (2)$$

Burada t rastgele yürüyüşlerin adımlarını, $rand(0,1)$ ise $[0,1]$ aralığında rastgele sayıyı ifade etmektedir. Rastgele yürüyüşler; artan eğilimli, azalan eğilimli ve rastgele artan-azalan eğilimli olmak üzere üç farklı şekilde olabilmektedir.

Rastgele yürüyen karıncaların konumları optimizasyon süresince kayıt altında tutulmakta ve Denklem 3'te verilen matris yapısıyla ifade edilmektedir.

$$M_K = \begin{bmatrix} A_{1,1} & A_{1,2} & \dots & \dots & A_{1,d} \\ A_{2,1} & A_{2,2} & \dots & \dots & A_{2,d} \\ \vdots & \vdots & \dots & \dots & \vdots \\ \vdots & \vdots & \dots & \dots & \vdots \\ A_{n,1} & A_{n,2} & \dots & \dots & A_{n,d} \end{bmatrix} \quad (3)$$

Burada, d problemin boyutunu, n karınca sayısını, $A_{i,j}$ ise i . karıncanın j . değerini ifade etmektedir. Optimizasyon adımları ilerledikçe her bir karıncanın pozisyonu bir uygunluk fonksiyonundan geçirilerek karıncaların uygunluk değeri hesaplanır ve Denklem 4'te gösterildiği gibi bir matriste depolanır.

$$M_U = \begin{bmatrix} f([A_{1,1}, A_{1,2}, \dots, A_{1,d}]) \\ f([A_{2,1}, A_{2,2}, \dots, A_{2,d}]) \\ \vdots \\ \vdots \\ f([A_{n,1}, A_{n,2}, \dots, A_{n,d}]) \end{bmatrix} \quad (4)$$

Burada f , uygunluk fonksiyonunu temsil etmektedir. Karıncalara ek olarak karınca aslanının da arama uzayında bir noktada gizlendiği varsayılmaktadır. Denklem 5'te karınca aslanlarının pozisyonlarının tutulduğu matris yapısı gösterilmektedir.

$$M_{KA} = \begin{bmatrix} AL_{1,1} & AL_{1,2} & \dots & \dots & AL_{1,d} \\ AL_{2,1} & AL_{2,2} & \dots & \dots & AL_{2,d} \\ \vdots & \vdots & \dots & \dots & \vdots \\ \vdots & \vdots & \dots & \dots & \vdots \\ AL_{n,1} & AL_{n,2} & \dots & \dots & AL_{n,d} \end{bmatrix} \quad (5)$$

Karınca aslanlarının uygunluk değerlerinin tutulduğu matris ise Denklem 6'da gösterilmiştir.

$$M_{KAU} = \begin{bmatrix} f([AL_{1,1}, AL_{1,2}, \dots, AL_{1,d}]) \\ f([AL_{2,1}, AL_{2,2}, \dots, AL_{2,d}]) \\ \vdots \\ \vdots \\ f([AL_{n,1}, AL_{n,2}, \dots, AL_{n,d}]) \end{bmatrix} \quad (6)$$

KAA'da iterasyonlar boyunca karıncaların arama uzayında rastgele yürüyüş yaptıkları

varsayılmaktadır. Rastgele yürüyüşler problemin tüm boyutlarını kapsayacak şekilde gerçekleştirilmektedir. Karınca aslanlarının tuzakları, karıncaların rastgele yürüyüşlerini etkilemektedir. Karınca aslanları, karıncaların uygunluk değerlerine göre yeni tuzaklar oluşturabilmektedir. Ayrıca tuzakların büyüklüğünü artırarak karınca yakalama olasılıklarını artırmaktadırlar. Her iterasyonda yakalanan karınca, o iterasyon adımı için en uygun değeri temsil etmektedir. Tuzağa yakalanan bir karıncanın rastgele yürüyüş büyüklüğü, karıncanın tuzak içinde karınca aslanına kaydırılması işlemi ile azaltılmaktadır. Kaydırılarak karınca aslanına doğru yaklaştırılan karıncanın uygunluk değerinin, karınca aslanından daha iyi olduğu bir durumda, karıncanın yakalandığı ve toprak altına çekildiği varsayılmaktadır. Son olarak her karınca yakalama işleminden sonra karınca aslanının tuzağını yenilediği ve yeni avlanma işlemi için beklemeye geçtiği kabul edilmektedir.

