



Yapay zeka ve sezgisel regresyon yöntemlerinin yağış-akış modellemesi için performans değerlendirmesi: Aksu Deresi için bir uygulama

Performance evaluation of artificial intelligence and heuristic regression methods for rainfall-runoff modelling: An application in Aksu Stream

Hasan Törehan Babacan^{1,*}, Ömer Yüksek², Fatih Saka³

¹ Amasya Üniversitesi, Taşova Yüksel Akın MYO, 05800, Amasya, Türkiye

² Karadeniz Teknik Üniversitesi, İnşaat Mühendisliği Bölümü, 61080, Trabzon, Türkiye

³ Karabük Üniversitesi, İnşaat Mühendisliği Bölümü, 78000, Karabük, Türkiye

Öz

Bu çalışmada, Aksu Deresi üzerinde, günlük toplam yağış (P) ve günlük ortalama debi (Q) değerleri kullanılarak Yağış-Akış Modelleri geliştirilmiş ve gelecek debi tahmini yapılmıştır. Yağış-Akış modellerinde kullanılan sayısal yöntemlerin Yağış-Akış sürecini açıklayabilme performansları kıyaslanmıştır. Yağış-Akış sürecini açıklamada, Yapay Zeka (AI) yöntemlerinden, Yapay Sinir Ağları (YSA) ve Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) kullanılmıştır. Ayrıca Sezgisel Regresyon (HR) yöntemi olarak Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS) ve Destek Vektör Makineleri (SVM) kullanılmıştır. Yöntemlerin performansı Hata Ortalamalarının Karesinin Karekökü (RMSE), Korelasyon Katsayısı (R) ve Mutlak Hataların Ortalaması (MAE) katsayıları ile belirlenmiş ve kıyaslanmıştır. Denenen AI yöntemlerinin performansları çok yakın olsa da ANFIS yöntemi ile oluşturulan Yağış-Akış modelinde en düşük hata değeri elde edilmiştir. Denenen diğer yöntemlerde ise en yüksek performans değeri MARS ile oluşturulan Yağış-Akış modelinde gözlenmiştir. AI, HR ve diğer yöntemlerde yapılan performans değerlendirmesinde, MARS yönteminin AI yöntemlerine göre Yağış-Akış sürecini açıklayabilme performansının daha yüksek olduğu görülmüştür.

Anahtar kelimeler: Yağış-Akış modellemesi, Yapay zeka, Sezgisel regresyon, Aksu Deresi

1 Giriş

Yağışa bağlı olarak gelecek debinin tahmin edilmesi taşkın olayları başta olmak üzere kurulacak su yapılarının projelendirilmesi, optimum yerin belirlenmesi ve projede bütçenin optimum şekilde kullanılabilmesi için büyük öneme sahiptir [1]. Hızla artan nüfus yoğunluğu, sanayileşme, akarsu yakınlarında şehirleşme ve doğal yağış-akış dengesinin beşeri etkenler ile bozulması taşkın riskini önemli derecede artırmaktadır.

Yağış-Akış Modellemesi (YAM), yağış rejiminin sürekli değişkenlik göstermesi, çok geniş alanlarda gerçekleşmesi, sürekli gözlenebilir olmaması, havza içerisinde bulunan farklı topografik koşullardan etkilenmesi ve çok fazla

Abstract

Rainfall-Runoff Models were developed by using the daily total precipitation (P) and daily mean discharge (Q) values on Aksu Stream and future discharges were predicted. The performances of numerical methods to explain the Rainfall-Runoff process were compared. Two kinds of Artificial Intelligence (AI) methods, including, Artificial Neural Networks (ANN) and Adaptive Neuro Fuzzy Inference System (ANFIS); as well as Heuristic Regression (HR) method, including Multivariate Adaptive Regression Splines (MARS) and Support Vector Machine (SVM), were used to describe the process. The performance of the methods was determined by using the Root Mean Square Error (RMSE), Correlation Coefficient (R) and Mean Absolute Error (MAE) coefficients. Although the performance of AI methods was very close, the lowest error value was obtained by ANFIS method. For the other methods, the highest performance was observed with MARS. It has been concluded that MARS method, which is HR method have higher performance than AI methods.

Keywords: Rainfall-Runoff modelling, Artificial intelligence, Heuristic regression, Aksu Stream

değişkenin etki etmesi gibi sebepler dolayısıyla hidrolojik araştırmaların en karmaşık problemlerinden birisidir [2]. Blöschl ve arkadaşlarının 2019 yılında yaptığı çalışmada hidrolojide çözülmemiş 260 problem ortaya koyulmuş ve bu problemlerden en önemli olan 23 tanesi belirlenmiştir. Belirlenen bu 23 problemde büyük çoğunluğu yağış-akış prosesi ile direkt olarak, geri kalanları ise yağış-akış prosesi ile dolaylı olarak ilişkilidir [3]. Hidroloji alanında büyük önemi olan bu karmaşık problemin çözülmesi için pek çok araştırmacı YAM konusunda çalışmalar yapmıştır [4]. Havzaya giren suyun, yüzeyde toplanarak çıkışa geçene kadar olan sürede pek çok dış faktörden etkilendiği ve bu faktörlerin tümünün yapılacak fiziki gözlem ve modelleme ile ifade edilmesinin mümkün olmadığı bilinmektedir [5].

* Sorumlu yazar / Corresponding author, e-posta / e-mail:hasan.babacan@amasya.edu.tr (H. T. Babacan)

Geliş / Received: 26.02.2022 Kabul / Accepted: 14.06.2022 Yayınlanma / Published: 18.07.2022

doi: 10.28948/ngumuh.1079616

YAM oluşturulması sırasında yüzey akışını etkileyen çok fazla parametre bulunduğundan modele karar vermek sınırlı bir amaç doğrultusunda yapılabilir ayrıca modelleri çözümlenmek için karmaşık eşitlikler kullanılmalıdır [6].

