


## Günlük Akarsu Akım Verilerinin Destek Vektör Makinesi ve Dalgacık Dönüşümü ile Modellenmesi: Çoruh Havzası Büyükdere Çayı Örneği

Ulviye ZİYA<sup>1</sup>, Mehmet Ali HİNİS<sup>1\*</sup>

<sup>1</sup> Aksaray Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Aksaray, Türkiye

Alındı/Received: 02/05/2024; Kabul/Accepted: 25/07/2024; Yayın/Published: 29/11/2024

! Makale birinci yazarın yüksek lisans tezinden üretilmiştir.

\* Sorumlu yazar e-posta: [mhinis@aksaray.edu.tr](mailto:mhinis@aksaray.edu.tr)

### Öz

Günlük akarsu akımlarının tahmini su yapılarının işletilmesi, kontrolü ve yönetimi için önemlidir. Kısa süreli akım değerlerinin tahmini birçok parametreye bağlı ve değişkenlik gösteren zor bir görevdir. Günlük, haftalık gibi kısa süreli akış tahminleri, bir havzadaki belirli bir rezervuarın önümüzdeki kısa zaman boyunca akışını tahmin etmek için kullanılır. Bu tahminler, mevcut su kaynaklarının optimum kullanımı için rezervuarda depolamasının aktif olarak düzenlenmesini gerektiren hidroelektrik güç planlaması ve taşkın azaltmayı planlamak için kullanılır. Bu sebeple gerek akarsu yapılarının yönetiminde rezervuarda ne kadar su biriktirileceği veya bırakılacağı belirlenmesinde gerekse üretilecek enerji miktarının belirlenmesinde kısa süreli akım tahminlerine ihtiyaç duyulmaktadır. Bu sebeple kısa süreli akımlar için en uygun tahminin yapılabilmesi su yapılarının yönetiminde hayati öneme sahiptir. Bu çalışmada günlük akım verilerinin kısa süreli akım tahminlerinde son yıllarda geliştirilmiş ve sıklıkla tercih edilen makine öğrenmesi yöntemlerinden birisi olan Destek Vektörleri Makineleri (DVM) incelenmiştir. Çoruh havzasında bulunan Büyükdere Çayına ait 1981-2009 yılları arasında ölçülmüş 10168 adet günlük akım verileri kullanılarak bu yöntem ile geliştirilen modeller sonuçlarının iyileştirilmesi için dalgacık dönüşümü kullanılarak hibrit modeller elde edilmiş ve günlük akım verileri için en uygun modeller araştırılmıştır. Geliştirilen modeller arasında 1,2 ve 5 günlük geciktirilmiş akım verilerin kullanılarak geliştirilen Dalgacık dönüşümlü DVM (WDVM04) modeli çeşitli istatistik kriterleri (R:0.998; NSE:0.996; KGE:0.993; PI:0.039; RMSE:0.304 ve MAPE:0.056) kullanılarak en iyi model olarak bulunmuştur.

**Anahtar Kelimeler:** Destek vektörleri makineleri, günlük akarsu akımı, dalgacık dönüşümü

## Estimation of Daily Stream Flow Data Using Support Vector Machines and Wavelet Transform Model

### Abstract

Estimating daily stream flows is significant for water structure operation, control, and management. Estimating short-term current values is difficult, depending on many parameters and variables. Short-term flow forecasts, such as daily, weekly, etc., are used to predict the flow of a particular reservoir in a basin over the next short period. These forecasts are used to plan hydroelectric power planning and flood mitigation, which requires active regulation of reservoir storage for optimal use of available water resources. For this reason, short-term flow forecasts are needed to determine how much water will be accumulated or left in the reservoir to manage river structures and to determine the amount of energy to be produced. Consequently, making the most appropriate prediction for short-term flows is vital in managing water structures. Support Vector Machines (SVM), one of the frequently preferred machine learning methods developed in recent years for short-term flow forecasting using daily flow data, were examined in this study. Hybrid models were obtained using wavelet transform to improve the results of the models developed with this method, using 10168 daily flow data of Büyükdere Stream in the Çoruh basin, measured between 1981 and 2009, and the most suitable models for daily flow data were investigated. Among the developed models, the Wavelet Transform SVM (WDVM04) model, developed using 1, 2, and 5-days lagged flow data, was used using various statistical criteria (R: 0.998; NSE: 0.996; KGE: 0.993; PI: 0.039; RMSE: 0.304 and MAPE: 0.056) was found to be the best model.

**Key Words:** Support vector machines, daily stream flow, wavelet transform

**Atf / To cite :** Ziya U, Hınıs MA (2024). Günlük Akarsu Akım Verilerinin Destek Vektör Makinesi ve Dalgacık Dönüşümü ile Modellenmesi: Çoruh Havzası Büyükdere Çayı Örneği. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi, 6(2): 18-32.

## 1. GİRİŞ

Su kaynakları mühendisliği plan ve projelendirme çalışmalarında kullanılan en önemli veriler arasında akarsu akımları, yeraltı su seviyeleri, yağış, akış, sızma ve buharlaşma değerleri sayılabilir. Bu verilerin sağlıklı şekilde elde edilmesi, eksik olan verilerin tamamlanması ve geleceğe yönelik tahmin yapılması planlamanın sağlıklı yapılabilmesi için en önemli aşamadır. Taşkın ve kurak zamanlar ve bu zamanlardaki akım tahminleri büyük ve küçük hidrolik yapıların tasarımında ve yönetiminde önemlidir. Akım tahminlerinde uzun süreli ve kısa süreli akımların tahmin edilmesi planlama açısından kısa süreli ve uzun süreli planlamaların kolaylaştırılmasına ve su yapılarının tasarımına ışık tutacaktır.

Büyük debi, yüksek su seviyesi ve büyük hızlar ile karakterize edilen taşkın değerinin bilinmesi hidrolik yapılar için önemlidir. Aynı zamanda su yapılarının yönetilmesi esnasında gelecekte meydana gelecek olan büyük akım değerlerinin önceden kestirilmesi halinde depolama hacminin önceden tahmin edilip gerekli hazırlıkların yapılması için yeterli zaman kazanmak mümkündür. Özellikle baraj, bağlama ve su kuvveti tesislerinde taşkın debilerinin bilinmesi büyük önem taşır (Erkek ve Ağralıoğlu 1993). Hidrolik yapıların tasarımında akışların gelecekteki olası değerleri kullanılmaktadır. Rastgele değişken olan yağışlar sonucu oluşan akışların gelecekteki değerlerini önceden tam olarak kestirmek mümkün olamamakla beraber bu değişkenin gelecekteki durumu yapay sinir ağları ve türevleri olan çeşitli makine öğrenmesi yöntemleri ile yaklaşık olarak belirlenebilmektedir. Hidrolik yapıların tasarım ve işletilmesinde, debi tahminlerinde ve havzalarda yerleşke kurmaktan taşkın tahliyesine kadar uzanan ilgi alanlarında tahmin modelleri kullanmak zorunlu hale gelmiştir. Günlük akarsu akımlarının tahmini su yapılarının işletilmesi, kontrolü ve yönetimi için oldukça önemlidir. Kısa süreli akım değerlerinin tahmini birçok parametreye bağlı olarak değişkenlik gösteren zor bir konudur. Akış tahmin modellerinin doğruluğu ve becerisi, su kaynakları yönetimi kararları üzerinde doğrudan etkiye sahiptir. Su kaynakları yöneticilerine ve politika yapıcılara daha iyi ve bilinçli karar vermede yardımcı olmak için çeşitli istatistiksel ve kavramsal akış tahmin modelleri geliştirilmiştir. Regresyona dayalı modeller de dahil olmak üzere istatistiksel teknikler aşırı derecede basittir ve analizden önce değişkenler arasında işlevsel bir biçimde sınırlıdır. Kavramsal hidrolojik modeller, bir havzadaki akarsu akışını daha iyi simüle edebilir çünkü matematiksel formülasyon yoluyla hidrolojik döngünün çeşitli süreçlerini hesaba katarlar. Ancak son yıllarda geliştirilen çeşitli makine öğrenmesi yöntemleri ile daha uygun sonuçlar almak mümkün olmaktadır. Yapay zeka yöntemleri ve Makine Öğrenmesi yöntemleri; yüksek boyutlu verilerin daha düşük boyutlara indirgenmesi, kümeleme ve sınıflandırma analizleri gibi çok değişkenli veri incelenmesinde kullanılan istatistiksel yöntemlere alternatif olarak son yıllarda kullanılmaktadır (Liu ve Weisberg 2005). Akım verilerinin tahmin edilmesinde kullanılan yöntemler arasında yapay sinir ağlarına ilave olarak uzman sistemler ve son yıllarda giderek popülerlik

kazanan makine öğrenmesi yöntemleri sayılabilir. Bu yöntemler uygulanırken uzun dönem tahminlerinde (aylık, yıllık) daha iyi sonuçlar elde edilirken kısa dönem tahminlerinde (günlük, saatlik) aynı başarı elde edilememektedir.

Deo ve ark. (2017) üç farklı algoritmayla Çoklu Uyarlanabilir Regresyon Eğriler (MARS), En küçük kareler Destek Vektör Makineleri (LSSVM), M5 Karar ağaçlarını kuraklık analizleri üzerinde uygulamışlardır. Faizollahzadeh Ardabili ve ark. (2019) Rastgele Orman yönteminin hidrolojik modellemede etkin bir biçimde kullanılabileceğini göstermişlerdir.