Denklem 1 kullanılarak karıncaların rastgele yürüyüş için pozisyonlarının belirlendiği ifade edilmişti. Arama uzayının dışına çıkmaları engellemek için Denklem 7 kullanılmaktadır (Tian vd. 2018).

$$X_i = \frac{(X_i - a_i) \times (d_i - c_i)}{(b_i - a_i)} + c_i \quad (7)$$

Burada, a_i ve b_i sırasıyla X_i konum vektörünün minimum ve maksimum değerlerini, c_i ve d_i değerleri ise sırasıyla, i . boyutun minimum ve maksimum değerlerini ifade etmektedir. Denklem 7 vasıtasıyla X_i vektörü $[0,1]$ aralığına ölçeklenirken, c_i ve d_i değerleri ile seçilen karınca aslanı etrafında rastgele yürüyüş yapması gerçekleştirilmektedir. Böylece karıncaların tuzak içinde karınca aslanı tarafından kum fırlatılarak ayaklarının kaydırılması ve karınca aslanına doğru rastgele yürüyüş yapması benzeştirilmektedir. c_i ve d_i değerlerinin karınca aslanı etrafında rastgele yürüyüş yaptırılabilmesi için Denklem 8 ve 9 kullanılmaktadır.

$$c_i = c' + Antlion_s \quad (8)$$

$$d_i = d' + Antlion_s \quad (9)$$

Burada; $Antlion_s$, rulet tekerleği yöntemi ile seçilen karınca aslanını ifade etmektedir.

$$c' = \frac{lb}{10^W \times (t/T)} \quad (10)$$

$$d' = \frac{ub}{10^W \times (t/T)} \quad (11)$$

Burada, lb ve ub sırasıyla problem boyutlarının minimum ve maksimum değerlerini ifade etmektedir. t içinde bulunulan iterasyon adımını, T ise maksimum iterasyon sayısını belirtmektedir. W değeri sabit bir sayı olup iterasyon adımı ve maksimum iterasyon sayılarına göre belirlenmektedir (Denklem 12).

$$W = \begin{cases} 2 & t > 0.1T \\ 3 & t > 0.5T \\ 4 & t > 0.75T \\ 5 & t > 0.9T \\ 6 & t > 0.95T \end{cases} \quad (12)$$

Son olarak t . iterasyondaki i . karıncanın konumu belirlenirken, t . iterasyondaki en iyi karınca aslanının konumu (R_A^t) ve tüm optimizasyon süresince seçilen en iyi karınca aslanının (elit) konumu (R_E^t) kullanılmaktadır. Denklem 13'te i . karıncanın konumunun hesabı verilmiştir.

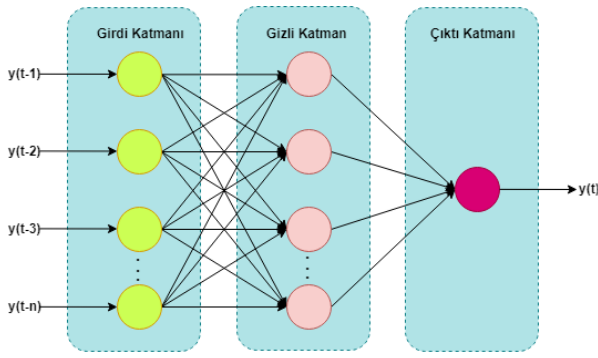
$$Karınca_i = \frac{R_A^t + R_E^t}{2} \quad (13)$$