YAM karmaşık ve uzun zaman serileri arasındaki ilişkinin ortaya koyulması esasına dayanmaktadır. Bu nedenle geçmiş çalışmalarda pek çok YAM geliştirildiği görülmektedir [4, 7, 8]. Geliştirilen YAM yapıları gelişen bilgisayar teknolojileriyle birlikte geliştirilen yeni algoritmalarla denenmektedir ve optimum ilişkinin bulunması amaçlanmaktadır [5]. Makine öğrenmesi gerçekleştiren Yapay Zeka (YZ) ve Sezgisel Regresyon (SR) yöntemleri YAM çalışmalarında ampirik ve fiziksel modellere göre daha başarılı sonuçlar üretmektedir [9].

Literatürde makine öğrenmesi ile geliştirilen YAM yapıları incelendiğinde farklı girdi parametrelerinin kullanıldığı görülmekte olup, bu parametrelerden yüzeysel akış miktarının tahmin edilmeye çalışıldığı görülmektedir. YAM yapılarında esas girdi parametreleri olarak yağış ve geçmiş yüzeysel akış verileri kullanılmıştır [10]. YAM konusunda YSA, ANFIS sayısal yöntemleri literatürde daha geniş yer bulmuş ancak çalışmada kullanılan MARS ve SVM daha sınırlı bir kullanım alanı bulmuştur. Yapılan çalışma bulguları incelendiğinde kullanılan modellerin, yağış ve yüzeysel akış parametreleri kullanarak gelecek yüzeysel akış tahmini konusunda başarılı sonuçlar ürettiği görülmektedir [10-13].

Aksu Deresi havzasında yağış-akış modelleme çalışmaları incelendiğinde, bölgedeki akış karakteristiğini tanımlamak için yağış ve geçmiş akış verilerinin tahminleyici parametre olarak kullanıldığı, gelecek akış değerlerini tahmin edecek YAM modelinin farklı YSA mimarileri ile araştırıldığı görülmüştür. Yapılan çalışmalarda alt havzada bulunan istasyonda akış tahmini yapılmış olup, YSA ile başarılı akış tahmini yapıldığı görülmüştür [8]. Bu çalışma bölgedeki mevcut çalışmadan farklı olarak, havzanın daha yüksek bir kesiminde gerçekleştirilmiştir ve YSA'ya alternatif farklı sayısal metotlar kullanılarak en uygun YAM elde edilmesini amaçlanmaktadır.

Yakın bir tarihte, büyük bir hasara ve can kayıplarına neden olan taşkın felaketinin yaşandığı Aksu Deresi üzerinde bulunan D22A090 numaralı akım gözlem istasyonu verileri kullanılarak bölgede optimum çözüm için YAM çalışması yapılmıştır. Yapılan bu çalışma ile literatürde en sık kullanılan makine öğrenmesi yöntemlerine ek olarak, yağış-akış modellemesi konusunda daha az kullanım alanı bulmuş yöntemlerin bölge için uygulaması gerçekleştirilmiş olup, bölge ve benzer akış karakteristiğine sahip bölgelerde gelecek debinin kesinlik oranı yüksek şekilde tahmin edilmesine katkı sağlaması amaçlanmıştır.

2 Materyal ve metot

2.1 Çalışma bölgesi: Aksu Deresi alt havzası

Doğu Karadeniz Havzası Türkiye'nin 25 havzası arasında yağış alanına göre ortalama yıllık yüzeysel akış potansiyeli en yüksek havzasıdır. Doğu Karadeniz Havzası'nın potansiyel iştirak oranı %8,9 olup havza Türkiye için en önemli havzalar arasındadır [14]. Çalışma

bölgesi olarak yoğun engebeli yapısı nedeniyle taşkın riskinin en fazla olduğu havzaların başında gelen Doğu Karadeniz Havzası seçilmiş olup, havza içerisinde 2020 yılının ikinci yarısında büyük bir taşkın yaşanmış olan Aksu Deresi alt havzası belirlenmiştir (Şekil 1). Çalışmada kullanılan D22A090 istasyonu Aksu Deresi üzerinde bulunmakta olup, istasyon Devlet Su İşleri (DSİ) Genel Müdürlüğü tarafından işletilmiştir. İstasyona ait bilgiler Tablo 1'de gösterilmiştir.

