

**T.C.**  
**ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**


**DOĞADAN İLHAM ALAN OPTİMİZASYON TEKNİKLERİ VE YAPAY SİNİR**  
**AĞLARI İLE TAŞKIN ÖTELEMESİ**

**Muhammed Furkan TORAMAN**

**Danışman: Dr. Öğr. Üyesi Okan Mert KATİPOĞLU**

**TEZ JÜRİ ÜYELERİ**  
**Dr. Öğr. Üyesi Gaye AKTÜRK**  
**Dr. Öğr. Üyesi Zeynep Özge TERZİOĞLU**  
**Dr. Öğr. Üyesi Okan Mert KATİPOĞLU**

**YÜKSEK LİSANS TEZİ**  
**ERZİNCAN, 2025**



© 2025 [Muhammed Furkan TORAMAN]. Tüm hakları saklıdır.

## ÖZET

### DOĞADAN İLHAM ALAN OPTİMİZASYON TEKNİKLERİ VE YAPAY SİNİR AĞLARI İLE TAŞKIN ÖTELEMESİ

**Muhammed Furkan TORAMAN**

**Yüksek Lisans Tezi, Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü,  
İnşaat Mühendisliği Anabilim Dalı**

**Danışman: Dr. Öğr. Üyesi Okan Mert KATIPOĞLU**

**2025, 48 sayfa**

Bu tez kapsamında yapay arı kolonisi algoritması, parçacık sürüsü optimizasyon algoritması, ateş böceği algoritması, Kurbağa sıçrama algoritması ve genetik algoritma gibi doğadan ilham alan optimizasyon algoritmaları ile yapay sinir ağının ağırlık ve yanlılık parametreleri optimize ederek taşkın ötelemesi yapılmıştır. Tahmin sonuçları tekil yapay sinir ağı algoritması ile karşılaştırılarak meta sezgisel optimizasyon tekniklerinin taşkın ötelemesi tahmin performansı değerlendirilmiştir. Tahminleri için Ordu-Turna suyundaki 2009 ve 2013 yılında meydana gelen taşkın verileri kullanılarak yapılmıştır. Modelleme sırasında memba istasyonundaki 30 dakikalık akımlar girdi ve mansaptaki 30 dakikalık akımlar hedef değişkeni olarak kullanılmıştır. Modelin kurulumunda verilerin %70'i eğitim ve %30'u test olarak ayrılmıştır. Kurulan modellerin performansı kök ortalama kare hata (RMSE), ortalama mutlak hata (MAE), Akaike Bilgi Kriteri (AIC), Nash-Sutcliffe Verimliliği (NSE), Kling-Gupta Verimliliği (KGE), determinasyon katsayısı ( $R^2$ ), ortalama yanlılık hatası (MBE), yanlılık faktörü (BF) ve yüzde yanlılık (Pbias) gibi istatistiksel metriklerle göre sınanmıştır. Analizler sonucunda ABC-ANN hibrit modeli 2009 taşkınlarını RMSE:1.84, AIC:71.63, KGE:0.94,  $R^2$ :0.97, ve Pbias:1.07 değerleri ve 2013 taşkınlarını ise RMSE:1.23, AIC:19.99, NSE:0.95,  $R^2$ :0.95, ve Pbias:0.63 değerleri ile en iyi tahminde bulunmuştur. Ayrıca RMSE değerlerinin yüzde değişlerine göre meta sezgisel optimizasyon algoritmaları tekil yapay sinir ağı modelini hata düzeyini taşkın tahmininde %45 ile %93 aralığında azalttığı tespit edilmiştir. Ek olarak, model performansları ısı haritaları, kümülatif dağılım grafikleri, Taylor diyagramları, keman grafikleri, kutu diyagramları, saçılma grafikleri, sütun grafikleri ve çizgi grafikleri ile görselleştirilerek ABC-ANN hibrit yaklaşımının üstünlüğü vurgulanmıştır. Buna göre sürü üyelerinin birbirleriyle etkileşimini taklit ederek yerel optimuma takılma riskini azaltan ve en uygun model

parametrelerinin belirlenmesine yardım eden ABC-ANN modeli en doğru tahmin sonuçları üretmiştir. Çalışmanın sonuçları karar vericilere ve politika yapıcılara olası taşkın risklerini önceden görme, proaktif önlemler alma ve uygun müdahale stratejileri geliştirme açısından yardımcı olmaktadır.

**Anahtar Kelimeler:** hiper parametre optimizasyonu, sürü zekâsı, taşkın ötelemesi, yapay zekâ.



## **ABSTRACT**

# **FLOOD ROUTING WITH NATURE-INSPIRED OPTIMIZATION TECHNIQUES AND ARTIFICIAL NEURAL NETWORKS**

**Muhammed Furkan TORAMAN**

**Master's Thesis, Erzincan Binali Yıldırım University, Institute of Science and  
Technology,**

**Department of Civil Engineering**

**Advisor: Assist. Prof. Dr. Okan Mert KATİPOĞLU**

**2025, 48 pages**

Within the scope of this thesis, flood prediction is performed by optimizing the weight and bias parameters of the artificial neural network with nature-inspired optimization algorithms such as artificial bee colony algorithm, particle swarm optimization algorithm, firefly algorithm, frog leap algorithm and genetic algorithm. The flood forecasting performance of meta-heuristic optimization techniques was evaluated by comparing the forecasting results with the single artificial neural network algorithm. The forecasts were made using the flood data of Ordu-Turna water in 2009 and 2013. During modeling, 30-minute flows at the upstream station were used as input and 30-minute flows downstream were used as target variables. In the model setup, 70% of the data is divided into training and 30% of the data is divided into testing. The performance of the models was tested according to statistical metrics such as root mean square error (RMSE), mean absolute error (MAE), Akaike Information Criterion (AIC), Nash-Sutcliffe Efficiency (NSE), Kling-Gupta Efficiency (KGE), coefficient of determination ( $R^2$ ), mean bias error (MBE), bias factor (BF) and percent bias (Pbias). As a result of the analysis, the ABC-ANN hybrid model predicted the 2009 floods with RMSE:1.84, AIC:71.63, NSE:0.94,  $R^2$ :0.97, and Pbias:1.07, and the 2013 floods with RMSE:1.23, AIC:19.99, NSE:0.95,  $R^2$ :0.95, and Pbias:0.63. In addition, according to the percentage changes of RMSE values, meta-heuristic optimization algorithms were found to reduce the error level of the single artificial neural network model in flood forecasting in the range of 45% to 93%. In addition, the model performances were visualized with heat maps, cumulative scatter plots, Taylor diagrams, violin plots, box plots, scatter plots, bar charts and line plots to emphasize the superiority of the ABC-ANN hybrid approach. Accordingly, the ABC-ANN model, which reduces the risk of getting

stuck in the local optimum by mimicking the interaction of swarm members with each other and helps to determine the most appropriate model parameters, produced the most accurate prediction results. The results of the study help decision makers and policy makers to anticipate potential flood risks, take proactive measures and develop appropriate response strategies.