2.3 Yapay sinir ağları

Yapay Sinir Ağları (YSA) insan beynindeki nöron yapılarının öğrenme mekanizmasından esinlenilerek geliştirilmiştir. YSA kendisine verilen bir veri setinden yola çıkarak öğrenme işlemi gerçekleştirerek, olaylar hakkında çıkarım yapabilme yeteneğine sahip bir yöntemdir. YSA'da girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katman yapısı bulunmaktadır (Şekil 3). Her katmandaki nöronlar bir sonraki katmanın tüm nöronlarına bağlantılı bir yapıya sahiptir. Bu bağlantı işlemi ile her bir bağlantı için tanımlanan ve iterasyonlar boyunca sürekli olarak güncellenen ağırlık değerleri kullanılmaktadır. Bu ağırlık

değerlerinin en iyi şekilde ayarlanması ile öğrenme işlemi gerçekleştirilmektedir. Ayrıca her bir nöron kendisine bağlantı yapan nöronlardan gelen değerleri ağırlık değerleri ile çarpıp toplayarak bir aktivasyon fonksiyonundan geçirir. Böylece verileri belli bir aralığa ölçeklenerek öğrenme işleminin çok daha doğru ve hızlı yapılması gerçekleştirilir. Her katmandaki nöron sayısı probleme özgü olarak belirlenmektedir. YSA'nın önemli bir faktörü de gizli katman sayısıdır. Gizli katman sayısı ve gizli katmandaki nöronların sayıları öğrenme başarısı üzerinde büyük etkiye sahiptir. Gerekenden daha az sayıda gizli katman ve nöronun kullanılması öğrenme işleminin gerçekleşmemesine neden olmaktadır, gerekenden daha fazla sayıda gizli katman ve nöron ise gereksiz kaynak tüketimine neden olmaktadır. Bu nedenle YSA ile çalışılırken gizli katman sayısı ve gizli katmanlardaki bulunan nöron sayılarının optimum düzeyde seçilmesi büyük önem arz etmektedir. YSA ile zaman serisi analizi işlemleri gerçekleştirilirken, bir çıktının tahmininde geriye dönük olarak verilerin kullanılması gerekmektedir. Çünkü zaman serilerinde her bir veri, kendisinden önce gelen verilerle ilişki içerisindedir. Fakat kendisinden önceki kaç adet veri ile ilişkili olduğunun tespit edilmesi zor bir işlemdir. Zaman gecikmesi olarak adlandırılan bu önceki dönem verilerinin sayısının belirlenmesinde literatürde farklı yöntemler kullanılmaktadır. Ancak genel olarak incelendiğinde deneme yanılma yolu ile en iyi zaman gecikmesinin bulunması gerçekleştirilmektedir.

Bu çalışmada, YSA ile çalışılırken karşılaşılan gizli katman sayısının ve nöron sayısının belirlenmesi, ayrıca zaman gecikmesi olarak kullanılacak olan veri sayısının tespit edilmesinde bir optimizasyon yöntemi kullanılması amaçlanmıştır. KAA ile gizli katman sayısı, nöron sayısı ve zaman gecikmesi sayısının optimizasyonu gerçekleştirilmiştir.



Şekil 3. YSA modeli yapısı

2.4 Değerlendirme Ölçütleri

Çalışma için geliştirilen modellerin değerlendirilebilmesi için 3 adet değerlendirme ölçütü kullanılmıştır. Regresyon analizi; aralarında ilişki bulunan değişkenler arasındaki korelasyonun matematiksel olarak ifadesini belirlemek için kullanılır (Bayazit 2006). Ortalama karesel hatanın karekökü; gözlenen değerler ile öngörülen değerler arasındaki farkların ortalamasının karekökünü temsil eder ve Denklem 14 ile ifade edilir.

$$OKHK = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i^- - Q_i)^2} \quad (14)$$