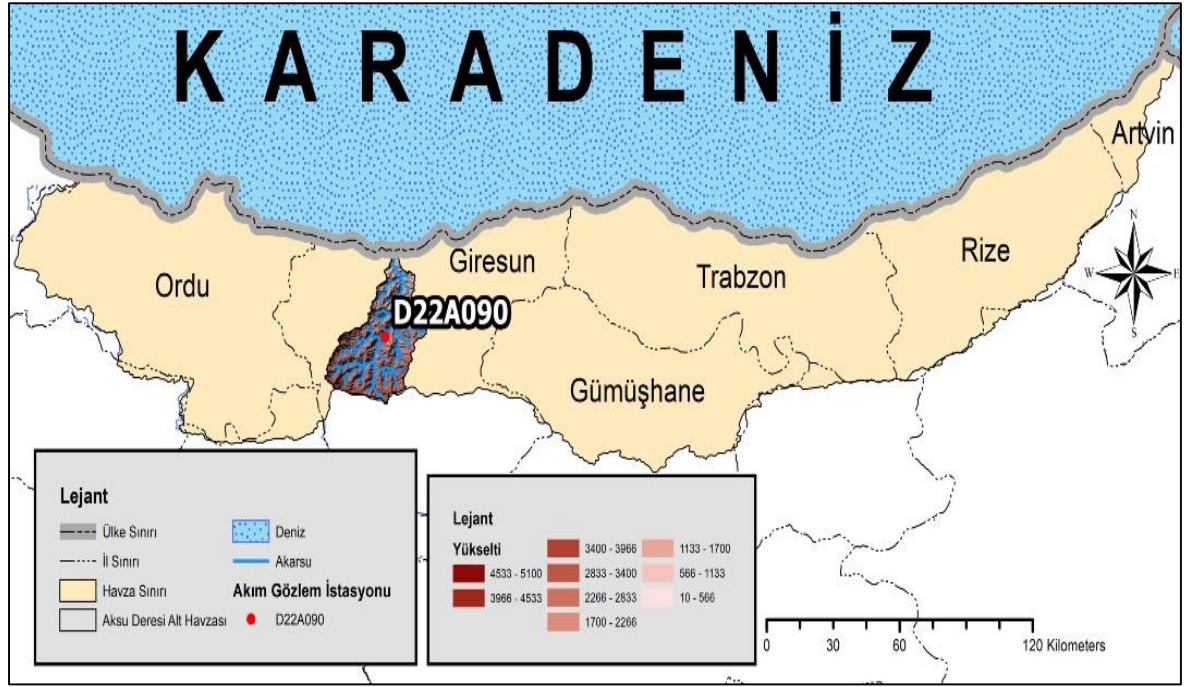
2.2 Çalışmada kullanılan yöntemler

2.2.1 Yapay sinir ağları (YSA)

Yapay Sinir Ağları (YSA) insan beyninin öğrenme, uyum sağlama, karar verme ve tahmin etme becerilerinin taklit edildiği bilgisayar sistemleridir. YSA makine öğrenmesi gerçekleştiren kapalı bir modeldir. YSA en genel durumda üç farklı katmandan oluşmaktadır. Bu katmanlar veri girişinden çıkışına doğru sırasıyla; girdi, ara (gizli) ve çıktı katmanıdır. Girdi katmanı verilerin dış dünyadan ağa girdiği kısım olup, ara katman verilerin belirlenen transfer fonksiyonları ile toplandığı ve çıktı katmanına aktarıldığı kısımdır ve çıktı katmanı da verilerin dış dünyaya aktarıldığı kısımdır [15]. YSA'da dış dünyadan gelen girdiler ağa biyolojik sinir hücrelerine benzeyen yapay nöronlar aracılığı ile alınır. YSA'nın temelini oluşturan nöronların gizli katmandaki sayısının belirlenmesi, öğrenme algoritmasının seçilmesi ve transfer fonksiyonlarının seçilmesi YSA'nın performansını etkileyen en önemli kriterleri olarak sayılabilmektedir [8, 16]. Çalışmada ileri adımlı geri beslemeli, çıktı katmanında üretilen veriyi hedeflenen veri ile kıyaslayarak ağı tersinir çalıştırmak üzere hata oranını azaltan ağ yapısı kullanılmıştır. YSA'da akış tahmini konusunda iyi sonuçlar üreten öğrenme algoritması Levenberg-Marquardt ve transfer fonksiyonu Hiperbolik Tanjant Sigmoid seçilmiştir [8, 15]. Optimum çözümün belirlenmesi için YSA gizli katmanında 3, 6, 9, 12, 15, 18, 21 nöron denenmiştir.

2.2.2 Adaptif sinirsel bulanık çıkarım sistemi (ANFIS)

Bulanık Mantık işleminde kullanılan sözel kuralların YSA'ya uyarlanması sonucunu oluşturulmuş bir sistemdir [17]. Bu yönüyle Adaptif Sinirsel Bulanık Mantık (ANFIS) yöntemi, bulanık mantık ile YSA'nın hibriti olarak çalışmaktadır. Bu durum YSA'nın kesin değerler ile çalışan yapısına ara değerler ile tahmin üretebilme esnekliği kazandırmıştır. ANFIS yönteminde girdiler seçilen bir fonksiyon kullanılarak bulanıklaştırılır ve elde edilen bulanık veri seti ile ağın tahminleme işlemi başlatılır. Bulanık veriler YSA yapısında çıktılara dönüştürülür ve elde edilen bulanık çıktılar durulaştırma denilen, bulanık verilerin tekrar gerçek verilere dönüştürüldüğü işlem ile ağdan çıktı olarak alınır [18]. Çalışmada hidrolojik zaman serilerinin modellemesinde başarılı şekilde kullanılan Takagi-Sugeno tipi ANFIS yapısı oluşturulmuştur [19]. Ağın efektif için önemli parametrelerden olan Üyelik Fonksiyonu (ÜF) tipine karar vermek üzere literatürde yaygın şekilde kullanılan Genelleştirilmiş Çan, Gauss ve Üçgen tip fonksiyonlar denenmiştir [20]



Şekil 1. Doğu Karadeniz Havzası ve D22A090 AGİ konumu

Tablo 1. D22A090 (DSİ) numaralı akım gözlem istasyonuna ait bilgiler

İstasyon No	Yeri	Yağış Alanı (km ²)	Yaklaşık Kot (m)	Bulunduğu Akarsu	Ortalama Akım (m ³ /s)
D22A090	40° 39' 10" K 38° 24' 20" D	470.2	700	Aksu Deresi	9.59

2.2.3 Çok değişkenli uyarlanabilir regresyon eğrileri (MARS)

Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS) yöntemi 1991 yılında Friedman tarafından geliştirilmiştir [21]. MARS modeli makine öğrenmesi gerçekleştirebilen regresyon tabanlı bir modeldir. Modelde girdi verileri kullanılarak Temel Fonksiyonlar (TF) oluşturulur. Oluşturulacak maksimum TF sayısı (maxTF) tasarımcı tarafından belirlenmesi gereken ve ağın performansını etkileyen önemli bir parametredir. maxTF değeriyle birlikte ağda ceza değeri de bulunmaktadır. Ağda bulunan ceza değeri girdi verilerinin tamamının oluşturulan TF'ler içerisinde bulunmasını ifade etmektedir. Yüksek ceza değeri atanması durumunda ağ tüm değişkenleri kullanarak TF oluşturmak için çalışacağından ağın performansının olumsuz etkilenmesi durumu ortaya çıkacaktır. maxTF değeri ve ceza değeri MARS modelleri için tasarımı etkileyen en önemli hususlar arasında sayılabilir. MARS modelinde oluşturulan bu TF'lerden eğriler elde edilerek birbiri ile kesiştirilir. Kesişimin en fazla kaç noktadan yapılacağı da tasarımcı tarafından belirlenen diğer bir parametredir. Belirlenen kesişim noktası sayısı kadar noktadan fonksiyon eğrileri ağ tarafından kesiştirilir ve bu kesişim Genelleştirilmiş Çapraz Budama (GÇB) prensibi ile budanarak seriden tek bir eğri elde edilir. Elde edilen eğri

Tahmin Fonksiyonu (PF) olarak adlandırılır ve MARS modeli bu fonksiyonu kullanarak tahmin işlemini gerçekleştirir. Çalışmada maxTF, ceza değeri ve kesişim değeri deneme-yanılma yöntemi ile belirlenmiştir. Sırasıyla maxTF, ceza değeri ve kesişim değeri, 35, 1 ve 1 olarak belirlenmiştir.