**Keywords:** hyper parameter optimization, swarm intelligence, flood routing, artificial intelligence.



## TEŞEKKÜR

Yüksek lisans tezi olarak sunduğum bu çalışma süresince bilgisi ve tecrübesiyle beni yönlendirirken sabrını ve desteğini hiçbir zaman esirgemeyerek bana olan inancını derinden hissettiren çok değerli danışman hocam Sayın Dr. Öğr. Üyesi Okan Mert KATİPOĞLU'na teşekkürü bir borç bilirim. Bu tez çalışması süresince varlığıyla moral motivasyon ve destek sağlamış olan sevgili aileme ve kıymetli eşime içtenlikle teşekkürlerimi sunarım.

Çalışmada kullanılan akarsu akımı verilerini temin eden Devlet Su İşleri Genel Müdürlüğüne teşekkür ederiz. Bu çalışma Erzincan Binali Yıldırım Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince desteklenmiştir. Proje Numarası: FYL-2024-985

Muhammed Furkan TORAMAN

Ocak, 2025

## İÇİNDEKİLER

|                                                                                        |      |
|----------------------------------------------------------------------------------------|------|
| ÖZET .....                                                                             | v    |
| ABSTRACT .....                                                                         | vii  |
| TEŞEKKÜR .....                                                                         | ix   |
| İÇİNDEKİLER .....                                                                      | x    |
| TABLolar DİZİNİ .....                                                                  | xi   |
| ŞEKİLLER DİZİNİ .....                                                                  | xii  |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                                   | xiii |
| 1. GİRİŞ .....                                                                         | 1    |
| 1.1. Araştırmanın Amacı .....                                                          | 1    |
| 1.2. Araştırmanın Önemi .....                                                          | 1    |
| 2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR .....                                        | 3    |
| 2.1. Taşkın Risk Yönetimi .....                                                        | 3    |
| 2.2. Yapay Zekâ Modelleri ile Taşkın Tahmini .....                                     | 4    |
| 2.3. Kaynak Özetleri .....                                                             | 5    |
| 3. YÖNTEM .....                                                                        | 9    |
| 3.2 Yapay Arı Kolonisi (Artificial Bee Colony-ABC) Algoritması .....                   | 9    |
| 3.3 Parçacık Sürüsü Optimizasyon (Particle Swarm Optimization-PSO) Algoritması .....   | 11   |
| 3.4 Genetik Algoritma (Genetic Algorithm-GA) .....                                     | 12   |
| 3.5 Ateş Böceği (Firefly Algorithm-FFA) Optimizasyonu .....                            | 13   |
| 3.6 Karışık Kurbağa Sıçraması Algoritması (Shuffled Frog Leaping Algorithm-SFLA) ..... | 15   |
| 3.7 Performans Metrikleri .....                                                        | 16   |
| 3.8. Çalışma Alanı .....                                                               | 18   |
| 3.9. Çalışmanın Akışı .....                                                            | 19   |
| 4. BULGULAR .....                                                                      | 21   |
| 4.1 2009 Yılı Taşkınlarının Tahmin Değerlendirmesi .....                               | 21   |
| 4.2 2013 Yılı Taşkınlarının Tahmin Değerlendirmesi .....                               | 30   |
| 5. TARTIŞMA ve SONUÇ .....                                                             | 40   |
| 6. SONUÇ ve ÖNERİLER .....                                                             | 42   |
| KAYNAKÇA .....                                                                         | 44   |



## TABLÖLAR DİZİNİ

|                                                                            |    |
|----------------------------------------------------------------------------|----|
| Tablo 1. Korelasyon katsayılarının sınıflandırılması .....                 | 17 |
| Tablo 2. 2009 yılı taşkın tahminlerinin test sonuçları .....               | 28 |
| Tablo 3. 2009 taşkın tahminlerinin ANN modeline göre yüzde değişimler..... | 30 |
| Tablo 4. 2013 Yılı taşkın tahminlerinin test sonuçları .....               | 37 |
| Tablo 5. 2013 taşkın tahminlerinin ANN modeline göre yüzde değişimler..... | 38 |



## ŞEKİLLER DİZİNİ

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| Şekil 1. Yapay sinir ağları örnek nöron yapısı .....                                       | 9  |
| Şekil 2. Yapay Arı Kolonisi Algoritmasının akış diyagramı.....                             | 10 |
| Şekil 3. Parçacık Sürüşü Optimizasyon Algoritmasının yapısı.....                           | 11 |
| Şekil 4. Parçacık Sürüşü Optimizasyon Algoritması akış diyagramı.....                      | 12 |
| Şekil 5. Genetik Algoritmasının yapısı .....                                               | 13 |
| Şekil 6. Genetik Algoritma akış diyagramı .....                                            | 13 |
| Şekil 7. Ateş böceklerinin hareketinden esinlenen FFA'nın yapısı.....                      | 14 |
| Şekil 8. FFA'nın akış diyagramı .....                                                      | 15 |
| Şekil 9. Kurbağa sıçraması algoritmasının akış diyagramı .....                             | 16 |
| Şekil 10. Değişkenlerinin dağılımına göre ilişki analizi.....                              | 17 |
| Şekil 11. Çalışma alanının coğrafi koordinatları .....                                     | 18 |
| Şekil 12. Çalışmada kullanılan taşkın verileri .....                                       | 19 |
| Şekil 13. Çalışmanın akış diyagramı .....                                                  | 20 |
| Şekil 14. Isı haritaları ile taşkın tahminlerinin değerlendirilmesi .....                  | 22 |
| Şekil 15. Kümülatif dağılım grafikleri ile taşkın tahminlerinin değerlendirilmesi .....    | 23 |
| Şekil 16. Taylor diyagramları ile taşkın tahmin modellerinin karşılaştırılması .....       | 24 |
| Şekil 17. Keman grafikleri ile taşkın tahmin modellerinin karşılaştırılması.....           | 25 |
| Şekil 18. Kutu diyagramlar ile taşkın tahminlerinin değerlendirilmesi.....                 | 26 |
| Şekil 19. Merkezi saçılma grafikleri ile taşkın tahmin modellerinin karşılaştırılması..... | 27 |
| Şekil 20. Çizgi grafikleri ile taşkın tahmin modellerinin karşılaştırılması.....           | 27 |
| Şekil 21. Radar grafiğine göre 2009 taşkınının tahmin doğruluğunun değerlendirilmesi.....  | 29 |
| Şekil 22. Sütun grafiğine göre taşkın tahmin hatalarının tekli ANN modeline göre değişimi. | 30 |
| Şekil 23. Isı haritaları ile taşkın tahminlerinin değerlendirilmesi .....                  | 31 |
| Şekil 24. Kümülatif dağılım grafikleri ile taşkın tahminlerinin değerlendirilmesi .....    | 32 |
| Şekil 25. Taylor diyagramı ile taşkın tahmin modellerinin karşılaştırılması .....          | 33 |
| Şekil 26. Keman grafikleri ile taşkın tahminlerinin değerlendirilmesi .....                | 34 |
| Şekil 27. Kutu diyagramlar ile taşkın tahminlerinin değerlendirilmesi.....                 | 35 |
| Şekil 28. Merkezi saçılma grafikleri ile taşkın tahmin modellerinin karşılaştırılması..... | 36 |
| Şekil 29. Çizgi grafikleri ile taşkın tahmin modellerinin karşılaştırılması.....           | 36 |
| Şekil 30. Radar grafiğine göre 2013 taşkınının tahmin doğruluğunun değerlendirilmesi.....  | 38 |
| Şekil 31. Sütun grafiğine göre taşkın tahmin hatalarının tekli ANN modeline göre değişimi. | 39 |