Son yıllarda çeşitli yapay zeka tekniklerinin kuraklık tahminlerindeki kullanımına değinen Mokhtarzad ve ark. (2017), ANN, ANIFS ve SVM yöntemleri ile Bojnourd (İran) bölgesinde bir çalışma yapmışlardır. Bu çalışma Normalleştirilmiş Yağış İndisi (SPI) ile kuraklık analizi yapmış ve analiz sonuçlarını modellemiştir. 1984 – 2012 yılları arasında yağış verisini kullanarak SPI'ı 3 aylık zaman periyodunda modellemiştir. Mohamadi ve ark. (2020) ANFIS, MLP, Radyal Tabanlı Yapay Sinir Ağları (RBFNN) ve SVM algoritmalarından yararlanarak kuraklık modellemesi yapmış ve su kaynaklarının etkili yönetilmesinde son derece önemli olduğunu göstermiştir.

Choubin ve ark. (2016) aylık ortalama yağış verisini kullanarak Kuraklık analizi yapmış ve analiz için veri madenciliğinde yer alan Çok Katmanlı Algılayıcı (MLP), ANFIS ve Karar Ağaçları (MP5) yöntemlerinden yararlanmıştır. MLP ile yapılan analizlerin diğerlerinden daha iyi olduğu sonucuna ulaşmıştır. Ghorbani ve ark. (2016) akarsu akımı tahmininde MLP, RBFNN ve SVM yöntemlerini karşılaştırarak, MLP'nin diğer modellere göre daha iyi tahmin etme kabiliyetine sahip olduğunu ortaya koydular.

Günlük akım tahmininde son yıllarda kullanılan baskın yaklaşım, makine öğrenimi ve regresyon algoritmalarının uygulanmasıdır. Doğrusal modellerin (çoğunlukla zaman serisi modelleri) aylık ve yıllık olan daha büyük zaman ölçeklerinde daha rekabetçi olduğu bulunmuştur (Papacharalampous ve ark. 2018). Regresyon algoritmaları, belirli bir zamandaki bağımlı değişken akışını bir dizi seçilmiş öngörücü değişkenin (örneğin, geçmiş akış akış değerleri, geçmiş yağış değerleri ve geçmiş sıcaklık değerleri) fonksiyonu olarak modeller; son iki tür bilgi topluca "dışsal tahmin değişkenleri" olarak adlandırılır. Makine öğrenimi durumunda, bu işlev algoritmik bir yaklaşımla doğrudan verilerden öğrenilir. Günlük akış tahminine yönelik mevcut yaklaşımların çoğunlukla tek bir makine öğrenimi algoritmasının uygulanmasına dayanmaktadır.

Mevcut çalışmanın sonuçları, hidrolojik uygulamalar alanında günlük akış tahmini için kullanılabileceği gibi zaman serisi modellerinin görece performansının anlaşılmasını da geliştirecek sonuçlar içermektedir. Hidroloji bilimi uygulamalarında makine öğrenimi uygulamalarının daha iyi anlaşılmasını kolaylaştırarak sonuçlar sunulmuştur.

Bu çalışmada son yıllarda en çok kullanılan makine öğrenmesi yöntemleri arasında yer alan Destek Vektör Makineleri (DVM) kullanılarak baraj ve bağlama gibi önemli su yapılarının yönetilmesinde önemli yer alan günlük akarsu akımlarının modellenmesi ve akım değerlerinin ileriye yönelik tahmin edilmesinde yardımcı olacak bir model ortaya koymak amaçlanmıştır. DVM yöntemi ile hesaplanan modeli iyileştirmek için dalgacık dönüşümü kullanılmış ve model sonuçları çeşitli istatistik kriterler ile karşılaştırılarak en uygun model belirlenmiştir.

## 2. MATERYAL VE METOT

### 2.1. Çalışma Alanı ve Veri

Bu çalışmada Çoruh havzasında bulunan Büyükdere Çayına ait 1981-2009 yılları arasında ölçülmüş 10168 adet günlük akım verileri kullanılmıştır. Büyükdere Çayının coğrafi konumu Şekil 1'de gösterilmektedir. Büyükdere Çayı Bayburt ilinin önemli su kaynağı olan Çoruh ırmağına dökülmektedir. Bölgede Karadeniz iklimi ile Doğu Anadolu iklimi arasında, karasal özellikleri ağır basan bir geçiş iklimi mevcuttur. Bayburt'ta tüm yıllara ait ortalama yağış 433,4 mm olup en yüksek sıcaklık 36,2<sup>0</sup> C ve en düşük sıcaklık -26,2<sup>0</sup> C olarak görülmüş ve ortalama sıcaklık 7,0<sup>0</sup> C derecedir (Anonim 2024).

Bu amaç doğrultusunda, Çoruh havzasında bulunan Büyükdere Çayına ait 1981-2009 yılları arasında ölçülmüş 10168 adet günlük akım verileri eksiksiz olarak kullanılmıştır. Bu verilere ait modeller oluşturulup sonuçları değerlendirilmiştir. Devlet Su İşleri Genel Müdürlüğü'nden elde edilen günlük akım verileri Şekil 2'de verilmiştir. Verilerin %70'lik kısmı eğitim aşamasında, %30'luk kısmı ise test aşamasında kullanılmıştır. Kullanılan verilerin temel istatistiksel özetleri tablo 1'de verilmiştir. Bu çalışmada günlük akımları tahmin edebilmek için pek çok model oluşturulmuş ve bu oluşturulan modeller arasında en iyi sonuç veren yedi farklı model seçilmiştir. Çalışmada kullanılmak üzere geliştirilen Modeller tablo 2'de verilmiştir. Buna göre t gözlenen akış ve tahmin verisi zamanını, t-1; 1 günlük, t-2; 2 günlük, t-3; 3 günlük geçmişe yönelik ötele zamanını temsil etmektedir. Bu modeller üç farklı DVM eğitim (Lineer, Polinom ve Gauss) fonksiyonları kullanarak hesaplanmış ve sonuçlar karşılaştırılmıştır. Daha sonra Dalgacık Dönüşümü kullanılarak yine aynı yöntemler ile oluşturulan modeller hesaplanmış ve modeller birbirleri ile karşılaştırılarak sonuçları yorumlanmıştır.

**Tablo 1.** Verilen temel istatistik değerleri

	Tüm Veri	Eğitim Verisi	Test Verisi
Ortalama	3.851	3.848	3.860
St.Sapma	5.144	5.222	4.957
Varyasyon Katsayısı	1.336	1.357	1.284
Çarpıklık	2.577	2.735	2.138
Maks	70.476	70.476	30.610
Min	0.118	0.118	0.183