2.2.4 Destek vektör makineleri (SVM)

Destek Vektör Makineleri (SVM) Cortes ve Vapnik (1995) tarafından geliştirilen regresyon tabanlı bir modeldir [22]. SVM makine öğrenmesi gerçekleştiren bir model olduğundan sınıflandırma ve tahminleme gibi uygulamalarda kullanılmaktadır. Model temel olarak iki farklı veri grubu arasında optimum ayırım sınırlarını veya hiper düzlemlerini belirlemektedir. Hidrolojik zaman serileri gibi doğrusal olmayan zaman serilerinde ayırım için doğrusal bir hiper düzlem çizmenin mümkün olmayacağı durumlarda SVM kernel çekirdek kullanılmaktadır. Kernel çekirdek yöntemi doğrusal olmayan verilerdeki makine öğrenmesini önemli bir şekilde arttırmaktadır [23]. SVM modeli eşitlikleri, Vapnik teorisinin bir parçası olarak ifade edilebilmektedir. SVM modeli çözüm eşitliği Eşitlik (1)'de görülmektedir.

Burada, N veri sayısı, X_k girdi parametreleri, T_k hedef değerleri, w ağırlık değerlerini, b sabit değeri, C düzenleme

sabitini, ε fonksiyon hata toleransını ve ξ ise esneklik sabitlerini ifade etmektedir [24].

$$\text{Minimum } \frac{1}{2} \|W\|^2 + C \sum_{k=0}^N (\varepsilon + \varepsilon^*)$$

Sınır durumlar; (1)

$$\begin{aligned} T_k - \langle w_i, X_k \rangle - b &\leq \varepsilon_k - \xi \\ \langle w_i, X_k \rangle + b - T_k &\leq \varepsilon_k + \xi^* \\ \varepsilon_k, \varepsilon_k^* &\geq 0, k = 1, \dots, N \end{aligned}$$

Ağda çalışacak bu çekirdek fonksiyonunun seçilmesi ağın performansını etkileyen önemli bir parametredir. Çalışmada çekirdek fonksiyonu olarak, literatürde başarılı sonuçlar ürettiği görülen Radyal Tabanlı Fonksiyon (RTF) olarak seçilmiştir [25]. Ayrıca RTF hidrolojik örüntülerin modellenmesi ve tahmin edilmesi için kullanımı önerilmiştir [26]. Kernel fonksiyonu olarak kullanılan RTF Eşitlik (2)'de görülmektedir.

$$k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (2)$$

Burada, x destek vektörü, $k(x, x_i)$ çekirdek fonksiyonu, σ RTF sabitini ifade etmektedir [24]. SVM modellemesinde çekirdek fonksiyonu olarak RTF seçildiğinde eğitim işlemleri için tasarımcı tarafından belirlenmesi gereken temel parametreler mevcuttur. C , ε , γ olan bu parametreler ağın eğitim aşamasında katsayıların optimizasyonu konusunda önemli parametrelerdir. Ağın optimum ağırlık değerleri kazanması ağın üreteceği çıktı performansını doğrudan etkilemektedir [27]. Çalışmada C , ε , γ değerleri deneme-yanılma yöntemi ile belirlenmiş olup, en yüksek performansa erişilen değerler sunulmuştur.

2.2.5 Veri setlerinin ve girdi kombinasyonlarının hazırlanması

Çalışmada gelecek akış tahmini yapmak üzere oluşturulan yağış-akış modelinde girdi verileri günlük ortalama akış ve günlük toplam yağış olarak seçilmiştir. Kullanılan akış verileri D22A090 numaralı AGİ'den alınmıştır. Analiz bölgesi olan AGİ konumundaki yağış verileri, analiz bölgesindeki AGİ'de direkt yağış ölçümü yapılmadığından, havza genelindeki Meteoroloji İstasyonları (Mİ) kullanılarak oluşturulan Thiessen Çokgenlerine uygun biçimde elde edilmiştir. Havzada kullanılan Mİ'ler ve Thiessen Çokgenleri Şekil 2'de görülmektedir. Çizilen Thiessen Çokgenlerine göre; 17034 numaralı Giresun istasyonu, Doğu Karadeniz Havzası'nda seçilen Mİ'lerden, analiz bölgesini etkin olan tek istasyon olarak belirlenmiş olup, günlük toplam yağış verileri 17034 numaralı Mİ'den alınmıştır. En uzun süre kesintisiz veri setinin sağlanması amacıyla AGİ verilerinin aralığı olan 1996-2004 yılları aralığı seçilmiştir. Veri seti %70 eğitim, %15 doğrulama ve %15 test grubu olarak ayrılmıştır. YAM çıktısı olan gelecek akış tahmin etmek üzere hazırlanan girdi setleri Tablo 2'de gösterilmiştir. Burada Q günlük ortalama akışı, P günlük toplam yağış ve t gün cinsinden zamanı ifade

etmektedir. Tahmin yapılacak gün t olarak, daha önceki günler (t-1, t-2, ..., t-n) olarak gösterilmiştir.

3 Bulgular ve tartışma

Gelecek akışı tahmin etmek üzere Aksu Deresi üzerinde bulunan D22A090 numaralı AGİ konumunda yapılan optimum YAM araştırmasında kullanılan ANFIS, YSA, MARS ve SVM yöntemlerinde 8 adet girdi kombinasyonu denenmiştir. Modellerin tümünde veri sayısına bağlı olarak korelasyon katsayısı için yapılan değerlendirmede tüm modellerin hedeflenen verilere yüksek korelasyonda yakınsayan tahmin verileri ürettiği gözlemlenmiştir.