## SİMGELER VE KISALTMALAR DİZİNİ

|         |                                               |
|---------|-----------------------------------------------|
| ABC     | Yapay Arı Kolonisi                            |
| ANN     | Yapay Sinir Ağları                            |
| ANFIS   | Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi |
| BT      | Torbalı Ağaç                                  |
| DSİ     | Devlet Su İşleri                              |
| FFA     | Ateş Böceği Algoritması                       |
| GA      | Genetik Algoritma                             |
| GBM     | Gradyan Artırılma Makinesi                    |
| KF      | Kalman Filtresi                               |
| KNN     | K-En Yakın Komşu                              |
| LSTM    | Uzun Kısa Süreli Bellek Sinir Ağını           |
| PSO     | Parçacık Sürüsü Optimizasyon                  |
| RF      | Rastgele Orman                                |
| SFL     | Kurbağa Sıçraması                             |
| SVM     | Destek Vektör Makinesi                        |
| XGBOOST | Ekstrem Gradyan Artırma                       |

# 1. GİRİŞ

## 1.1. Araştırmanın Amacı

Bu çalışmada doğadan ilham alan yapay zekâ optimizasyon algoritmaları ile taşkın ötelemesi tahmini yapılmıştır. Tahminler çeşitli istasyonlardan kaydedilen veriler kullanılarak yapılacaktır. Çalışmada ateş böceği algoritması, Kurbağa sıçrama algoritması, yapay arı kolonisi algoritması, parçacık sürüsü optimizasyon algoritması ve genetik algoritma ile yapay sinir ağlarında birleştirilmesiyle taşkın ötelemesi tahminleri yapılmıştır. Yapay sinir ağının ağırlık ve yanlılık parametreleri optimize ederek taşkın ötelemesi yapılmıştır. Tahmin sonuçları tekil yapay sinir ağı algoritması ile karşılaştırılarak meta sezgisel optimizasyon tekniklerinin taşkın ötelemesi tahmin performansı değerlendirilmiştir. Çalışma sonucunda tahmin algoritmalarından elde edilen test sonuçları istatistiksel metrikler ve grafiklerle birlikte karşılaştırılıp yorumlanmıştır. Yapılan karşılaştırma sonucunda en tutarlı sonuç veren algoritma tespit edilmiştir.

Yapay sinir ağları ve doğadan ilham alınarak geliştirilen çeşitli yapay zekâ algoritmalarını hibritleştirerek taşkın tahmin modellerini oluşturmak ve bu modeller doğrultusunda erken uyarı sistemlerinin gelişmesine katkı sağlanması planlanmaktadır. Bu sayede taşkınlardan oluşabilecek can ve mal kayıpları en aza indirgenebilecek, altyapı hasarları, mülk kayıpları azaltılacaktır. Böylece taşkın riskli bölgelerde yaşayan insanların güvenliğinin sağlanması ve acil müdahale planlarının geliştirilme basamaklarına katkı sağlanması amaçlanmaktadır.

## 1.2. Araştırmanın Önemi

Taşkınlar doğal afetler arasında en yıkıcı olanlardan biridir. Taşkınlar sonucu birçok ev, tarım arazisi, yerleşkeler, altyapılar zarar görebilmekte ve can kaybına neden olabilmektedir. Ayrıca taşkınlar sonucu birçok temiz su kaynakları kirlenebilmektedir. Taşkınlar bir bölgenin ekonomisine de ciddi darbeler vurabilmektedir. Ayrıca toplum içerisinde stres, travma ve endişeye neden olabilmektedir. Tüm bunların önüne geçmek ve bu riskleri en az seviyeye indirmek için erken uyarı sistemleri ile taşkınları önceden tahmin edip gereken tedbirlerin alınması sağlanabilir. Erken uyarı sistemleri taşkın olmadan önce taşkın şiddetini tahmin edip alınabilecek önlemler konusunda uyarı yapabilmektedir. Bu sayede taşkınların verebilecekleri zararlar minimum seviyeye düşürülebilmesi açısından hayati öneme sahiptir.

Proje kapsamında çeşitli hibrit yapay zekâ algoritmaları karşılaştırılarak taşkın öteleme tahmini yapılacaktır. Çalışmada birçok yapay zekâ algoritması kullanılıp elde edilen sonuçlarla taşkın öteleme tahminleri yapılacaktır. Bu sayede hem taşkınlar için erken uyarı sistemlerine hem de yapay zekanın ve teknolojinin geliştirilmesine katkıda bulunmaktadır.

Doğada ilham alan optimizasyon teknikleri ve yapay sinir ağları (Artificial Neural Networks-ANN) ile taşkın öteleme tahmini, geleneksel ANN modelinin çeşitli parametrelerinin optimize ederek en düşük hataya ulaşmayı hedeflemesi ve en doğru taşkın hidrografının tahmin edilerek taşkın risk yönetimini etkili bir şekilde sağlanmasını sağlar. Böylece ANN modelinin hiperparametreleri belirlenerek küresel optimum değerlere ulaşılmaktadır. Böylece halkın can ve mal güvenliğinin korunmasına katkı sağlayacak taşkın risk yönetimi çalışmalarına katkı sunulmaktadır.

Doğadan ilham alan optimizasyon teknikleri ve ANN modellerinin birleşimini kullanarak taşkın öteleme tahmini konusunda yeni bir yaklaşım sunması taşkın risk azaltılması için kritik öneme sahiptir. Bu yaklaşım, daha doğru tahminler yapma, taşkın riskini daha iyi yönetme ve acil durum planlamasını geliştirme potansiyeline sahiptir. Ayrıca, çalışmanın literatüre katkısı, geleneksel tahmin modellerinin sınırlamalarını aşarak daha güvenilir ve verimli bir taşkın öteleme tahmini yöntemi sunmasıdır.