Ortalama mutlak hata; gerçek değerler ile öngörülen değerlerin farklarının ortalamalarını temsil eder ve Denklem 15 ile ifade edilir (Burgan ve Aksoy 2020).

$$OMH = \frac{1}{N} \sum_{i=1}^N |Q_i^- - Q_i| \quad (15)$$

2.5 KAA ile çalıştırılan YSA modeli

Oluşturulan model YSA modellerinin KAA ile optimize edilmesi ilkesine göre çalışmaktadır. Gizli tabaka sayısı, nöron sayısı ve modeldeki zaman gecikmesi parametreleri KAA tarafından atanır. KAA'nın her bir üyesi tarafından oluşturulan YSA modelleri kıstas fonksiyonları ile kontrol edilir ve hatası en az olan model ve her bir üyenin bulunduğu sonuçlar kaydedilir. Bir sonraki iterasyonda bu değerler kullanılarak yeni parametre değerleri atanarak en iyileme yapılır. Bu hibrit modelin çalışması bitirildiğinde en hatalı YSA modeline ait parametreler ortaya konmuş olmaktadır. Modelin çalışma prensibi Şekil 4' te özetlenmeye çalışılmıştır. Çalışmanın KAA ve YSA yazılımı MATLAB aracılığıyla

oluşturulmuştur. Nesneye yönelik programlama mantığı ile oluşturulan bu yazılımla elde edilen sonuçlara ait grafiklerin çizilmesi ve hata hesapları da otomatik olarak oluşturulmuştur.



Şekil 4. KAA ile çalıştırılan YSA modelinin akış şeması

3. Bulgular

Bu çalışmada KAA kullanılarak, 3 farklı istasyona ait aylık akım miktarlarının YSA ile tahmin işlemi gerçekleştirilirken, optimum gizli katman sayısı, optimum nöron sayısı ve optimum zaman gecikme sayısının tespiti gerçekleştirilmiştir. KAA algoritmasında popülasyon büyüklüğü 20, iterasyon sayısı ise 100 olarak seçilerek tüm işlemler gerçekleştirilmiştir. Zaman gecikmesi olarak [1, 150] aralığı, gizli katman ve nöron sayısı aralığı için [1, 15] aralığı seçilmiştir. YSA'nın öğrenme başarılarının karşılaştırılmasında ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH) ve determinasyon katsayısı (R^2) ölçütleri kullanılmıştır. Çalışmada aylık akım verileri kullanılmıştır. Her bir öğrenme işleminde toplam verinin ilk %80'lik kısmı eğitim işlemi için, geri kalan kısmı ise test işlemi için kullanılmıştır. YSA'nın başlangıç ağırlık değerleri her zaman 0'dan başlatılmıştır. Test işlemi sonrasında elde edilen ölçütler üç farklı istasyon içinde ayrı ayrı olarak Çizelge 2'de verilmiştir. Ayrıca pik debiler

incelendiğinde hatanın %10 civarında olduğu görülmüştür.

Çizelge 2. İstasyonlar için YSA modeli öğrenme karşılaştırması


İstasyon No	OKHK	OMH	R ²
1401	34.49	21.92	0.89
1402	31.26	25.87	0.91
1413	18.76	13.62	0.80

Çizelge 2’de verilen kıstas değerleri, karınca aslanı algoritmasının YSA modellerini karşılaştırmada kullandığı fonksiyonlardır. Modeller oluşturulup kıyaslama yapılırken; optimizasyon algoritması bu fonksiyonlara göre değerlendirme yapmış ve elde edilen en iyi sonuçlar bu çizelgede gösterilmiştir.


Elde edilen bu sonuçlara karşı gelen optimum parametre değerleri ise Çizelge 3’te gösterilmiştir. Optimum parametreler ile elde edilen tahmin sonuçlarına karşılık, gerçek değerlerin karşılaştırılması grafikleri, 1401, 1402, 1413 nolu istasyonlar için sırasıyla Şekil 5, Şekil 6 ve Şekil 7’de verilmiştir. Su yılı değerleri 1 Ekim’de başlamaktadır.