ANFIS yöntemi ile geliştirilen YAM performans verileri girdi modellerine göre Tablo 3'te görülmektedir. ANFIS-YAM modelinde denenilen farklı ÜF'ler arasından, kullanılan verilere en uygun olan fonksiyonun üçgen tip olduğu görülmektedir. Üçgen tip ÜF kullanılarak bulanıklaştırılan verilerin tüm girdi modellerinde diğer ÜF tiplerine göre daha yüksek performans elde ettiği belirlenmiştir. ANFIS-YAM'da girdi modellerine göre yapılan değerlendirmede, girdi modelindeki parametre sayısının artışı model performansını olumsuz etkilemiştir. Girdi modelindeki parametrelerin ANFIS yönteminde bulanık kural tabanındaki kural sayısındaki artışa neden olması bu durumun esas kaynağı olarak belirlenebilir. ANFIS-YAM'da en yüksek performans değerine ulaşan üçgen tip ÜF sayısının girdi modelleri için artırılması da kural sayısını arttırdığından ANFIS yöntemi ile oluşturulan YAM için optimum çözüm 2 ÜF kullanılan ve geçmiş akış verilerinden gelecek akışı tahmin eden ANFIS-YAM-M2-2Ü olduğu görülmektedir.

YSA yöntemi ile oluşturulan YAM için optimum çözüm araştırması için gizli katmanda farklı sayılarda nöron denenmiş olup nöron sayısına bağlı olarak performans çıktılarına değıştiği gözlenmiştir. YSA-YAM tüm girdi modellerine karşılık ürettiği tahmin çıktıları, hedef veri setine yüksek korelasyonla yakınsamaktadır. Yüksek korelasyon ile tahminleme performansı YSA-YAM'ı gelecek debinin trendleri hakkında kullanılabilir duruma getirmektedir. YSA-YAM'da girdi modellerindeki parametre artışının belirli bir düzeye kadar olan artışının ağ performansını olumlu etkilediği görülmüştür. YSA-YAM'da performansı en yüksek girdi modeli M5 olmuştur. M5 girdi modelinde akış verileri 3 güne kadar, yağış verileri ise 1 güne kadar gecikmeli olarak verilmiştir. Performansı en yüksek olan YSA-YAM-M5-6 için performans verileri Tablo 4'te görülmektedir.

MARS yönteminin kullanıldığı YAM kullanılarak yapılan gelecek akış tahminlerinde girdi parametrelerindeki artışın belirli bir düzeyden sonra sabit değer üretme eğiliminde olduğu görülmüştür. MARS modeli belirlenen maksimum sayıda TF'yi üretmek bunlar arasından en uygun PF'yi elde etmektedir. Girdi parametrelerinin PF'ye katılma durumu çalışmada tasarlanan yapıda ceza değerinin düşük veya 0 düzeyinde tutulması ile sınırlandırılmış ve bu sayede ağın bütün girdi parametrelerini PF'ye katma zorunluluğu engellenmiştir. Tablo 5'te yer alan MARS-YAM performans verileri incelendiğinde M1 girdi modelinden M5'e kadar girdi parametrelerindeki artışın PF tahmin performansını

olumlu etkilediği ancak girdi modeline M5 parametresinden farklı olarak katılan P(t-2), P(t-3), P(t-4) parametrelerinin PF'ye katılma durumunun olmadığı belirlenmiştir. Bu durumda M5, M6, M7 ve M8 girdi modelleri için MARS-YAM tarafından seçilen PF'de M5 ile aynı girdi parametreleri etkin olduğundan aynı performans değeri elde edilmiştir. Ceza değerinin artırılarak PF'ye tüm girdi parametrelerinin katılması durumunda MARS-YAM'ın doğru tahmin üretme düzeyinin düşeceği görülmüştür. MARS-YAM M5, M6, M7 ve M8 girdi parametrelerinden oluşturulan TF ile PF'ye katılma düzeyi Tablo 6'da görülmektedir. Tablo 6'ya göre yapılan değerlendirmede Q(t) değerlerinin tahmin edilmesi için oluşturulan PF'de en etkin parametrenin P(t) olduğu görülmüştür. Q(t-3), P(t-2), P(t-3) ve P(t-4)'ün PF'ye katılmadığı, P(t-1)'in ise önem düzeyinin düşük olduğu görülmektedir.