## 2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR

### 2.1. Taşkın Risk Yönetimi

Taşkınlar, diğer birçok doğal afet gibi, dünya oluşumundan bu yana süreklilik gösteren doğal olaylarındandır. Tarihsel süreç boyunca hidrolojik, meteorolojik, jeolojik ve tektonik kökenli çeşitli olaylar, taşkınların meydana gelme sıklığını ve etkilerinin şiddetini dönemsel olarak değiştirmiştir (Smith ve Ward, 1998). Bununla birlikte, üretim ve tüketim alışkanlıklarındaki değişimler, doğal kaynakların kullanımı ve yerleşim şekillerindeki farklılaşmalar, taşkınların insan yaşamı üzerindeki etkilerini giderek daha belirgin hale getirmiştir. Günümüzde doğal olaylarının, doğal dengelerinden saparak insan yaşamı üzerinde olumsuz etkiler oluşturmaları genellikle insan-doğa ilişkisinin bozulması ve insan kaynaklı faaliyetlerle ilişkilendirilmektedir. Özellikle son yıllarda küresel ısınmanın etkisiyle atmosferde ve iklim koşullarında meydana gelen sıra dışı değişimlerin, taşkın olaylarının dünya genelinde artmasına neden olması bu durumun somut bir örneği olarak değerlendirilebilir (CHANGE, Intergovernmental Panel On Climate 2007; Hirabayashi vd. 2013; Legg, 2021).

Afet yönetiminin en kritik unsurlarından biri olan risk yönetimi, bütünleşik afet yönetiminin başlangıç aşamasını oluşturmaktadır. Afet yönetiminde temel hedef, alınacak önlemler ve gerçekleştirilecek denetimler yoluyla olası zararları en aza indirmektir. Afet öncesinde risk yönetiminin ihmal edilmesi, muhtemel hasarların boyutunu artırarak afetlerin yönetilemez bir hale gelmesine neden olabilir. Risk yönetiminin eksikliği, gelişmiş ülkelerin ekonomileri üzerinde dahi ciddi sorunlar yaratırken, gelişmekte olan ülkeler için bu durum, sürdürülebilir kalkınmayı ciddi biçimde tehdit eden bir engel haline gelmektedir (Ekşi ve Kantarlı, 2018; Wetmore, 2020).

Taşkınlar ve taşkınlarla mücadele üzerine yapılan birçok akademik çalışmaya ek olarak, Birleşmiş Milletler (BM), Federal Acil Durum Yönetim Ajansı (FEMA) ve Dünya Meteoroloji Örgütü (WMO) gibi uluslararası kuruluşlar, bu konudaki eksikliklere dikkat çekmiş ve taşkın kaynaklı kayıpları en aza indirmenin “Sürdürülebilir Taşkın Yönetimi (STY)” anlayışıyla mümkün olabileceğini vurgulamışlardır. Dünya yüzeyindeki sürekli değişim ve iklim koşullarının doğal değişkenliği, taşkınlarla ilgili çalışmaların sürdürülebilir bir çerçevede ele alınmasını zorunlu kılmaktadır (Luther vd. 2017). İklim koşulları ile taşkın havzasının özellikleri, taşkın afetinin oluşum biçimini ve sonuçlarını etkileyen en önemli parametreler arasında yer almaktadır. Bu doğrultuda literatürde yer alan pek çok çalışma, iklimsel olayların

etiklediği taşkınların havza üzerindeki etkilerini incelemektedir. Bu amaçla farklı taşkın modelleme yöntemleri geliştirilmiş olsa da bu modellerin doğruluk oranları arasında henüz bir standart sağlanamamıştır. Dolayısıyla taşkınların, taşkın havzalarını ne ölçüde ve hangi şiddette etkileyebileceği, araştırmacıların üzerinde durduğu temel konulardan biri olmaya devam etmektedir (Kaya, 2017).

## **2.2. Yapay Zekâ Modelleri ile Taşkın Tahmini**

İklim koşullarının dinamik yapısı nedeniyle, taşkın tahminlerinde fiziksel süreçler aracılığı ile belirlenmesi karmaşık bir görevdir. Fiziksel tabanlı modeller, karmaşık hidrolojik sistemlerin fizyografik ve jeomorfik özellikleri nedeniyle büyük bir belirsizlik derecesine sahiptir (Mosavi vd. 2018). Hidrolojik olayları tahmin etmek için çeşitli hidro-jeomorfolojik izleme türleri gereklidir ve kapsamlı hidrolojik parametreleri toplamak oldukça zor olabilir. Ayrıca fiziksel tabanlı modellerin pratik uygulaması, gerekli verilerin eksikliği ve veri edinme maliyetindeki sınırlılıklar nedeniyle dezavantajlara sahiptir. Birkaç durumda, fiziksel tabanlı modeller düzgün bir şekilde tahminde bulunamamıştır (Van den Honert ve McAneney, 2011). Bu nedenle alternatif olarak veriye dayalı modellerin taşkın tahmininde daha pratik ve güvenilir şekilde kullanımı nedeniyle tercihe edilmeye başlanmıştır (Abu-Salih vd. 2023).

Gelişmiş yapay zekâ modelleri, taşkın ötelemesi tahmininde alternatif bir yaklaşım olarak önemli bir yer tutmaktadır ve sayısal ve fiziksel modellerden daha çok öne çıkmıştır. AI yaklaşımları, taşkın hidrografi tahmininde iklim ve hidro-meteorolojik verilerinden faydalanarak umut verici sonuçlar üretme kapasitesine sahiptir (Mosavi vd. 2018). Bu teknikler genellikle geçmiş taşkın hidrografları ile eğitilerek gerçekleşmesi muhtemel olan taşkın hidrografının üretilmesinde kullanılabilmektedir. AI modelleri karmaşık ilişkileri modelleme ve genelleme yeteneği sayesinde hidrolojide etkin bir şekilde kullanılmaya başlanmıştır. Ayrıca taşkın risk yönetimi için önemli bir konu olan taşkın hidrografının tahmin edilmesinde doğrusal olmayan dinamiklerini ve durağan olmayan davranışları etkili bir şekilde yakalayarak yorumlama kapasitesine sahiptir. AI modelleri çoğu durumda fiziksel tabanlı modellerden ve sayısal modellerden daha iyi bir performansa sahiptir. Modellerin hibridizasyonu yakın zamanda önemli iyileştirmeler için rapor edilmiştir (Bellos ve Tsakiris, 2016; Abu-Salih vd. 2023). Bu nedenle metasezgisel optimizasyon teknikleri ve AI modellerinin birleştirilmesi ile yenilikçi hibrit yaklaşımlar ile taşkın tahminlerinin yüksek doğrulukta tahmin edilmesi beklenmektedir.