Çizelge 3. İstasyonlar için optimum değerler


İstasyon No	Gizli Katman Sayısı	Nöron Sayısı	Zaman Gecikmesi
1401	8	8	22
1402	12	12	5
1413	9	9	35



Şekil 5. 1401 nolu istasyon tahmin-gerçek değerlerin karşılaştırılması



Şekil 6. 1402 nolu istasyon tahmin-gerçek değerlerin karşılaştırılması



Şekil 7. 1413 nolu istasyon tahmin-gerçek değerlerin karşılaştırılması

4. Tartışma ve Sonuç

Su kaynaklarının planlanması ve projelendirilmesi aşamalarında gelecek dönemlere ait verilerin tahmin edilmesi son derece önemlidir. Bu çalışmada Yeşilirmak nehri üzerinde bulunan 1401, 1402, 1413 numaralı istasyonların gelecek dönemdeki akış miktarları yapay sinir ağları ile tahmin edilmiştir. Yapay sinir ağları ile zaman serisi analizi yapılırken, girdi olarak kullanılacak veri sayısının adedi performansı etkilemektedir. Geriye dönük olarak bakılan veri sayısı (zaman gecikmesi) bir optimizasyon problemi olarak ele alınabilmektedir. Bu aşamada karınca aslanı algoritması kullanılarak, zaman gecikmesi boyutunun optimize edilmesi gerçekleştirilmiştir. Zaman gecikmesine ek olarak yapay sinir ağlarında mevcut olan gizli katman sayısı da modele eklenerek optimize edilmiştir. Klasik olarak kurulan YSA modellerinde rastgele nöron sayıları ve geçmişe yönelik veri sayısı girilerek yapılan modellemeler ile sonuca ulaşabilmektedir. Ancak bu şekilde yapılan bir çalışmada optimum sonuca ulaşılması zaman almakta ya da imkansız bir hal almaktadır. Çalışmada kullanılan karınca aslanı optimizasyon algoritması sayesinde bu problem büyük ölçüde çözülmüştür. Örneğin 50 üye ve 500 iterasyon kullanıldığında 2500 farklı hesap, minimum hataya sahip olacak şekilde çok kısa sürede sonuçlandırılabilir. Yapılan

hesaplamlarda tüm üyeler minimum hatanın elde edildiği bölgeye yaklaşmakta ve belli bir iterasyon sonucu değişimler çok azalmaktadır. Çok hassas olarak yapılması gereken bu işlemin elle yapılarak sonuca ulaşılması ise oldukça zor olmaktadır. Örneğin; 8 gizli katman 8 nöron ve 22 zaman gecikmesi ile yapılan çalışmanın determinasyon katsayısı 0.89 iken, zaman gecikmesinin 23 olduğu bir durumda determinasyon katsayısı 0.68'e kadar düşmektedir. Bu çalışmada elde edilen bu sonuç ile YSA ile ilgili çalışmaların sezgisel optimizasyon teknikleri ile birlikte kullanılmasının doğruluk payını arttırdığı görülmüştür. Çalışmada kullanılan tüm istasyonlardan elde edilen sonuçlara bakıldığında ise tüm istasyonların yüksek oranda tahmin edilebildiği bulunmuştur.

5. Kaynaklar

- Arslan, O., 2018. Prediction of evaporation values of Konya closed basin via developed empirical formula. *International Scientific and Vocational Journal*, **2**, 29-38.
- Bayazit, M., 2006. Çok değişkenli istatistik analiz ve hidrolojide uygulamaları. Su Vakfı Yayınları, İstanbul, 35-45.