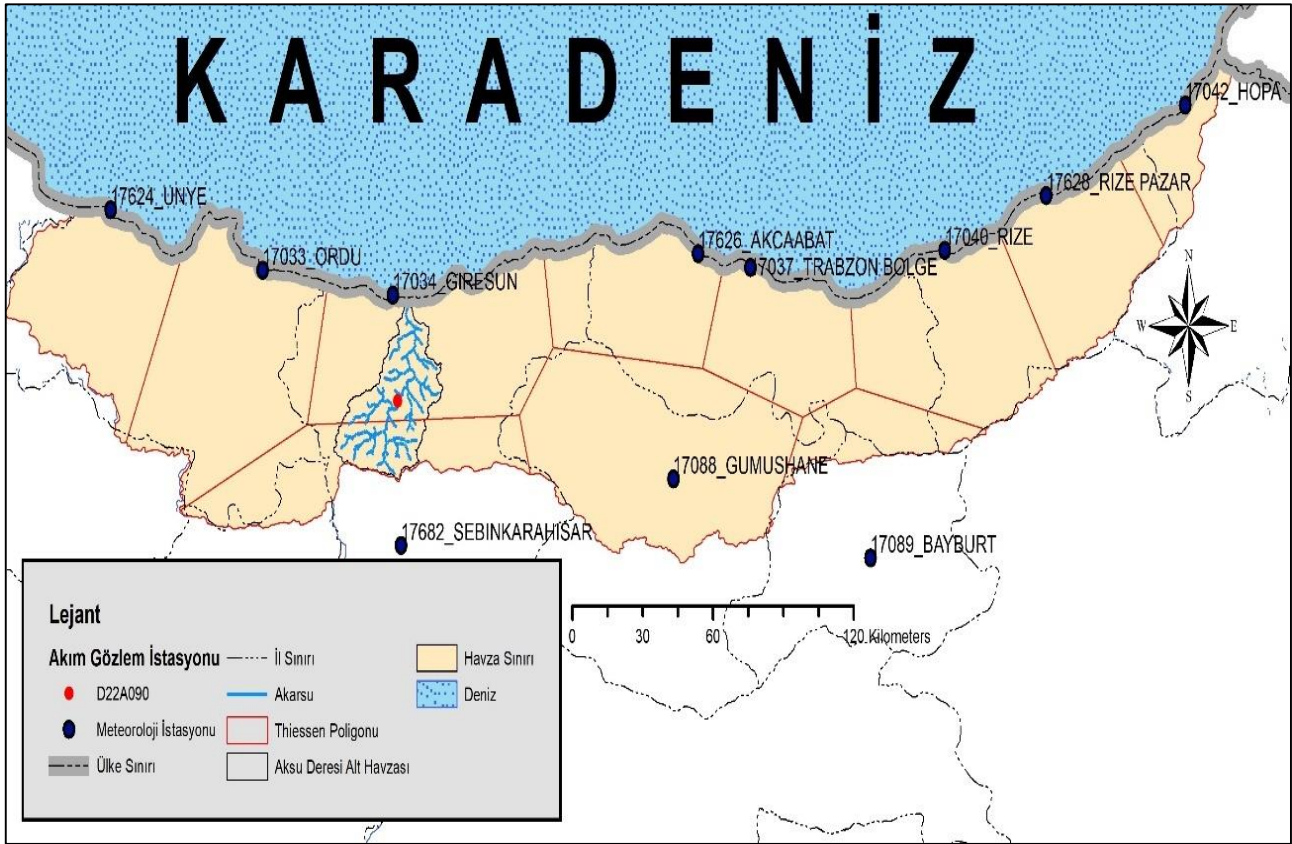
SVM yöntemi ile geliştirilen YAM'da çekirdek fonksiyonu olarak RTF seçilmiştir. RTF parametreleri olan C, ϵ ve γ her girdi modeli için deneme-yanılma yöntemiyle geniş bir aralıkta denenmiştir. Eğitim aşamasında girdi modellerinde elde edilen en yüksek performans değerine göre tahminleme yapılmıştır. SVM-YAM'da eğitim aşamasında modellere göre en yüksek performans değerine ulaşan RTF parametre değerleri ile girdi modellerine göre elde edilen en yüksek performans verileri Tablo 7'de verilmiştir. SVM-YAM'da girdi modelindeki parametre sayısında yaşanan artışın ağırlık tahminleme performansını olumlu etkilediği görülmüştür. M8 modelinde akış verileri 3 güne, yağış verileri ise 4 güne

kadar geciktirilmiş düzeyde ayrı parametreler halinde ağ girdi olarak tanımlanmıştır. SVM-YAM-M8 modeli SVM yöntemiyle geliştirilen YAM'lar içerisinde en yüksek performans değerine ulaşan model olmuştur.

4 Sonuçlar

Aksu Deresi üzerinde 4 farklı yöntem kullanılarak YAM geliştirilmiştir. Geliştirilen tüm modellerin performans verileri, uzun yıllar kesintisiz olan veri setini tahmin etme konusunda başarılı olmuştur. Literatürde hidrolojik parametrelerin tahmin edilmesi konusunda sıklıkla kullanılan AI yöntemleri, daha az kullanım alanı bulan sezgisel regresyon modeli MARS ve diğer bir regresyon tabanlı model olan SVM ile YAM oluşturma performansı kıyaslanmıştır.

Literatürde yaygın kullanım alanı bulan AI yöntemleri ile oluşturulan YAM'lar donanım bağımlılığı yüksek modellerdir ancak daha az girdi parametresi ile korelasyonu yüksek tahminleme yapabilmektedir. AI modellerinin arkaplanda çok fazla denklem çalıştırması ve kolay açıklanabilir olmaması bu modellerin esneklik düzeyini azaltmaktadır. HR yöntemi MARS ve regresyon tabanlı olan SVM ile geliştirilen YAM'lar daha fazla girdi parametresi kullanarak daha yüksek performans verileri elde etmiştir. Bu modellerin AI yöntemlerine göre daha az donanım bağımlı olması ve kolay açıklanabilir olması yöntemlerin esnekliğini arttırmaktadır.



Şekil 2. Doğu Karadeniz Havzası Thiessen Poligonu çalışması

Tablo 3. ANFIS-YAM performans verileri

Ü.F Sayısı	Ü.F.	Performans	ANFIS Girdi Kombinasyonu							
			M1	M2	M3	M4	M5	M6	M7	M8
2	Gen. Çan	RMSE	3.970	3.749	4.960	10.25	16.78	14.09	14.59	14.11
		R	0.922	0.931	0.888	0.754	0.578	0.641	0.644	0.647
		MAE	1.202	1.088	1.220	1.696	1.917	2.086	2.187	2.101
2	Gauss	RMSE	3.974	3.772	3.968	6.293	10.18	11.88	11.47	9.280
		R	0.922	0.930	0.922	0.838	0.674	0.651	0.693	0.744
		MAE	1.208	1.105	1.180	1.368	1.744	1.986	1.903	1.762
2	Üçgen	RMSE	3.946	3.682	3.707	3.690	5.669	5.764	6.915	5.758
		R	0.923	0.934	0.931	0.932	0.853	0.849	0.801	0.851
		MAE	1.210	1.103	1.147	1.172	1.442	1.564	1.727	1.738
3	Üçgen	RMSE	3.964	3.726	4.707	7.028	7.900	9.503	15.44	17.50
		R	0.922	0.931	0.901	0.845	0.822	0.723	0.621	0.580
		MAE	1.198	1.087	1.317	1.519	1.740	1.913	2.754	3.099

Koyu sembol ile yazılan değerler en yüksek performans değerinin elde edildiği modeli ifade etmektedir.