### 2.3. Kaynak Özetleri

Taşkın ötelemesinin doğru bir şekilde tahmini, riskli bölgelerde önlemlerin alınması, bölgede can ve mal kaybının önlenmesi ve tarım alanlarının korunmasına yardımcı olmaktadır. Nayak vd. (2004) akarsu akımını tahmin etmek amacıyla ANN ve bulanık çıkarım sistemlerinin birleşiminden oluşan Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (Adaptive Network Based Fuzzy Inference System-ANFIS) modeline başvurmuşlardır. Analizler sonucunda orijinal akarsu akışı serisinin istatistiksel özelliklerinin korunduğu ve umut verici sonuçlar elde edildiği görülmüştür. ANFIS yönteminin geleneksel tekniklerden daha etkili tahminler ürettiği tespit edilmiştir. Liu vd. (2016) taşkın tahmini için k-en yakın komşu (K-Nearest Neighbor-KNN) algoritmasını, Kalman filtresi (KF) ile birleştirilerek KN2K modelini ortaya çıkarmıştır. KNN yaklaşımının uygulanması ile gelişmiş güncelleme sonuçlarının üretilebileceği tespit edilmiştir. Analizler KN2K yönteminin gerçek zamanlı taşkın tahmininde yüksel potansiyele sahip olduğunun göstermektedir. Yaseen vd. (2017) aylık akışları tahmin etmek için sezgisel algoritma ve bulanık mantık tekniklerini kullanmıştır. ANFIS modelinin eğitiminde meta sezgisel bir algoritma olan ateş böceği (Firefly Algorithm -FFA) algoritması kullanmışlardır. Analizler sonucunda hibrit FFA-ANFIS modelinin üstün sonuçlar ürettiğini gösterilmiştir. Hassanvand vd. (2018) taşkın ötelemesi için ANN ve ANFIS algoritmalarını hibritleştirilerek kullanılmıştır. Yarasa algoritması (Bat Algorithm-BA) ve emperyalist rekabetçi algoritma (Imperialist Competitive Algorithm-ICA) kullanılarak ANN modellerinin ve genetik algoritma ve parçacık sürüsü optimizasyon algoritmasını ANFIS modeli optimize edilerek taşkın hidrografi tahmini yapılmıştır. 8 taşkın hidrografının ağ eğitimi için 6 hidrograf ve ağ testi için 2 hidrograf kullanmıştır. ANN-ICA'nın hidrograf hacmini, tepe akışını ve taşkın süresini en doğru model olarak ortaya çıkarılmıştır. Liu vd. (2020) Çin'deki üç havzada uzun kısa süreli bellek sinir ağını (Long Short Term Memory Neural Network-LSTM) ve KNN algoritmalarını yağış-akış ilişkilerini simüle etmek amacıyla kullanmıştır. Model doğruluğu çeşitli istatistiksel yaklaşımlar ile değerlendirilmiştir. Sonuç olarak LSTM-KNN modelinin gerçek zamanlı taşkın tahmin potansiyelinin umut verici olduğu vurgulanmıştır. Sahana vd. (2020) fırtına dalgası taşkın duyarlılığı analizinde geleneksel frekans oranı, değiştirilmiş frekans oranı ve destek vektör makinesi (Support Vector Machine-SVM) yaklaşımlarının potansiyelini değerlendirmeyi amaçlamışlardır. Sundarban Biosphere Reserve'nin çekirdek alanları ve nehirler boyunca uzanan bazı bölgelerinde önemli ölçüde duyarlılık gözlenmiştir. Orta derecede duyarlılık, Rezervin kuzey, kuzeybatı ve güneybatı kesimlerindeki bazı bölgelerde yayginken,



Rezervin batı kısmında (kıyıdan uzakta yer alan) düşük duyarlılık gözlemlenmiştir. Uzamsal olarak kabul edilen duyarlılık alanı, değiştirilmiş frekans oranı ve SVM modelinde daha düşük (%65,1) iken, değiştirilmiş frekans oranı ve SVM modelleri arasında en yüksek (%83,2) olmuştur. Böylece, SVM modelinin SBR'deki fırtına dalgası taşkın duyarlılığını analizinde optimum sonuçlara ulaşmıştır. Pourghasemi vd. (2020) ANFIS ile genetik algoritma (GA), simüle edilmiş tavlama (SA), emperyalist rekabetçi algoritma (ICA) ve diferansiyel evrim (DE) teknikleri birleştirilerek Çin'in Dingnan İlçesi'ndeki sel riskinin haritalandırılmıştır. Sonuçlar, en doğru sonuçların ANFIS–GA topluluğu ile elde edildiği ardından ANFIS–SA, ANFIS–DE ve ANFIS–ICA geldiğin ortaya çıkarmıştır. Sahoo vd. (2021) Hindistan Mahanadi Nehri'nde taşkın tahmini için ANFIS modelini meta-sezgisel Gri Kurt Optimizasyonu (Gray Wolf Optimizer-GWO) ve Çekirge Optimizasyon Algoritması (Grasshopper Optimization Algorithm-GOA) ile birleştirmiştir. Önerilen meta-sezgilerin performansını, 50 yıllık aylık tarihsel taşkın deşarj verilerini göre bir ANFIS modeliyle karşılaştırılarak analiz edilmiştir. Sonuçlar, hibrit ANFIS-GOA'nın bağımsız AI algoritmalarından daha üstün sonuçlar gösterdiğine ortaya çıkarmıştır. Katipoğlu ve Sarıgöl (2023) Torbalı Ağaç (Bagged tree-BT), Gradyan Artırılma Makinesi (Gradient Boosting Machine-GBM), Rastgele Orman (Random Forest-RF), KNN, SVM ve Ekstrem Gradyan Artırma (Extreme Gradient Boost-XGBOOST) algoritmalarını kullanarak İç Anadolu bölgesindeki 3 ilin taşkın tahminini yapmışlardır. Model performansları kök ortalama kare hata, ortalama mutlak hata ve belirleme katsayısı gibi çeşitli istatistiksel göstergelere göre test edilmiştir. Analizlere göre taşkın ötelemesi tahmininde GBM optimum çıktıları üretmesi sayesinde en iyi yapay zekâ yaklaşımı olduğu ileri sürülmüştür. Sarıgöl ve Katipoğlu (2023) günlük ortalama taşkın hidrograf verilerini regresyon ağacı, Gauss süreci regresyonu, SVM, ANFIS ve regresyon ağacı toplulukları gibi çeşitli veriye dayalı modelin eğitimde kullanmıştır. Ardından eğitilen modeller göre 2015 yılı saatlik taşkın hidrografi tahmin edilmiştir. Kurulan tahmin modellerinin performansı çeşitli istatistiksel ve grafiksel göstergelere göre değerlendirilmiştir. Buna göre girdileri 5 alt kümeye ayırdığı ve üçgen üyelik fonksiyonunun kullanılarak kurulan ANFIS modeli en üstün sonuçları vermiştir. Yapılan çalışmalar incelendiğinde taşkın ötelemesi tahmininde hibrit doğa tabanlı optimizasyon ve sinir ağlarının birlikte kullanıldığı çalışmalar sınırlıdır. Bu bağlamda, çalışma konusu, taşkın ötelemesi tahmini alanında özgün ve yenilikçi bir yaklaşım sunmaktadır. Metasezgisel optimizasyon tabanlı ANN modelleri, taşkın ötelemesi tahmininde geleneksel yöntemlere kıyasla daha doğru ve hassas sonuçlar elde etme potansiyeline sahiptir. Bu modeller, hidrolojik verilere dayanarak taşkın ötelemesi tahmininde en uygun parametre değerlerini belirlemek için optimize edilmiştir. Bu sayede, taşkın ötelemesi tahminleri daha güvenilir ve doğru hale