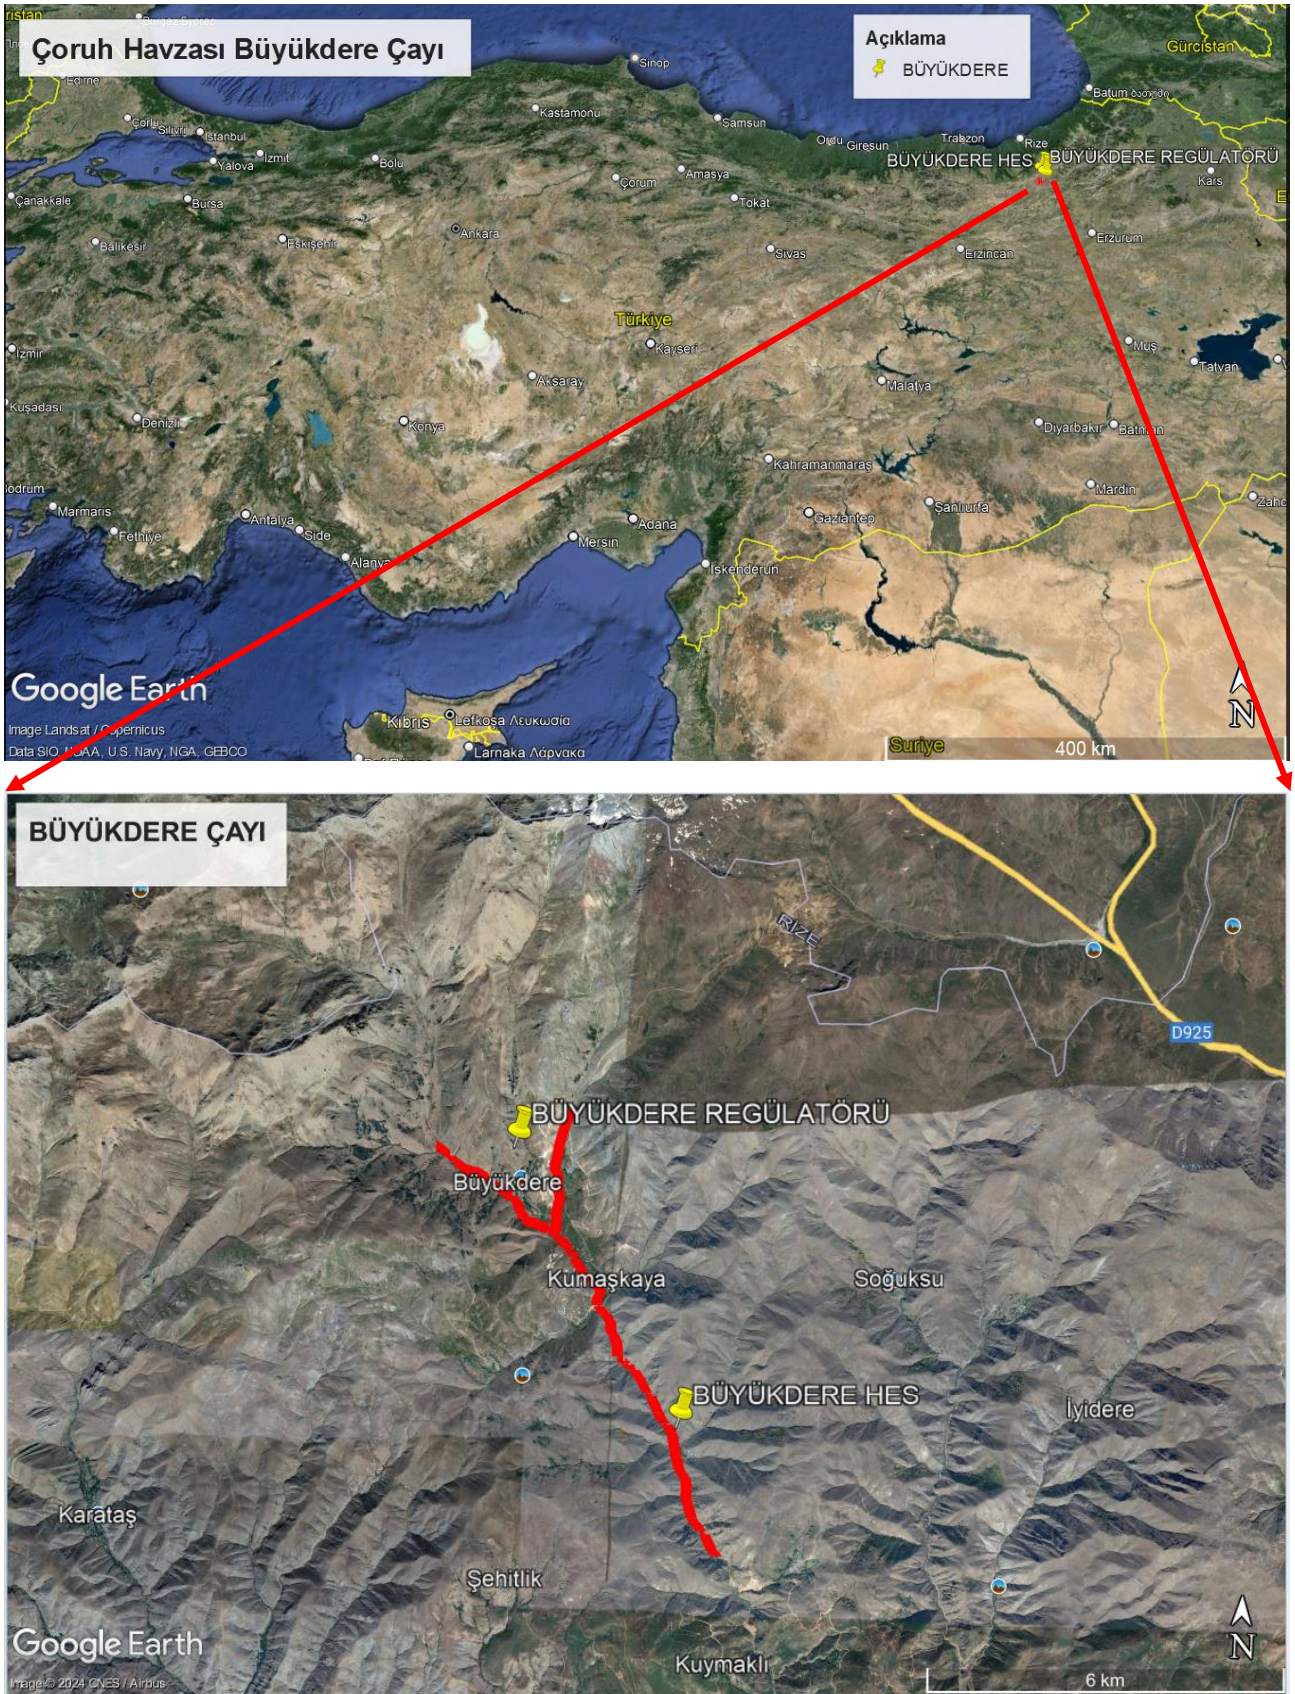
**Tablo 2.** Çalışmada kullanılan modeller

Modeller	Girdi	Çıktı
M01	$Q_{t-1}$	$Q_t$
M02	$Q_{t-1}, Q_{t-2}$	$Q_t$
M03	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
M04	$Q_{t-1}, Q_{t-2}, Q_{t-5}$	$Q_t$
M05	$Q_{t-1}, Q_{t-2}, Q_{t-6}$	$Q_t$
M06	$Q_{t-1}, Q_{t-2}, Q_{t-11}$	$Q_t$
M07	$Q_{t-1}, Q_{t-2}, Q_{t-30}$	$Q_t$


### 2.2. Destek Vektörleri Makinesi (DVM)

DVM modelleri başlangıçta doğrusal olarak ayrılabilir nesne sınıflarının sınıflandırılması için geliştirilmiştir. DVM'nin çalışma prensibi iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun tahmin edilmesidir. İki ayrı sınıftan doğrusal olarak ayrılabilir nesnelere oluşan iki boyutlu bir düzlemde bunları mükemmel şekilde ayıran bir sınıflandırıcı bulmak amaçlanmıştır. Bu nesnelere sınıflandırmak için SVM, maksimum marj üreten bir hiperdüzlem bulmaya çalışır (Vapnik 1995). Bu hiperdüzlem ile SVM, her sınıfın en yakın veri noktası arasındaki mesafeyi maksimuma çıkarır. Her iki sınıfın hiperdüzlemlerinin üzerine düşen nesnelere destek vektörleri olarak adlandırılır. Destek vektörleri en önemli eğitim noktalarıdır. Destek vektörleri Hiperdüzlemi tanımlar ve karar yüzeyinin optimum konumunun belirlenmesinde doğrudan etkiye sahiptir (Raghavendra ve Deka 2014). Gerçek zamanlı problemlerde, verileri uzayda bölen, ayırıcı bir hiperdüzlemi tam olarak belirlemek mümkün değildir ve ayrıca bazı durumlarda eğri bir karar sınırı elde edilebilir. Dolayısıyla SVM, ayrılamayan sınıflar için bir sınıflandırıcı olarak da kullanılabilir. Bu gibi durumlarda, orijinal girdi uzayı, özellik fonksiyonları adı verilen doğrusal olmayan fonksiyonlar kullanılarak her zaman daha yüksek boyutlu bir özellik uzayına (Hilbert uzayı) eşlenebilir. Özellik uzayı yüksek boyutlu olmasına rağmen, hiperdüzlemin sınıflandırılması için doğrudan özellik fonksiyonlarını kullanmak pratikte mümkün değildir. Bu gibi durumlarda, özellik fonksiyonları tarafından oluşturulan doğrusal olmayan haritalandırma, çekirdek (kernel) adı verilen özel doğrusal olmayan fonksiyonlar kullanılarak yapılabilir.

Çekirdek fonksiyonlarının seçimi daha iyi bir genelleme yapılmasını sağlar. Çekirdek fonksiyonu kullanılarak SVM'lerde doğrusal olmayan sınırlar oluşturulabilir ve böylece problem daha iyi tanımlanıp çözülebilir. Bu amaçla kullanılacak oldukça fazla sayıda çekirdek vardır. Bunlar arasında doğrusal, polinom, gauss fonksiyonları sayılabilir. Doğrusal olmayan çekirdekler (nonlineer kernel) sayesinde, SVM'ye karmaşık ayırıcı hiperdüzlemleri modelleme yeteneği verir.



Şekil 1. Büyükdere Çayının Coğrafi Konumu



Şekil 2. Büyükdere Nehri Günlük Akım değerleri

DVM veri seti üzerinde ortalama hata karesini minimize ederek türetilen ampirik risk minimizasyonu prensibinden ziyade, istatistiksel öğrenme teorisindeki yapısal risk minimizasyonu niteliğinde çalışmasıdır. Gerçek dünyada karşımıza çıkan problemlerin çoğu doğrusal olarak ayırabilen verilere sahip değildir. Bu durumda giriş verileri klasik yöntemle çözülmeyebilir. Böyle problemlerde ise doğrusal olmayan sınıflandırma yöntemi kullanılmaktadır (Cristianini ve Shawe-Taylor 2000).

Hidrolojik analizlerde pek çok parametre doğrusal olmama eğilimindedir. Bu sebeple doğrusal olmayan problemleri çözmek amacıyla girdi değişkenlerini daha yüksek boyutlu bir özellik uzayına dönüştürmek için doğrusal olmayan bir eşleme fonksiyonunun tanıtılmasıdır. Bu nedenle bu çalışmada akış tahmini için doğrusal olmayan destek vektör regresyonunu uygulanmıştır.