Ü.F. : Üyelik fonksiyonu

Gen. Çan: Genelleştirilmiş Çan Eğrisi

Tablo 4. YSA-YAM performans verileri

Nöron Sayısı	Performans	YSA Girdi Kombinasyonu							
		M1	M2	M3	M4	M5	M6	M7	M8
3	RMSE	4.266	4.071	4.048	4.039	4.015	4.055	3.988	4.125
	R	0.922	0.930	0.930	0.930	0.931	0.930	0.933	0.927
	MAE	1.534	1.482	1.458	1.523	1.503	1.524	1.461	1.549
6	RMSE	4.186	4.136	4.204	4.176	3.875	3.984	4.091	4.064
	R	0.925	0.928	0.926	0.925	0.936	0.932	0.929	0.929
	MAE	1.564	1.691	1.588	1.538	1.477	1.593	1.616	1.630
9	RMSE	4.286	4.147	4.319	4.302	5.725	4.004	4.062	3.979
	R	0.922	0.927	0.923	0.920	0.886	0.932	0.930	0.932
	MAE	1.613	1.455	1.557	1.662	1.743	1.650	1.824	1.577
12	RMSE	4.247	4.146	4.090	4.412	4.649	5.932	4.759	4.094
	R	0.923	0.927	0.928	0.917	0.909	0.858	0.905	0.928
	MAE	1.623	1.684	1.558	1.719	1.874	1.989	1.794	1.666
15	RMSE	5.307	4.108	4.660	4.206	4.143	4.086	4.158	4.984
	R	0.876	0.930	0.913	0.926	0.927	0.929	0.927	0.894
	MAE	1.729	1.585	1.585	1.741	1.909	1.727	1.744	1.802
18	RMSE	5.584	4.106	4.270	4.507	4.103	4.121	4.528	4.167
	R	0.884	0.930	0.924	0.912	0.929	0.927	0.912	0.926
	MAE	1.731	1.433	1.539	1.659	1.629	1.577	1.682	1.662
21	RMSE	5.490	4.167	4.175	4.126	4.035	4.321	4.305	4.524
	R	0.867	0.926	0.926	0.927	0.930	0.921	0.921	0.912
	MAE	1.795	1.856	1.760	1.486	1.624	1.666	1.662	1.817

Koyu sembol ile yazılan değerler en yüksek performans değerinin elde edildiği modeli ifade etmektedir.

Tablo 5. MARS-YAM performans verileri

MARS Girdi Kombinasyonu	Performans		
	RMSE	R	MAE
M1	3.845	0.926	1.229
M2	3.382	0.943	1.280
M3	3.382	0.943	1.280
M4	3.172	0.950	1.311
M5	3.101	0.952	1.302
M6	3.101	0.952	1.302
M7	3.101	0.952	1.302
M8	3.101	0.952	1.302

Koyu semboller performansı en yüksek modeli göstermektedir.

Tablo 6. MARS-YAM M5, M6, M7 ve M8 girdi parametrelerinin PF'ye katılma durumu

Girdi Kombinasyonu	Parametrelerin PF'ye Katılma Sayısı							
	Q _(t-1)	Q _(t-2)	Q _(t-3)	P _(t)	P _(t-1)	P _(t-2)	P _(t-3)	P _(t-4)
M5	5	3	0	6	1	x	x	x
M6	5	3	0	6	1	0	x	x
M7	5	3	0	6	1	0	0	x
M8	5	3	0	6	1	0	0	0

x: Parametre bu modelde bulunmuyor

Tablo 7. SVM-YAM performans verileri

Model Parametreleri (C, ε, γ)	SVM-RBF Kombinasyonu	Girdi	RMSE	Performans	
				R	MAE
(5, 0.001, 0.500)	M1		3.958	0.922	1.095
(10, 0.0001, 0.125)	M2		3.730	0.932	0.987
(10, 0.001, 0.330)	M3		3.639	0.934	0.977
(10, 0.001, 0.250)	M4		4.041	0.936	2.460
(10, 0.001, 0.125)	M5		3.641	0.934	0.967
(10, 0.001, 0.167)	M6		3.627	0.935	0.963
(5, 0.001, 0.200)	M7		3.618	0.935	0.959
(10, 0.001, 0.125)	M8		3.616	0.935	0.956

Koyu semboller performansı en yüksek modeli göstermektedir.

Çalışmadan elde edilen bulgulara göre AI, HR ve regresyon tabanlı yöntemler ile geliştirilen YAM'ların tamamı yüksek performans verileri elde ederek tahminleme yapmıştır, bu durum geliştirilen YAM'ların bölgede gelecek taşkınlar hakkında fikir verebilecek günlük ortalama debi tahmini yapmak ve tahmin edilecek gelecek debi verilerinin altyapı tesislerini boyutlandırmak için kullanılabilir olduğunu göstermektedir. Literatürde bölgede geçmiş yıllarda gerçekleştirilen çok fazla YAM çalışması bulunmamakla birlikte, yapılan çalışma [8] incelendiğinde, YSA ile geliştirilen modellerin performans verilerinin, bu çalışma bulgularına paralel olarak MARS ile geliştirilen modele kıyasla daha düşük performans değerine ulaştığı görülmüştür. Bu nedenle bölgede yağış-akış arasındaki ilişkinin sezgisel regresyon teknikleri ile daha iyi açıklanabildiği sonucuna ulaşabilmektedir. Bu çalışmada elde edilen bulgular kullanılarak D22A090 numaralı AGİ'nin en yakın memba ve mansabındaki AGİ konumlarında, benzer sayısal yöntemler kullanılarak, yağış-akış analizlerin yapılması, çalışmada geliştirilen modellerin bölge için kalibrasyonunu sağlayacaktır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %8

Kaynaklar

[1] D. Hughes, P. Greenwood, G. Coulson and G. Blair, Gridstix: Supporting flood prediction using embedded hardware and next generation grid middleware. International Symposium on a World of Wireless,

Mobile and Multimedia Networks (WoWMoM'06), pp. 6-12, New York, 2006.