getirmektedir. Ghalkhani vd. (2013) İran'ın Madarsoo havzasında bir FFWS için taşkın ötelemesi amacıyla yapay zekâ tabanlı iki model, yapay sinir ağı (ANN) ve uyarlanabilir bulanık çıkarım sistemi (ANFIS) kullanmışlardır. Bu amaçla, farklı yağış desenleri, Hidrolojik Mühendislik Merkezi (HEC)-1 hidrolojik modeli kullanılarak akış hidrograflarına dönüştürülmüş ve nehir boyunca HEC nehir analiz sistemi (RAS) hidrodinamik modeli ile yönlendirmişlerdir. Daha sonra, farklı gecikme zamanlarına sahip simüle edilen hidrograflar, ANN ve ANFIS modellerinin eğitimi için giriş verisi olarak kullanılarak havza çıkışında taşkın hidrografını simüle etmek üzere değerlendirmişlerdir. Sonuçlar, ANN ve ANFIS ile elde edilen simülasyonların HEC-RAS tarafından simüle edilen sonuçlarla uyumlu olduğunu gösterilmiştir. Bu nedenle, bu tür modellerin FFWS'lerde taşkın ötelemesi için yedek bir araç olarak kullanılması şiddetle önerilmektedir. Bui vd. (2016) taşkın duyarlılık modeli oluşturmak için sinirsel bulanık çıkarım sistemi kullanılmış ve ardından modeli, İki Meta-sezgisel Algoritma (Evrimsel Genetik Algoritma ve Parçacık Sürü Optimizasyonu) ile optimize etmişlerdir. Çalışma alanı olarak, tropikal siklonların sık görüldüğü Vietnam'ın Merkezi Tuong Duong bölgesi seçilmiştir. İlk olarak, çalışma alanı için bir CBS veritabanı oluşturulmuştur. Bu veritabanı, 76 tarihi taşkın alanını ve taşkınları etkileyen on faktörü içermekte olup, önerilen modelin geliştirilmesi ve doğrulanmasında kullanılmıştır. Modelin performansı ve öngörü yeteneği, Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE), alıcı çalışma karakteristiği (ROC) Eğrisi ve ROC Eğrisi Altındaki Alan (AUC) ile değerlendirilmiştir. Deneysel sonuçlar, önerilen modelin hem eğitim (RMSE = 0.306, MAE = 0.094, AUC = 0.962) hem de doğrulama veri setinde (RMSE = 0.362, MAE = 0.130, AUC = 0.911) yüksek performans gösterdiğini ortaya koymuştur. Önerilen modelin kullanılabilirliği, J48 Karar Ağacı, Rastgele Orman, Çok Katmanlı Algılayıcı Sinir Ağı, Destek Vektör Makinesi ve Uyarlanabilir Bulanık Çıkarım Sistemi gibi son teknoloji yumuşak hesaplama tekniklerinden elde edilen sonuçlarla karşılaştırılarak değerlendirilmiştir. Sonuçlar, önerilen MONF modelinin bu referans modellerden daha üstün olduğunu göstermiştir. Çalışmada, MONF modelinin taşkın duyarlılık haritalaması için kullanılabilecek yeni bir alternatif araç olduğu sonucuna varılmıştır. Bu çalışmanın sonuçları, taşkına eğilimli alanların sürdürülebilir yönetimi için planlamacılara ve karar vericilere faydalı bilgiler sunmaktadır. Chapi vd. (2017) Taşkın duyarlılığı haritalaması için yeni bir yapay zekâ (AI) modeli olan Bagging-LMT tanıtmışlardır. Bu model, Bagging topluluk yöntemi ile Lojistik Model Ağacı (LMT) kombinasyonuna dayanmaktadır. Çalışma kapsamında, Haraz havzası (Kuzey İran) için bir mekânsal veri tabanı oluşturulmuştur. Bu veri tabanı, bir taşkın envanter haritası ile Bilgi Kazanç Oranı (IGR) yöntemi kullanılarak belirlenen on bir taşkın koşullandırma faktörünü içermektedir. Modelin performansı, kesinlik, duyarlılık,


özgüllük, doğruluk, RMSE, MAE, Kappa ve alıcı ROC altındaki alan (AUC) kriterlerine göre değerlendirilmiştir. Ayrıca model, LMT, lojistik regresyon, Bayes lojistik regresyonu ve rastgele orman gibi dört ileri düzey referans yumuşak hesaplama modeliyle karşılaştırılmıştır. Sonuçlar, önerilen modelin tüm bu modellerden daha üstün bir performans sergilediğini ve taşkına eğilimli alanların sürdürülebilir yönetimi için kullanılabileceğini göstermektedir.



### 3. YÖNTEM

#### 3.1 Yapay Sinir Ağları (Artificial Neural Networks-ANN)

Yapay sinir ağları insan beyninden esinlenerek oluşturulan bir matematiksel modeldir. Yapay sinir ağları veri analizi, görüntü işleme ve tahmin yürütme gibi görevleri yerine getirmek için oluşturulmuştur. Yapay sinir ağları yapay zekâ altında öğrenme ve tahmin etme yeteneklerini kazandırmak amacıyla uygulanır. Yapay sinir ağları insan beynindeki sinir hücrelerini taklit eden yapay nöronlar oluşturur ve bu nöronlar arasında veri alışverişinde bulunarak öğrenme işlemini gerçekleştirir (Bishop 1995). Şekil 1’de yapay sinir ağları örnek nöron yapısı gösterilmiştir. Bu model girdi, gizli ve çıktı katmanından oluşmaktadır. İleri yayılım işleminde veriler giriş katmanından alınır. Her nöron ağırlıklı toplam ve aktivasyon fonksiyonuyla işlenir ve bilgi çıkış katmanına doğru ilerler (Bishop 1995; Abraham 2005; Zou vd. 2009). Bu çalışmada yapay sinir ağı modelinin ağırlık ve önyargı parametreleri, meta-sezgisel optimizasyonları ile optimize edilerek en doğru taşkın tahminlerinin üretilmesi amaçlanmıştır. Bu nedenle hibrit yaklaşımlar ile taşkın tahminleri performansı karşılaştırılmıştır.