Drucker ve ark. (1997) tarafından önerilen destek vektör regresyonu (DVR) regresyon için kullanılan bir Destek vektör makinesi modelidir. DVR, yüksek boyutlu bir özellik uzayında doğrusal fonksiyonun bir hipotez uzayını kullanır ve yapısal risk minimizasyonu ilkesine göre eğitilir (Wu ve ark. 2019). DVR'de karar fonksiyonu aşağıdaki gibi yazılabilir:

$$f(x)=w \cdot \phi(x)+b \quad (1)$$

Burada  $f(x)$ : regresyon fonksiyonu,  $x$ : girdi vektörü,  $w$  ve  $b$  fonksiyonun parametreleridir.  $\phi(x)$  ise doğrusal olmayan haritalandırma fonksiyonudur. Amaç optimum değerlerin bulunmasıdır. Bu amaca aşağıdaki optimizasyon denkleminin çözülmesi ile ulaşılabilir:

$$\min_{w,b,\xi,\xi^*} \frac{1}{2} w^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2)$$

Aşağıdaki şartları sağlamalıdır:

$$y_i - (w \cdot \phi(x_i) + b) \leq \varepsilon + \xi_i \quad (3.a)$$

$$(w \cdot \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^* \quad (3.b)$$

$$\xi_i, \xi_i^* \geq 0 \quad i=1, \dots, n$$

Burada  $\xi_i$  ve  $\xi_i^*$  esnek değişkenler,  $C$ : sabit ceza katsayısı,  $\varepsilon$ : marjin değeridir. Denklem 3'te sağ taraf modelin genelleştirilmesini, sağ taraf ise ampirik riski temsil etmektedir. Bu iki değer minimumda tutulması ile DVR çözüme ulaşmaktadır.

Doğrusal olmayan DVR, Lagranj çarpanları ile gösterilebilir.

$$\min_{a,a^*} \frac{1}{2} \sum_{i=1}^n \sum_{i=1}^n (a_i - a_i^*) (a_j - a_j^*) K + \varepsilon \sum_{i=1}^n (a_i + a_i^*) - \sum_{i=1}^n y_i (a_i - a_i^*) \quad (4)$$

$$\sum_{i=1}^n y_i (a_i - a_i^*) = 0 \quad (5)$$

$0 \leq a_i, a_i^* \leq C, i=1, \dots, n$ ;  $a_i$  ve  $a_i^*$ : Lagranj çarpanları;  $K$ : Kernel fonksiyonudur.

$$K=K(i,j)=\phi(x_i)T\phi(x_j)K=K(i,j)=\phi(x_i)T\phi(x_j) \quad (6)$$

Yaygın olarak kullanılan kernel fonksiyonları;

Doğrusal Kernel:

$$K(i,j)=x_i \cdot x_j \quad (7)$$

Gauss Kernel:

$$K(i,j)=\exp(-\gamma|x_i-x_j|^2) \quad (8)$$

Polinom Kernel:

$$K(i,j)=(\gamma(x_i \cdot x_j)+r)^d \quad (9)$$

Burada;  $\gamma$ : Yapısal parametre;  $d$ : polinom derecesi;  $r$ : kalıntı terimidir.

## 2.2. Dalgacık Dönüşümü

Dalgacık (wavelet) dönüşümü, gözlemsel elde edilen büyük veri kümelerinden (tarihsel kayıtlar, zaman serileri vb.) önemsiz ve potansiyel olarak yararlı bilgi veya bilginin çıkarılmasında uygulanabilir. Sınıflandırma veya tahmin sorunlarını çözmek için kullanılabilen dalgacık dönüşümü, bir sinyalin zaman-frekans alanındaki davranışı hakkında bilgi sağlayabilen çoklu çözünürlüklü bir analizdir (Saraiva ve ark. 2021). Dalgacık dönüşümünün

istatistik analizlere göre bir avantajı, sinyali ayırtmak için tek bir pencere tekniği yerine farklı pencere boyutları analizini gerçekleştirmesidir.

Hidrolojik zaman serisi modellemede dalgacık dönüşümünün uygulamalarında hidrolojik serilerin çok-zamanlı ölçeklerinin belirlenmesi ve anlaşılması, mevsimselliklerin ve eğilimlerin tanımlanmasında kullanılabilir. Bu nedenle, dalgacık dönüşümünün durağan olmayan sinyalleri farklı zamansal ölçeklerde (seviyelerde) alt sinyallere ayırma yeteneği, hidrolojik süreçlerin daha iyi yorumlanmasında yardımcı olmaktadır (Nurani 2014). Dalgacık dönüşümü, sinyali sırasıyla düşük ve yüksek çözünürlüklü bileşenlere ayırmak için dar ve geniş pencere analizini kullanır. İkinci avantaj ise hidro-meteorolojik zaman serilerinin çoğunlukla durağan olmaması nedeniyle bu serilerde dalgacık dönüşümünün İstatistik analizinden daha başarılı bir araç olarak değerlendirilmesidir (Partal ve Kişi 2007). Dalgacık dönüşümü avantajlarından biri de düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarının olmasıdır.


Böylece, bütün frekans aralıklarında uygun değer zaman-frekans çözünürlüğü sağlanabilmektedir (Ersöz ve Özşen 2011).

Dalgacık dönüşümünde kullanılan ana dalgacık fonksiyonu ölçek parametresi ve konum parametresine bağlı olarak Denklem 10'da verilmiştir.

$$\Psi_{a,b}(t) = |a|^{-1/2} \Psi\left(\frac{t-a}{b}\right) \quad (10)$$

Burada, a ve b ölçek parametresi, t zamandır. Dalgacık fonksiyonu  $\Psi(t)$  ana fonksiyonunun "a" kadar ölçeklendirilip "b" kadar zaman ekseninde ötelenmesi ile elde edilir (Başakın 2019).

Daubechies dalgacık fonksiyonu gözlem verisindeki sinyal bileşenlerinin hassas şekilde çıkarılması mümkün kıldığından Daubechies dalgacık ailesi (db) literatürde sıklıkla kullanılmaktadır. Bu çalışmada daubechies 45 (db45) dalgacık fonksiyonu ile 5 seviye dalgacık dönüşümü kullanılmıştır. Çalışmada kullanılan günlük akım verileri ve 5 seviyede db45 dalgacık dönüşümü sonucu elde edilen yaklaşık ve detaylı serileri Şekil 3'de verilmiştir.



Şekil 3. Çalışmada kullanılan günlük akım verilerinin Daubechies 45 (db45) dalgacık dönüşümü ile ayrıştırılmış serileri

#### 2.4. Model Performans başarı ölçütleri

MATLAB programı üzerinde geliştirilen modellerin performansı çeşitli istatistiksel değerlendirme kriterleri kullanılarak değerlendirilmiştir. Bu çalışmada Korelasyon, Nash-Sutcliffe verimlilik katsayısı (NSE), Kling-Gupta verimlilik katsayısı (KGE), Performans Indisi (PI), Karekök ortalama karesel hata (RMSE) ve Ortalama mutlak yüzde hata (MAPE) kriterleri kullanılmıştır. R, NSE ve KGE kriterleri için mükemmel değer 1'e yakın olan değerler olurken, PI, RMSE ve MAPE kriterleri için mükemmel değer 0'a yakın değerlerdir. Bu değerlerden uzaklaşılması mükemmellikten uzaklaşıldığını göstermektedir.

$$R = \frac{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)}) \times (X_{i(Hesap)} - \bar{X}_{i(Hesap)})}{\sqrt{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)})^2} \times \sqrt{\sum_{i=1}^N (X_{i(Hesap)} - \bar{X}_{i(Hesap)})^2}} \quad (11)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2}{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)})^2} \quad (12)$$

$$PI = \frac{\frac{RMSE}{\bar{X}_{i(Göz)}}}{1+r} \quad (13)$$

$$RMSE = \left[ \frac{1}{N} \times \sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2 \right]^{1/2} \quad (14)$$

$$MAPE = \frac{1}{N} \times \sum_{i=1}^N \frac{|X_{i(Göz)} - X_{i(Hesap)}|}{|X_{i(Göz)}|} \quad (15)$$

$$K - G = 1 - [(R - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2]^{1/2} \quad (16)$$

$$\alpha = \frac{\sigma_{Hesap}}{\sigma_{Göz}} \quad (17)$$

$$\beta = \frac{\bar{X}_{i(Hesap)}}{\bar{X}_{i(Göz)}} \quad (18)$$

$$PI = \frac{RMSE}{\frac{\bar{x}(Göz)}{1+r}} \quad (19)$$

### 3. BULGULAR

Bu çalışmada günlük akım verileri Destek vektör makinelerinin üç farklı Kernel yöntemi kullanılarak modellenmiştir. Günlük akım verilerinin farklı zaman gecikmeleri ile oluşturulan ve tablo 2’de verilen yedi farklı model ilk önce dalgacık analizi ile ayrıştırılmadan ve daha sonra dalgacık analizi ile ayrıştırılarak incelenmiştir. Elde edilen sonuçlar arasında dalgacık analizi ile dönüştürülmemiş olanlar tablo 3’de, dalgacık dönüşümü ile elde edilen modellerin sonuçları ise tablo 4’de verilmiştir.

Dalgacık dönüşümü öncesi kurulan model sonuçlarını gösteren tablo 3 incelendiğinde; eğitim serisi için bütün modellerde Korelasyon, NSE, PI ve RMSE kriterlerine göre en iyi sonuçlar Polinom kernel fonksiyonundan elde edilirken, KGE kriterine göre ise en iyi sonuçlar lineer kernel fonksiyonu ile hesaplanan DVM modellerinden elde edilmiştir. Test serisi sonuçları incelendiğinde Korelasyon, NSE, PI ve RMSE kriterlerine göre yedi adet modelin dört adedinde lineer, iki adet gauss ve bir adet polinom kernel fonksiyonu ile elde edilen modellerin en iyi model olduğu, KGE kriterine göre ise tamamında lineer kernel fonksiyonlu DVM modelinin en iyi model olduğu bulunmuştur.