- [2] A. S. Tokar and P. A. Johnson, Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4, 232-239, 1999. [https://doi.org/10.1061/\(ASCE\)1084-0699\(1999\)4:3\(232\)](https://doi.org/10.1061/(ASCE)1084-0699(1999)4:3(232)).
- [3] G. Blöschl, M. F. Bierkens, A. Chambel, C. Cudennec, G. Destouni, A. Fiori and M. Renner. Twenty-three unsolved problems in hydrology (UPH)—a community perspective. *Hydrological Sciences Journal*, 64(10), 1141-1158, 2019. <https://doi.org/10.1080/02626667.2019.1620507>.
- [4] P. K. T. Mishra and S. Karmakar, Performance of optimum neural network in rainfall-runoff modeling over a river basin. *International Journal of Environmental Science and Technology*, 16(3), 1289-1302, 2019. <https://doi.org/10.1007/s13762-018-1726-7>.
- [5] M. Peel and T. A. McMahon, Historical development of rainfall-runoff modeling. *Wiley Interdisciplinary Reviews: Water*, 7(5), 1471-1486, 2020. <https://doi.org/10.1002/wat2.1471>.
- [6] J. Sitterson, C. Knightes, R. Parmar, K. Wolfe and M. Muiche, An overview of rainfall-runoff model types. 9th International Congress on Environmental Modelling and Software, pp. 41-50, Colorado, USA, 24-28 Jun 2018.
- [7] M. Ashrafi, L. H. Chua and C. Quek, The applicability of Generic Self-Evolving Takagi-Sugeno-Kang neuro-fuzzy model in modeling rainfall-runoff and river

- routing. *Hydrology Research*, 50(4), 991-1001, 2019. <https://doi.org/10.2166/nh.2019.146>.
- [8] Ö. Yüksek, H. T. Babacan ve F. Saka, Yağış-akış modellemesinde optimum yapay sinir ağı yapısının araştırılması. *Türk Hidrolik Dergisi*, 2(1), 31-37, 2018.
- [9] R. M. Adnan, A. Petroselli, S. Heddami, C. A. Santos and O. Kisi, Comparison of different methodologies for rainfall-runoff modeling: machine learning vs conceptual approach. *Natural Hazards*, 105(3), 2987-3011, 2021. <https://doi.org/10.1007/s11069-020-04438-2>.
- [10] M. Jahandideh-Tehrani, G. Jenkins and F. A. Helfer, Comparison of particle swarm optimization and genetic algorithm for daily rainfall-runoff modelling: a case study for Southeast Queensland, Australia. *Optimization and Engineering*, 22(1), 29-50, 2021. <https://doi.org/10.1007/s11081-020-09538-3>.
- [11] A. Talei, L. H. C. Chua and T. S., Wong, Evaluation of rainfall and discharge inputs used by Adaptive Network-based Fuzzy Inference Systems (ANFIS) in rainfall-runoff modeling. *Journal of Hydrology*, 391(3-4), 248-262, 2010. <https://doi.org/10.1016/j.jhydrol.2010.07.023>.
- [12] M. Kwon, H. H. Kwon and D. A. Han, hybrid approach combining conceptual hydrological models, support vector machines and remote sensing data for rainfall-runoff modeling. *Remote Sensing*, 12(11), 1801-1822, 2020. <https://doi.org/10.3390/rs12111801>.
- [13] J. Adamowski, H. F. Chan, S. O. Prasher and V. N. Sharda, Comparison of multivariate adaptive regression splines with coupled wavelet transform artificial neural networks for runoff forecasting in Himalayan micro-watersheds with limited data. *Journal of Hydroinformatics*, 14(3), 731-744, 2012. <https://doi.org/10.2166/hydro.2011.044>.
- [14] DSİ 2020 yılı resmi su kaynakları istatistikleri, <https://www.dsi.gov.tr/Sayfa/Detay/1499> Erişim: 13.02.2022
- [15] P. Hosseinzadeh Talaei, Multilayer perceptron with different training algorithms for streamflow forecasting. *Neural Computing and Applications*, 24(3), 695-703, 2014. <https://doi.org/10.1007/s00521-012-1287-5>.
- [16] W. Wang, P. H. Van Gelder, J. Vrijling and J. Ma, Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*, 324(1-4), 383-399, 2006. <https://doi.org/10.1016/j.jhydrol.2005.09.032>.
- [17] H. T. Babacan, İklim değişikliğinin akarsu akışları üzerindeki etkisinin araştırılması: Doğu Karadeniz Havzası Örneği, Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2021.
- [18] J. S. Jang, ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), pp. 665-685, 1993. <https://doi.org/10.1109/21.256541>.
- [19] N. N. Ozyurt and E. A. Sezer, Daily streamflow prediction by ANFIS modeling: Application to lower zamanti karst basin, Turkey. *Journal of Intelligent and Fuzzy Systems*, 23(6), 305-311, 2012.
- [20] M. Kabir and M. M. J. Kabir, "Fuzzy membership function design: An adaptive neuro-fuzzy inference system (ANFIS) based approach, 2021 International Conference on Computer Communication and Informatics (ICCCI), pp. 1-5, Narashino, Japan, 27-29 Jan 2021. <https://doi.org/10.1109/ICCCI50826.2021.9402633>.
- [21] J. H. Friedman, Multivariate adaptive regression splines. *The Annals of Statistics*, 19(1), 1-67, 1991. <https://doi.org/10.1214/aos/1176347963>.
- [22] C. Cortes and V. Vapnik, Support-vector networks, *Machine Learning*, 20(3), 273-297, 1995. <https://doi.org/10.1007/BF00994018>.
- [23] H. Arslan, F. Üneş, M. Demirci, B. Taşar, ve A. Yılmaz, Keban baraj gölü seviye değişiminin ANFIS ve destek vektör makineleri ile tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(2), 71-77, 2020. <https://doi.org/10.47495/okufbed.748018>.
- [24] S. K. Himanshu, A. Pandey and B. Yadav, Assessing the applicability of TMPA-3B42V7 precipitation dataset in wavelet-support vector machine approach for suspended sediment load prediction. *Journal of Hydrology*, 550, 103-117, 2017. <https://doi.org/10.1016/j.jhydrol.2017.04.051>.
- [25] S. Ayhan ve Ş. Erdoğan, Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201, 2014.
- [26] M. A. Ghorbani, R. Khatibi, A. Goel, M. H. FazeliFard and A. Azani, Modeling river discharge time series using support vector machine and artificial neural networks. *Environmental Earth Sciences*, 75(8), 1-13, 2016. <https://doi.org/10.1007/s12665-016-5435-6>.
- [27] A. Lal and B. Datta, Development and implementation of support vector machine regression surrogate models for predicting groundwater pumping-induced saltwater intrusion into coastal aquifers. *Water Resources Management*, 32(7), 2405-2419, 2018. <https://doi.org/10.1007/s11269-018-1936-2>.