Şekil 1. Yapay sinir ağları örnek nöron yapısı

#### 3.2 Yapay Arı Kolonisi (Artificial Bee Colony-ABC) Algoritması

ABC algoritması, Karaboga tarafından 2005 yılında sayısal problemleri optimize etmek için geliştirilmiş sürü tabanlı bir meta-sezgisel algoritmadır (Karaboga, 2005). Yapay arı kolonisi algoritması Tereshko ve Loengarov (2005) tarafından önerilen bal arıların yiyecek arama

davranışlarından esinlenmektedir. Algoritma kendi kendini organize etme ve kolektif zekâ için önemli iki davranışı uygular: yiyecek arayanların zengin yiyecek kaynaklarına alınması, olumlu geri bildirim ve yiyecek arayanların zayıf kaynakları terk etmesi, olumsuz geri bildirim neden olur (Karaboga ve Ozturk 2010; Özturk vd., 2014; Chen vd., 2018).

ABC'de, yapay yiyecek arayan arılardan (temsilciler) oluşan bir koloni, zengin yapay yiyecek kaynakları arar. ABC'yi uygulamak için, ele alınan optimizasyon problemi ilk olarak bir amaç fonksiyonunu en aza indiren en iyi parametre vektörünü bulma problemine dönüştürülür. Ardından, yapay arılar rastgele bir başlangıç çözüm vektörleri popülasyonu keşfeder ve yinelemeli olarak iyileştirir. Zayıf çözümlerden ayrılarak daha uygun çözümlere yönelinmektedir (Karaboga, 2010). ABC algoritması daha az parametreye ihtiyaç duyduğundan kullanımı kolaydır. Ayrıca birçok çözüm uzayında etkili arama yapabilmesi ABC algoritmasının avantajları arasında yer alır. Şekil 2’de ABC’nin uygulanma adımlarını gösteren akış diyagramı verilmiştir.



Şekil 2. Yapay Arı Kolonisi Algoritmasının akış diyagramı


### 3.3 Parçacık Sürüsü Optimizasyon (Particle Swarm Optimization-PSO) Algoritması

Parçacık sürüsü optimizasyonu doğadan esinlenerek geliştirilmiş bir optimizasyon algoritmasıdır. Parçacık sürüsü algoritması kuş sürülerinin veya balık sürülerinin toplu olarak hareketinden esinlenerek oluşturulmuştur. Bir çözüm uzayında gezinen parçacıkların iş birliği ile en iyi çözümü bulmayı amaçlar. Algoritma çok boyutlu optimizasyon problemlerinin çözülmesinde yardımcı olur (Özsağlam ve Çunkaş 2008; Katipoğlu vd. 2023). Sürü olarak bilinen kuşların davranışı, kendileri için belirli yiyecek maddelerini bulmaya dayanır. İlk olarak, popülasyon (parçacık) bazı keyfi olarak üretilen konum değerleriyle başlatılır. Her parçacığın (pbest) en üstün konumu, küresel en iyi parçacık (gbest) hakkındaki bilgiyle birlikte kesintisiz olarak yerel olarak depolanır. PSO algoritmasında sürüdeki tüm parçacıklar bağımsız olduğundan dolayı birçok parametre birbirleriyle ilişkilendirilebilir. Tüm popülasyonun konumu ve hızı sırasıyla aşağıdaki denklemler ile güncellenir (Kennedy and Eberhart 1995). Şekil 3'te PSO'nun çalışma prensibi görselleştirilmiştir. Şekil 4'te PSO'nun uygulanma adımlarını gösteren akış diyagramı verilmiştir.


$$x_{i,n}^{j+1} = x_{i,n}^j + v_{i,n}^{j+1} \quad (1)$$

$$v_{i,n}^{j+1} = wv_{i,n}^j + c_1r_1p_{i,n}^j - x_{i,n}^j + c_2r_2p_{g,n}^j - x_{i,n}^j \quad (2)$$

Burada  $x$ ,  $v$  ve  $w$  sırasıyla pozisyon, hız ve iç ağırlığı göstermektedir.



Şekil 3. Parçacık Sürüsü Optimizasyon Algoritmasının yapısı




Şekil 4. Parçacık Sürüsü Optimizasyon Algoritması akış diyagramı

### 3.4 Genetik Algoritma (Genetic Algorithm-GA)

Genetik algoritma doğal seleksiyon ve genetik çeşitlilik gibi evrimsel kavramlara dayanan bir optimizasyon algoritmasıdır. Bu algoritma evrim teorisinden esinlenerek oluşturulmuştur. Genetik algoritma karmaşık ve çok boyutlu problemlerin çözümünde kullanılır. Genetik algoritma büyük çözüm uzayındaki optimal değer bulmasında kullanılır (Gül Gökay ve Taşkın, 2002; Sivanandam vd. 2008). Genetik algoritma popülasyon tabanlı bir algoritma olduğundan farklı bireyler aynı anda değerlendirilebilir ve birçok hedefi optimize etmek için kullanılabilir. Şekil 5'te GA'nın çalışma prensibi görselleştirilmiştir. Şekil 6'da GA'nın uygulanma adımlarını gösteren akış diyagramı verilmiştir.



Şekil 5. Genetik Algoritmasının yapısı




Şekil 6. Genetik Algoritma akış diyagramı

### 3.5 Ateş Böceği (Firefly Algorithm-FFA) Optimizasyonu


Yang (2009) tarafından geliştirilen FFA, kısa sürede çok popüler hal alan bir doğadan ilham alan güçlü ve etkili bir optimizasyon algoritmasıdır. Bu algoritma, ateş böceklerinin yanıp sönmesinden esinlenilmiştir. Bu yanıp sönme işlemi potansiyel avı ve çiftleşme partnerlerini çekmek üzere iki basamaktan oluşmaktadır (Yang, 2010). Algoritmada her ateş böceği, parlaklığı (çözüm kalitesi) düşük olan diğer ateş böceklerini çeker. Parlaklık mesafeyle ters



orantılıdır, bu yüzden ateş böcekleri yakınlarındaki daha parlak olanlara doğru hareket eder. Algoritmayı basitleştirmek için üç varsayım bulunmaktadır. Birincisi, tüm ateş böcekleri unisex'tir. İkincisi, daha parlak ateş böceği daha az parlak olanı çeker. Belirli bir ateş böceğine kıyasla daha parlak bir ateş böceği bulunmuyorsa, ateş böcekleri rastgele davranış sergiler. Üçüncüsü, maksimizasyon problemi, parlaklığı amaç fonksiyon değeri olarak ele alınarak basitleştirilebilir. FFA optimizasyonunun temel amacı en iyi çözümü (en parlak ateş böceğini) bulana kadar iterasyonlarla hareket etmektir (Yang, 2009; Fister vd. 2013). Ateşböceği algoritması ışık gücü farkı ile birbirleri arasında çekim kuvvetini belirlediğinden keşif ve sömürü arasında doğal bir denge sağlar. Bu sayede çözüm uzayında etkin bir arama yapabilmeyi sağlar. Şekil 7’de ateş böceklerinin hareketi gösterilmiştir. Şekil 8’de FFA’nın uygulanma adımlarını gösteren akış diyagramı verilmiştir.