Dalgacık dönüşümü öncesi eğitim ve test serisi modelleri incelendiğinde; eğitim serisi verileri için bütün modellerde polinom fonksiyonlu DVM modelinin Korelasyon, NSE, PI ve RMSE kriterleri için en uygun model olduğu, KGE ve MAPE kriterleri için lineer fonksiyonlu DVM modellerinin en uygun model olduğu görülmüştür. Eğitim veri setinde en uygun model Korelasyon ve NSE kriterlerine göre (0.979; 0.958; 0.141) M03 olurken, KGE’ye göre (0.968) M04 ve M05 modelleri, RMSE için (1.078) M06 ve MAPE için (0.082) M02 olmuştur. Test veri seti incelendiğinde farklı istatistiksel kriterler için Lineer, Polinom ve Gauss fonksiyon tabanlı DVM modelleri ön plana çıkmaktadır. M04, M05, M06 ve M07 modellerinde lineer fonksiyonlu DVM modelleri en iyi sonuçları verirken, M01 modelinde polinom, M02 ve M03 modelleri için Gauss fonksiyon tabanlı DVM modelleri en iyi sonuçları vermiştir. Bu modeller arasında en iyi bulunan model ise; Korelasyon ve NSE, PI ve RMSE kriterlerine göre (0.977; 0.955; 0.137; 1.047) Gauss tabanlı M02 modeli; KGE (0.972) göre lineer tabanlı M02, M04 ve M05 modelleri; MAPE kriterine göre (0.081) lineer tabanlı M01 modelleri en iyi model olarak bulunmuştur.

Modellerin iyileştirilmesi için dalgacık ayrıştırması dönüşümü uygulanmış ve yeni kurulan modeller incelenmiştir. Dalgacık dönüşümü sonrası kurulan modellerde ise gerek eğitim serisi gerekse test serisinin bütün modellerinde lineer tabanlı DVM modellerinin en uygun sonuçları verdiği görülmüştür. Eğitim serisi modelleri arasında ise WDVM (dalgacık dönüşümlü destek vektör makinesi) WM04 modeli kriterlerin çoğunluğuna göre en uygun model olarak bulunmuştur (R: 0.998; NSE:0.995; PI: 0.046; RMSE:0.356). KGE ve MAPE

kriterlerine göre ise DVM\_WM03 modeli (KGE:0.996; MAPE:0.042) en iyi model olarak görülmüştür. Dalgacık dönüşümü sonrası elde edilen modellerin test serisi incelendiğinde kriterlerin çoğunluğuna göre WM04 modeli (R:0.998, NSE:0.996; PI: 0.039; RMSE:0.304) en iyi model olarak bulunmuştur. KGE ve MAPE kriterlerine göre ise M03 modeli (KGE: 0.995; MAPE: 0.051) en iyi model olarak görülmektedir.

Dalgacık dönüşümü öncesi elde edilen en iyi modeller arasında olan M02 ve M04 modellerinin gözlem verisi ile karşılaştırılması Şekil 4’de, dalgacık dönüşümü sonrası elde edilen en iyi modeller olan WM03 ve WM04 modellerinin gözlem verisi ile karşılaştırılması ise Şekil 5’de verilmiştir. Dalgacık dönüşümü öncesi ve sonrasında NSE kriterine göre M04 modelinde % 4.9, M03 modelinde % 4.6 ve M05 modelinde % 4.6 oranında iyileşme görülmüştür.

Model sonuçlarının dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası elde edilen model sonuçlarının saçılım grafiklerinin karşılaştırılması Şekil 6’da verilmiştir. Şekil 6’nın üst satırında dalgacık dönüşümü öncesi elde edilen model sonuçları, Şekil 6’nın alt satırında ise dalgacık dönüşümü sonrası elde edilen model sonuçlarının saçılım grafikleri verilmiştir. Saçılım grafikleri incelendiğinde bütün dalgacık dönüşümü sonrası elde edilen model sonuçlarının dalgacık dönüşümü olmadan elde edilen sonuçlardan daha üstün olduğu görülmektedir. Dalgacık dönüşümü ile elde edilen sonuçlar incelendiğinde WM01 modelinde diğer modellere göre en az iyileşme olduğu görülmüştür. WM01 modeli dışındaki diğer dalgacık modelleri saçılma grafiklerinin 45<sup>o</sup>lik eğime (1:1 çizgisine) oldukça yakın sonuçlar verdiği görülmüştür. Diğer bir anlatımla, dalgacık dönüşümü sonrası kurulan modellerde - WM01 modeli hariç- gözlem değerlerine oldukça yakın sonuçlar elde edilmiştir. Bu modeller arasında WM03 ve WM04 modelleri doğru denklemleri olarak en iyi sonuç vermiş görünmekte olsa da WM01 haricindeki bütün modeller performans açısından gözlem değerlerine oldukça yakın sonuçlar verdiği görülmektedir. Hangi modelin daha iyi performans gösterdiğini belirleyebilmek için Taylor grafiği ve Violin (Keman) grafiği kullanılmıştır. Bütün modellerin Taylor grafiği ile karşılaştırılması Şekil 7’de verilmiş olup en uygun bulunan modellerin dağılımlarının karşılaştırılması Violin (Keman) grafiği olarak Şekil 8’de verilmiştir.

Taylor grafiği (Şekil 7) incelendiğinde dalgacık dönüşümü öncesi kurulan modellerin grafiğin üst kısmında grup halinde kümelendiği ve birbirine oldukça yakın sonuç verdiği, dalgacık dönüşümü sonrası kurulan modellerin gözlem değerine daha yakın bir pozisyonda gruplandığı görülmüştür. Büyütülerek daha detaylı incelendiğinde WM04 ve WM03 modellerinin gözlem değerlerine en yakın olduğu ve WM04 modelinin gözlem değerine daha yakın olduğundan daha iyi bir model olduğu görülmüştür. Bu modelleri ise üçüncü sırada en iyi model olarak WM05 modeli izlemektedir. Bu modellere ait NSE; KGE; PI; RMSE ve MAPE değerlerine sırasıyla bakıldığında: WM04 (0.996; 0.993; 0.039; 0.304 ve 0.056); WM03 (0.996; 0.995; 0.042; 0.321 ve 0.051) ve WM05 (0.994; 0.993; 0.048; 0.368 ve 0.065) olarak tespit edilmiştir. Burada KG

kriteri haricindeki diğer kriterler birbirleri ile uyumlu olarak modellerin sırasını iyi bir şekilde tespit etmiştir. Ancak KGE kriteri M03 modelini M05 modeline göre daha uygun olarak göstermiş fakat bu durum Taylor diyagramında teyid edilmemiştir. Dolayısı ile KGE kriterini kullanırken, diğer istatistiksel kriterler ile onaylamak gerekmektedir.

Dalgacık dönüşümü sonrası elde edilen modeller dalgacık dönüşümsüz modellere göre daha iyi sonuç verdiği için

Şekil 8’de dalgacık sonrası elde edilen modellere ait Violin (keman) grafikleri verilmiştir. Şekil 8 incelendiğinde dalgacık dönüşümü sonrası model sonuçlarının gözlem verisi ile çok yakın aritmetik ortalama ve medyan verisine sahip olduğu; tahmin edilen verilerin dağılımının gözlem verilerinin dağılımına oldukça benzer olduğu; ancak maksimum değer tahmininde hiç birisinin maksimum gözlem değerine (30.61) ulaşamadığı görülmüştür.


**Tablo 3.** Dalgacık dönüşümü öncesi Test ve Eğitim setlerinde akım verilerinin tahmin edilen değerleri

MODEL	YÖNTEM	TEST SETİ						EĞİTİM SETİ						
		DVM	Korelasyon	NSE	KGE	PI	RMSE	MAPE	Korelasyon	NSE	KGE	PI	RMSE	MAPE
M01	Linear		0.974	0.949	<b>0.966</b>	0.146	1.114	<b>0.081</b>	0.969	0.939	<b>0.961</b>	0.170	1.290	<b>0.077</b>
	Polinom		<b>0.975</b>	<b>0.950</b>	0.962	<b>0.145</b>	<b>1.109</b>	0.113	<b>0.974</b>	<b>0.949</b>	0.945	<b>0.156</b>	<b>1.185</b>	0.107
	Gauss		0.974	0.949	0.961	0.146	1.116	0.143	0.970	0.941	0.938	0.168	1.272	0.129
M02	Linear		0.975	0.950	<b>0.972</b>	0.146	1.111	0.085	0.970	0.940	<b>0.967</b>	0.170	1.285	<b>0.082</b>
	Polinom		0.970	0.939	0.962	0.161	1.220	<b>0.084</b>	<b>0.978</b>	<b>0.957</b>	0.951	<b>0.143</b>	<b>1.085</b>	0.084
	Gauss		<b>0.977</b>	<b>0.955</b>	0.968	<b>0.137</b>	<b>1.047</b>	0.125	0.971	0.943	0.946	0.164	1.242	0.111
M03	Linear		0.975	0.950	<b>0.970</b>	0.146	1.111	<b>0.106</b>	0.969	0.940	<b>0.966</b>	0.169	1.284	<b>0.102</b>
	Polinom		0.968	0.935	0.950	0.167	1.266	0.189	<b>0.979</b>	<b>0.958</b>	0.950	<b>0.141</b>	<b>1.073</b>	0.182
	Gauss		<b>0.976</b>	<b>0.952</b>	0.963	<b>0.143</b>	<b>1.088</b>	0.132	0.971	0.943	0.940	0.164	1.246	0.115
M04	Linear		<b>0.975</b>	<b>0.949</b>	<b>0.972</b>	<b>0.146</b>	<b>1.114</b>	<b>0.094</b>	0.969	0.939	<b>0.968</b>	0.170	1.287	<b>0.091</b>
	Polinom		0.965	0.924	0.898	0.180	1.364	0.359	<b>0.979</b>	<b>0.953</b>	0.900	<b>0.148</b>	<b>1.128</b>	0.348
	Gauss		0.974	0.949	0.959	0.147	1.117	0.139	0.971	0.942	0.933	0.166	1.259	0.118
M05	Linear		<b>0.975</b>	<b>0.950</b>	<b>0.972</b>	<b>0.146</b>	<b>1.111</b>	<b>0.093</b>	0.970	0.940	<b>0.968</b>	0.169	1.284	<b>0.090</b>
	Polinom		0.966	0.932	0.953	0.171	1.295	0.117	<b>0.979</b>	<b>0.957</b>	0.950	<b>0.143</b>	<b>1.087</b>	0.117
	Gauss		0.974	0.950	0.965	0.146	1.114	0.135	0.971	0.943	0.934	0.165	1.252	0.114
M06	Linear		<b>0.975</b>	<b>0.950</b>	<b>0.970</b>	<b>0.146</b>	<b>1.110</b>	<b>0.107</b>	0.969	0.940	<b>0.966</b>	0.169	1.283	<b>0.103</b>
	Polinom		0.969	0.938	0.961	0.162	1.234	0.149	<b>0.979</b>	<b>0.957</b>	0.954	<b>0.142</b>	<b>1.078</b>	0.143
	Gauss		0.974	0.948	0.959	0.148	1.128	0.132	0.971	0.942	0.935	0.166	1.260	0.110
M07	Linear		<b>0.975</b>	<b>0.950</b>	<b>0.971</b>	<b>0.146</b>	<b>1.110</b>	<b>0.107</b>	0.969	0.940	<b>0.967</b>	0.169	1.283	<b>0.103</b>
	Polinom		0.970	0.938	0.948	0.162	1.230	0.134	<b>0.979</b>	<b>0.956</b>	0.942	<b>0.143</b>	<b>1.092</b>	0.134
	Gauss		0.975	0.950	0.958	0.146	1.110	0.133	0.970	0.940	0.932	0.169	1.282	0.113