- Burgan, H.İ., Aksoy, H., 2020. Monthly flow duration curve model for ungauged river basins. *Water*, **12**, 338.
- Çevik, O., Yürekli, K., 2003. Mevsimsel ARIMA modeli kullanılarak Yeşilirmak Nehri aylık akım serisinin modellenmesi. *Tarım Bilimleri Dergisi*, **9**, 261-268.
- Çıtakoğlu, H., Çetin, M., Çobaner, M., Haktanır, T., 2017. Mevsimsel yağışların jeostatistiksel yöntemle modellenmesi ve gözlemi olmayan noktalarda tahmin edilmesi. *Teknik Dergi*, **28(1)**, 7725-7745.
- Dabanlı, İ., Şen, Z., Yeleğen, M.Ö., Şişman, E., Selek, B., Güçlü, Y.S., 2016. Trend assessment by the Innovative-Şen Method. *Water Resources Management*, **30**, 5193-5203.
- EİE, Akım Gözlem Yıllıkları.
- Güçlü, Y.S., Şen, Z., 2016. Hydrograph estimation with fuzzy chain model. *Journal of Hydrology*, **538**, 587-597.
- Güçlü, Y.S., 2018. Multiple Şen-innovative trend analyses and partial Mann-Kendall test. *Journal of Hydrology*, **566**, 685-704.
- Karabörk, M.Ç., Kahya, E., 1999. Sakarya havzasındaki aylık akımların çok değişkenli stokastik modellenmesi. *Journal of Engineering and Environmental Science*, **23**, 133-147.
- Kaynar, O., Taştan, S., Demirkoparan, F., 2011. Yapay sinir ağları ile doğalgaz tüketim tahmini. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, **25**, 463-474.
- Keskin, M.E., Taylan, E.D., 2007. Orta Akdeniz havzasındaki aylık akımların çok değişkenli stokastik modellenmesi. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, **42**, 89-97.
- Küçük, M., Ağırlioğlu, N., 2006. Dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmesi. *İtü Dergisi*, **5**, 69-80.
- Küçükerdem, T.S., Kilit, M., Saplıoğlu, K., 2018. Kestel barajı hacminin adaptif ağ tabanlı bulanık çıkarım sistemi ile tahmini. International Symposium on Urban Water and Wastewater Management.
- Makas, Y., Karaatlı, M., 2016. Yapay sinir ağlarıyla hidroelektrik enerji üretiminin çok dönemli tahmini. *Uluslararası Teknolojik Bilimler Dergisi*, **4**, 1-7.
- Mirjalili, S., 2015. The ant lion optimizer. *Advances in Engineering Software*, **83**, 80-98.
- Nacar, S., Kankal, M., Hınıs, M.A., 2018. Çok değişkenli uyarlanabilir regresyon eğrileri (ÇDURE) ile günlük akarsu akımlarının tahmini- Haldizen Deresi örneği. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, **8**, 38-47.
- Raman, H., Sunilkumar, N., 1995. Multivariate modelling of water resources time series using artificial neural networks. *Hydrological Sciences Journal*, **40**, 145-163.
- Salas, J.D., Delleur, J.W., Yevjevich, V., Lane W.L. 1980. Applied modeling of hydrologic time series. Water Resources Publications.
- Taşar, B., Üneş, F., Demirci, M., Kaya, Y.Z., 2018. Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *DÜMF Mühendislik Dergisi*, **9**, 543-551.
- Terzi, Ö., Köse, M., 2012. Yapay sinir ağları yöntemi ile Göksu Nehri'nin akım tahmini. *Uluslararası Teknolojik Bilimler Dergisi*, **4**, 1-7.
- Tian, T., Liu, C., Guo, Q., Yuan, Y., Li, W., Yan, Q., 2018. An improved ant lion optimization algorithm and its application in hydraulic turbine governing system parameter identification. *Energies*, **11**, 95.
- Topçuoğlu, K., Pamuk, G., Özgürel, M., 2005. Gediz Havzası yağışlarının stokastik modellenmesi. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, **42**, 89-97.