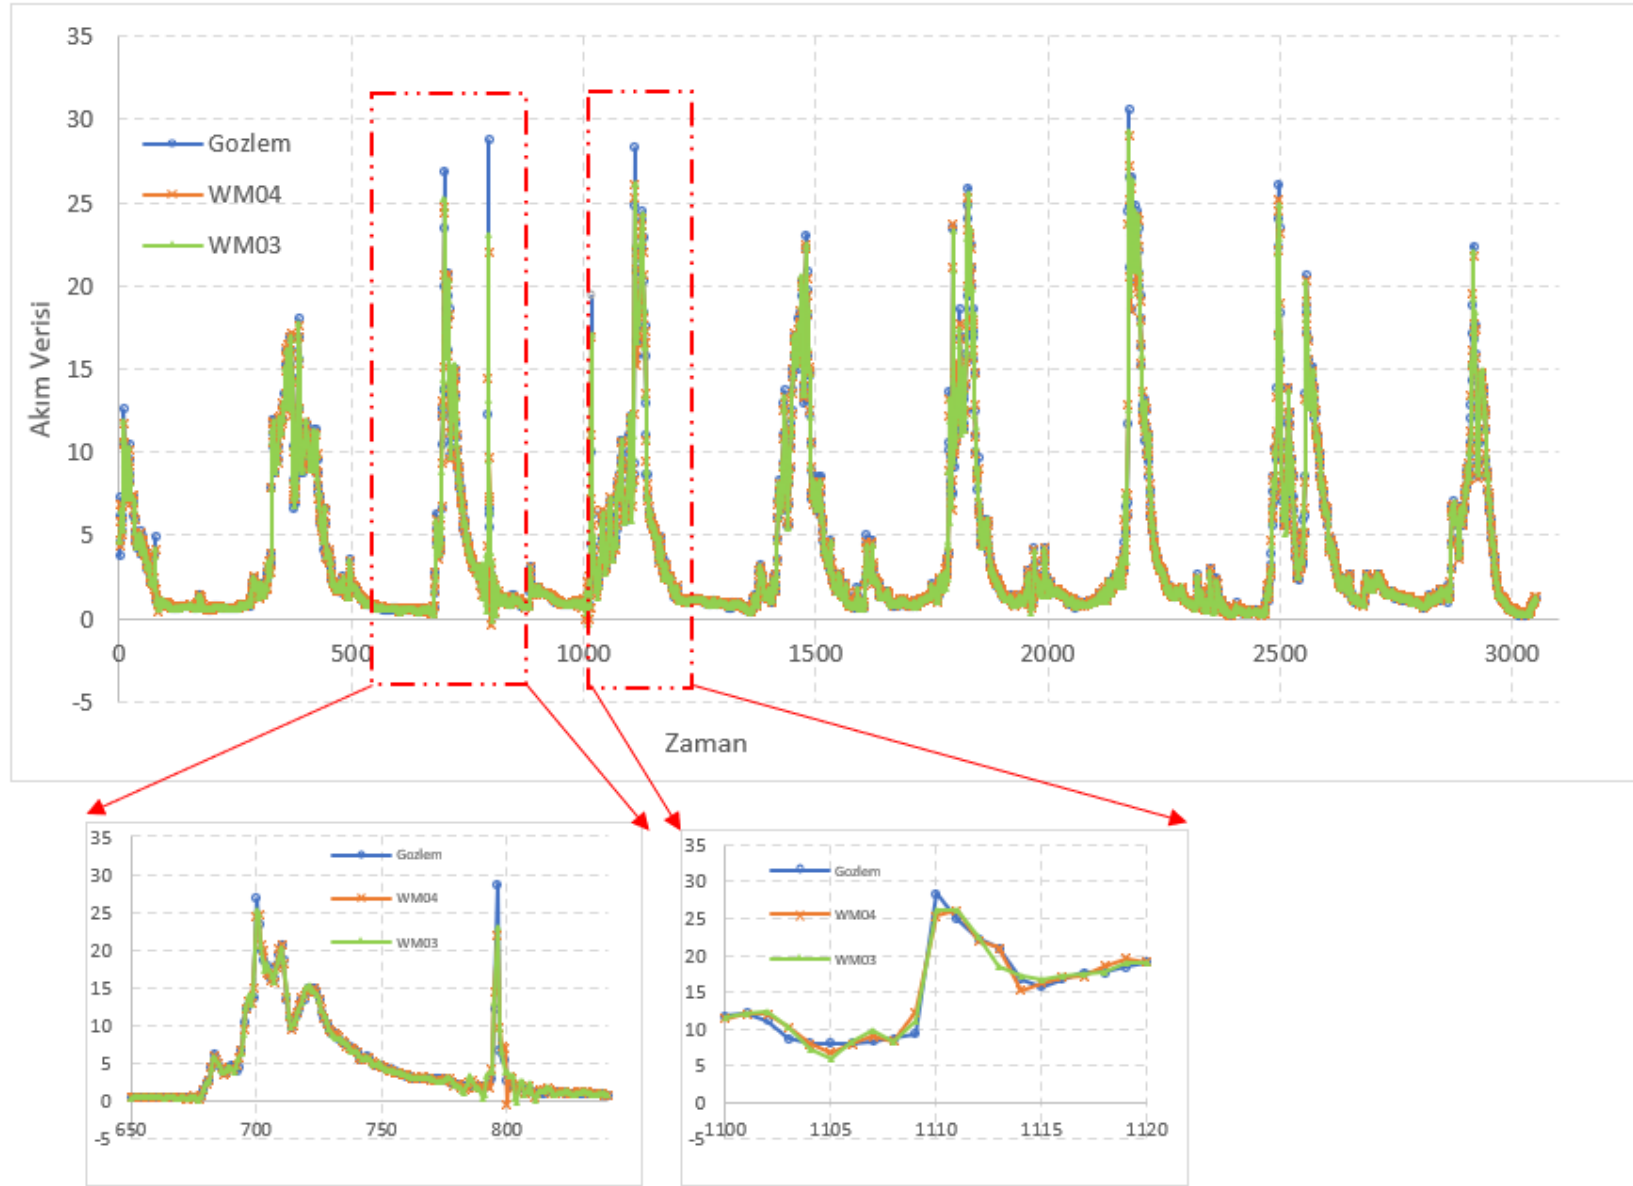
**Tablo 4.** Dalgacık dönüşümü sonrası Test ve Eğitim setlerinde akım verilerinin tahmin edilen değerleri

MODEL	YÖNTEM	TEST SETİ						EĞİTİM SETİ						
		DVM	Korelasyon	NSE	KGE	PI	RMSE	MAPE	Korelasyon	NSE	KGE	PI	RMSE	MAPE
WM01	Linear		<b>0.985</b>	<b>0.969</b>	<b>0.969</b>	<b>0.113</b>	<b>0.868</b>	<b>0.077</b>	<b>0.982</b>	<b>0.965</b>	<b>0.965</b>	<b>0.128</b>	<b>0.979</b>	<b>0.072</b>
	Poly		0.923	0.470	0.253	0.486	3.609	2.381	0.769	-0.294	0.078	0.873	5.942	2.375
	Gauss		0.896	0.794	0.772	0.308	2.252	0.286	0.937	0.858	0.787	0.264	1.967	0.120
WM02	Linear		0.997	<b>0.994</b>	<b>0.993</b>	0.050	0.385	0.059	<b>0.997</b>	<b>0.994</b>	<b>0.994</b>	<b>0.054</b>	<b>0.418</b>	<b>0.047</b>
	Poly		0.969	0.854	0.646	0.250	1.897	1.148	0.941	0.761	0.613	0.342	2.555	1.126
	Gauss		0.825	0.665	0.653	0.407	2.870	0.422	0.915	0.800	0.705	0.317	2.338	0.133
WM03	Linear		0.998	<b>0.996</b>	0.995	0.042	0.321	0.051	<b>0.998</b>	<b>0.995</b>	<b>0.996</b>	<b>0.048</b>	<b>0.366</b>	<b>0.042</b>
	Poly		0.951	0.770	0.589	0.316	2.379	1.316	0.961	0.804	0.594	0.307	2.314	1.299
	Gauss		0.776	0.584	0.580	0.467	3.198	0.545	0.903	0.760	0.652	0.349	2.556	0.150
WM04	Linear		0.998	<b>0.996</b>	0.993	0.039	0.304	0.056	<b>0.998</b>	<b>0.995</b>	<b>0.993</b>	<b>0.046</b>	<b>0.356</b>	<b>0.048</b>
	Poly		0.891	0.579	0.543	0.440	3.215	1.278	0.902	0.609	0.545	0.446	3.268	1.235
	Gauss		0.757	0.556	0.557	0.487	3.302	0.606	0.899	0.748	0.634	0.359	2.623	0.156
WM05	Linear		0.997	<b>0.994</b>	0.993	0.048	0.368	0.065	<b>0.997</b>	<b>0.994</b>	<b>0.993</b>	<b>0.053</b>	<b>0.410</b>	<b>0.053</b>
	Poly		0.855	-0.464	-0.220	0.837	5.997	3.813	0.902	-0.159	-0.177	0.768	5.624	3.743
	Gauss		0.753	0.549	0.549	0.492	3.328	0.617	0.898	0.744	0.629	0.362	2.643	0.165
WM06	Linear		0.997	<b>0.994</b>	0.992	0.049	0.380	0.077	<b>0.997</b>	<b>0.994</b>	<b>0.991</b>	<b>0.054</b>	<b>0.416</b>	<b>0.064</b>
	Poly		0.956	0.858	0.756	0.247	1.868	0.754	0.984	0.936	0.782	0.174	1.326	0.727
	Gauss		0.738	0.528	0.531	0.507	3.404	0.648	0.895	0.733	0.615	0.370	2.698	0.172
WM07	Linear		0.997	<b>0.994</b>	0.989	0.051	0.389	0.083	<b>0.997</b>	<b>0.993</b>	<b>0.989</b>	<b>0.055</b>	<b>0.421</b>	<b>0.070</b>
	Poly		0.954	0.716	0.482	0.350	2.640	1.717	0.945	0.664	0.460	0.405	3.029	1.692
	Gauss		0.714	0.490	0.489	0.535	3.539	0.675	0.889	0.712	0.587	0.386	2.804	0.172

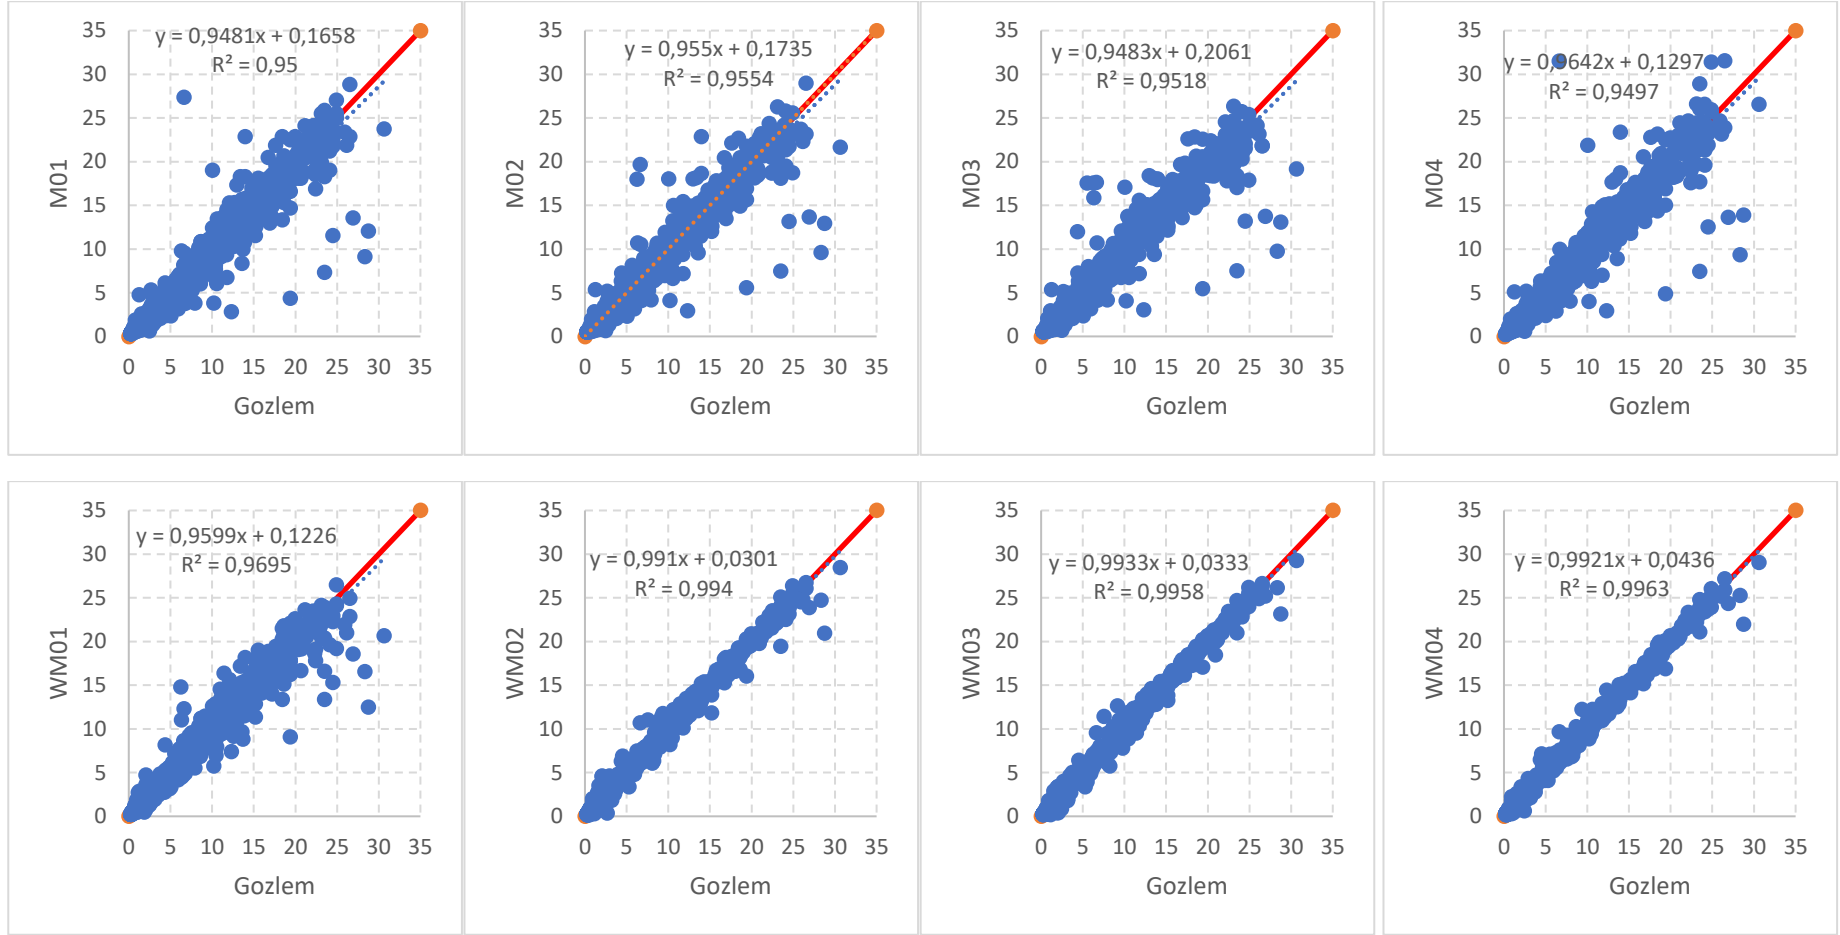




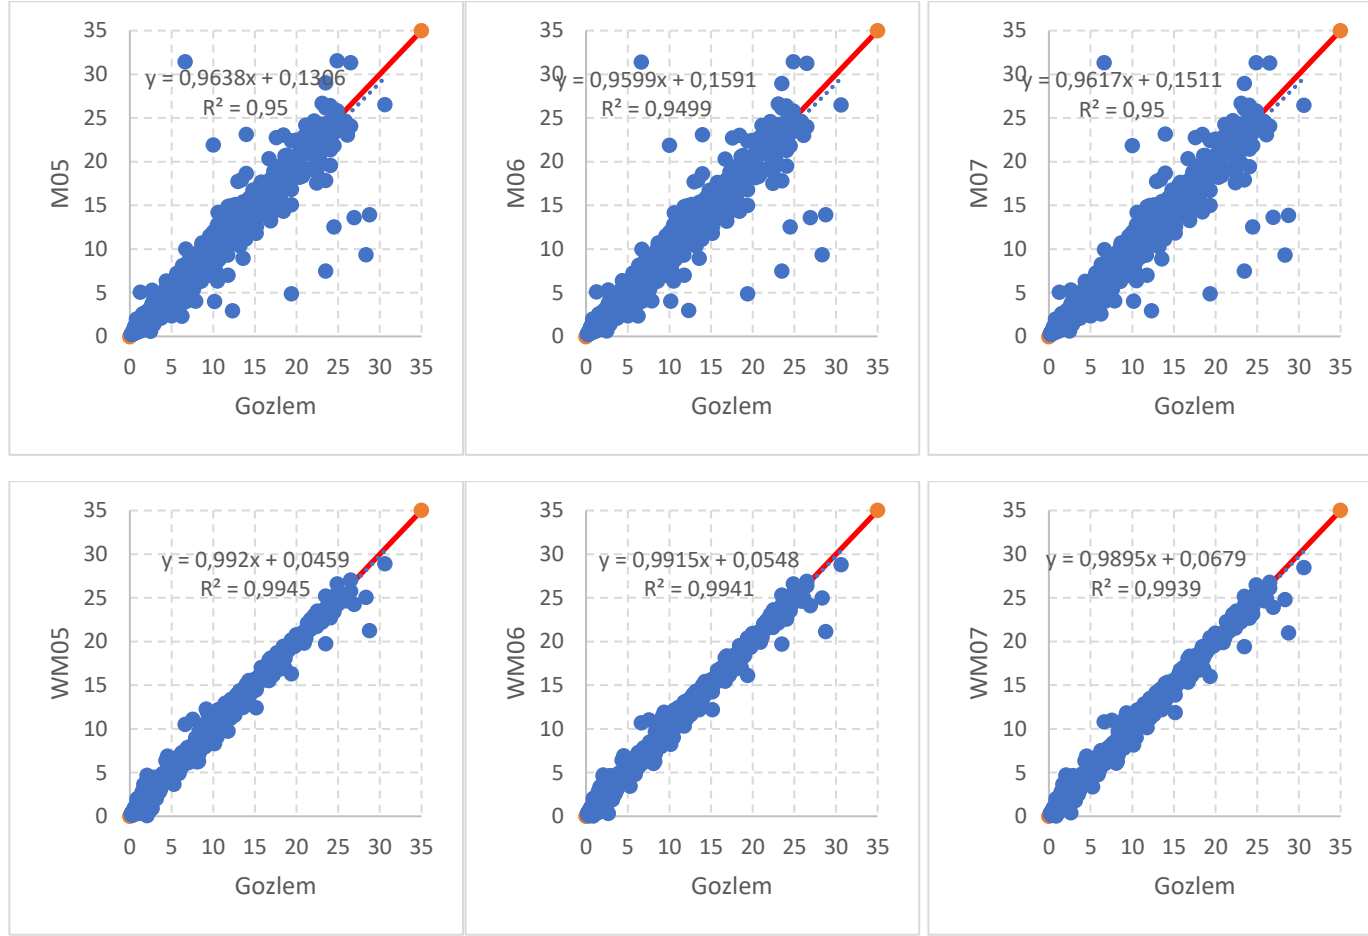
Şekil 4. Gözlenmiş veri ile dalgacık dönüşümü öncesi M02 ve M04 model karşılaştırılması




Şekil 5. Gözlenmiş veri ile dalgacık dönüşümü sonrası WM03 ve WM04 model karşılaştırılması




**Şekil 6.** Test veri seti için modellerin dalgacık dönüşümü öncesi (üst satırda verilen modeller) ve dalgacık dönüşümü sonrası (alt satırda verilen modeller) saçılma grafiklerinin karşılaştırılması (Kırmızı renk ile verilen çizgi 1:1 (45°'lik) simetri çizgisidir)



**Şekil 6 (devam).** Test veri seti için modellerin dalgacık dönüşümü öncesi (üst satırda verilen modeller) ve dalgacık dönüşümü sonrası (alt satırda verilen modeller) saçılma grafiklerinin karşılaştırılması (Kırmızı renk ile verilen çizgi 1:1 (45°'lik) simetri çizgisidir)



Şekil 7. Modellerin Taylor grafiği ile karşılaştırılması



Şekil 8. Modellere ait Violin (Keman) grafikleri

#### 4. TARTIŞMA VE SONUÇ

Bu çalışmada günlük akım verilerinin modelleme çalışmasında sıklıkla kullanılan Destek Vektör Makineleri (DVM) incelenmiş ve DVM için en uygun model geliştirilmesinde kullanılan farklı Kernel fonksiyonları araştırılarak en uygun fonksiyonlar ve modeller ortaya konulmuştur. Elde edilen modeller üzerinde dalgacık dönüşümü kullanılarak sonuçların iyileştirilmesi sağlanmıştır. Günlük akım verilerinin farklı zaman gecikmeleri ile yedi farklı model oluşturulmuştur. Bu modeller üç farklı DVM kernel (Lineer, Polinom ve Gauss) fonksiyonları kullanarak hesaplanmış ve sonuçlar karşılaştırılmıştır. Elde edilen modellerin iyileştirilmesi için dalgacık dönüşümü olarak daubechies 45 (db45) dalgacık fonksiyonu ile 5 seviye dalgacık dönüşümü kullanılmış ve model sonuçlarında yaklaşık %5 oranında iyileşme görülmüştür.

Günlük akarsu akım değerlerinin modellenmesinde kullanılan Destek Vektörleri Makinası kernel

#### KAYNAKLAR

Anonim (2024). Bayburt valiliği, www.bayburt.gov.tr.

Başakın E, Ekmekecioğlu Ö, Özger M (2019). Makine öğrenmesi yöntemleri ile kuraklık analizi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 25(8): 985-991.

Choubin B, Malekian A, Golshan M (2016). Application of several data-driven techniques to predict a standardized precipitation index. Atmosfera, 29(2): 121-128.

Cristianini N, Shawe-Taylor J (2000). An Introduction to Support Vector Machines and Other Kernel-based Learning methods. Cambridge University Press.

Deo RC, Kisi O, Singh VP (2017). Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. Atmospheric Research, 184: 149-175.

Drucker H, Burges CJC, Kaufman L, Smola A (1997). Support vector regression machines. Advances in Neural Information Processing Systems, 28(7): 779-784.

Erkek C, Ağırlioğlu N (2008). Su Kaynakları Mühendisliği. Beta Yayınevi.

Ersöz A, Özşen S (2011). Uyku EEG Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu. Elazığ, Türkiye.

Faizollahzadeh Ardabili S, Mosavi A, Dehghani M, Várkonyi-Kóczy A (2019). Deep learning and machine learning in hydrological processes climate change and earth systems International Conference on Global Research and Education. Balatonfüred, Hungary.

Ghorbani MA, Deo RC, Karimi V, Kashani MH, Ghorbani S (2019). Design and implementation of a hybrid MLP-GSA model with multi-layer perceptron-gravitational search algorithm for monthly lake water level forecasting. Stochastic Environmental Research and Risk Assessment, 33(1):125-147.

Liu Y, Weisberg R (2005). Patterns of ocean current variability on the West Florida Shelf using the self-organizing map, Journal of Geophysical Research, 110: C06003.

Mokhtarzad M, Eskandari F, Vanjani N J, Arabasadi A (2017). Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. Environmental Earth Sciences, 76(21): 729.

Mohamadi S, Sammen SS, Panahi F, Ehteram M, Kisi O, Mosavi A, Al-Ansari N (2020). Zoning map for drought prediction using integrated machine learning models with a nomadic people optimization algorithm. Natural Hazards, 104(1): 537-579.

Nourani V, Baghanam AH, Adamowski J, Kisi O (2014). Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. Journal of Hydrology, 514: 358-377.

Papacharalampous G, Tyrallis H, Koutsoyiannis D (2018). Predictability of monthly temperature and precipitation using automatic time series forecasting methods. Acta Geophysica, 66(4):807-831.

fonksiyonlarından Polinom, Gauss ve Lineer (doğrusal) fonksiyonlar karşılaştırıldığında en iyi sonuçların Linear ve Gauss fonksiyonlarından elde edildiği görülmüştür (Tablo 3). Dalgacık dönüşümü kullanılarak oluşturulan modellerde ise Lineer DVM fonksiyon sonuçlarının bütün modellerde daha iyi olduğu gözlemlenmiştir. Günlük akarsu akım modellerinde dalgacık dönüşümünün Lineer Kernel fonksiyonu ile hesaplanan DVM modellerinde kullanılmasının model performansını artıracığı bu çalışma ile elde edilen en önemli sonuçtur.

#### ÇIKAR ÇATIŞMASI

Herhangi bir çıkar çatışması yoktur.

#### TEŞEKKÜR

Bu çalışmada kullanılan günlük akım verilerinin temin edilmesinde katkısı bulunan DSİ Genel Müdürlüğüne teşekkür ederiz

Partal T, Kişi Ö (2007). Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*, 342(1-2): 199-212.

Raghavendra SN, Deka PC (2014). Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing*, 19: 372-389.

Saraiva SV, Carvalho FDO, Santos CAG, Barreto LC, Freire PKDMM (2021). Daily streamflow forecasting in Sobradinho Reservoir using machine learning models coupled with wavelet transform and bootstrapping. *Applied Soft Computing Journal*, 102: 1568–4946.

VapnikVN (1995). *The Nature of Statistical Learning Theory*, Springer-Verlag.

Wu J, Liu H, Wei G, Song T, Zhang C, Zhou H (2019). Flash Flood Forecasting Using Support Vector Regression Model in a Small Mountainous Catchment. *Water*, 11(7): 1327.