Şekil 7. Ateş böceklerinin hareketinden esinlenen FFA'nın yapısı




Şekil 8. FFA'nın akış diyagramı

### 3.6 Karışık Kurbağa Sıçraması Algoritması (Shuffled Frog Leaping Algorithm-SFLA)

Eusuff vd. (2006) tarafından geliştirilen kurbağa sıçraması algoritması, doğadan ilham alan bir optimizasyon algoritmasıdır. SFLA algoritması, bir grup kurbağanın maksimum miktarda yiyecek konumunu arama doğranışından esinlenmektedir. Algoritmada, kurbağalar popülasyonunu temsil eden çözümler, problem uzayında sıçrayarak daha iyi çözümler bulmaya çalışır. Kurbağalar gruplara ayrılır ve her grup, kendi içindeki en iyi çözüm doğrultusunda sıçramalar yapar. Sürekli iyileşme hedeflenir ve kötü çözümler düzeltilerek en iyi çözüme ulaşılır. SFLA bir kombinasyon stratejisi aracılığı ile yerel aramada mesaj alışverişine dayanmaktadır. Bu algoritma, popülasyon veya memepleksler ile adlandırılan farklı bölümlere ayrılan rastgele bir kurbağa grubundan yola çıkar. Yerel ve küresel arama yaklaşımına dayanarak optimum çözümü bulmak için bireysel bir kurbağayı kullanmaktadır (Luo vd. 2008; Dalavi vd. 2016; Mohammadi vd. 2020). Bu algoritma hem yerel aramalar hem de küresel aramalar da mesaj alışverişinde bulunmaktadır. Bu yaklaşım doğrusal olmayan ve belirsiz

vakaları etkili şekilde çözme yeteneğine sahiptir. Karışık Kurbağa Sıçraması algoritması grupların farklı bölgelerde arama yapabilmesini sağlayarak çok modlu problemlerin çözümünde avantaj sağlamaktadır. Şekil 9’da SFLA’nın uygulanma adımlarını gösteren akış diyagramı verilmiştir.



Şekil 9. Kurbağa sıçraması algoritmasının akış diyagramı

### 3.7 Performans Metrikleri

Kurulan modellerin performansı kök ortalama kare hata (RMSE), ortalama mutlak hata (MAE), Akaike Bilgi Kriteri (AIC), Nash-Sutcliffe Verimliliği (NSE), Kling-Gupta Verimliliği (KGE), determinasyon katsayısı ( $R^2$ ), ortalama yanlılık hatası (MBE), yanlılık faktörü (BF) ve yüzde yanlılık (Pbias) gibi istatistiksel metriklerle göre sınanmıştır. RMSE, tahmin edilen değerler ile gözlemlenen değerler arasındaki farkların karelerinin ortalamasının karekökünü ifade eder. MAE, tahmin edilen değerler ile gözlemlenen değerler arasındaki mutlak farkların ortalamasıdır. AIC, tahmin edilen modelin karmaşıklığını ve veri uyumunu bir arada değerlendiren bir kriterdir. NSE, gözlemlenen değerlerin ortalamasına göre tahmin edilen

değerlerin nispi performansını ölçer. KGE, Korelasyon, yanlılık ve standart sapmalar arasındaki ilişkiyi bir arada değerlendiren bir verimlilik ölçütüdür.  $R^2$ , bağımlı değişkendeki toplam varyansın ne kadarının bağımsız değişkenler tarafından açıklandığını gösterir. MBE, tahmin edilen değerler ile gözlemlenen değerler arasındaki ortalama farkı gösterir. BF, tahmin edilen değerlerin gözlemlenen değerlere göre ortalama oranını ifade eder. Pbias, tahmin edilen değerlerin gözlemlenen değerlere göre ortalama yüzde farkını gösterir. Pbias değeri 0'a ne kadar yakınsa, model o kadar tarafsızdır ve 0 en iyi değerdir. Daha düşük RMSE, MAE ve AIC değeri, daha iyi bir model performansını gösterir (Harmel vd. 2007, 2010; Moriasi vd. 2015).



Şekil 10. Değişkenlerinin dağılımına göre ilişki analizi

Korelasyon katsayısı (r): İki değişken arasındaki ilişkinin yönünün ve gücünü ifade etmek için kullanılmaktadır. Tablo 1'de korelasyon katsayısının değerine göre değişkenlerin ilişkisi ifade edilmiştir. Pozitif değerler doğru orantılı ilişkiyi gösterirken negatif değerler ters orantıyı göstermektedir (Öztuna vd. 2008; Choi vd. 2010; Aslan vd. 2019). Şekil 10'da değişkenlerinin dağılımına göre ilişkinin görselleştirilmesi yapılmıştır. Korelasyon katsayıları taşkın saçılma diyagramları ve ısı haritalarının yorumlanmasında kullanılmıştır.

Tablo 1. Korelasyon katsayılarının sınıflandırılması

| Korelasyon katsayısı (r) | İlişki                                                |
|--------------------------|-------------------------------------------------------|
| 0.00 - 0.19              | İlişki yok ya da önemsenmeyecek derecede düşük ilişki |
| 0.20 - 0.39              | Zayıf ilişki                                          |
| 0.40 - 0.59              | Orta düzeyde ilişki                                   |
| 0.60 - 0.79              | Kuvvetli ilişki                                       |
| 0.80 - 1                 | Çok Kuvvetli ilişki                                   |

### 3.8. Çalışma Alanı

Karadeniz ikliminin etkisi altında olan çalışma alanı kışları yumuşak ve yağmurlu, yazları ılıman ve oldukça yağışlı bir yapıya sahiptir. Bölgede sahilden uzaklaştıkça yazlar kurak ve ılık, kışlar yağışlı ve soğuk bir hal almaktadır. Bölgenin engebeli bir yapıda olması doğudan batıya doğru düşen yağış miktarının farklılaşmasına neden olmaktadır. Çalışma alanında yağışın değişimi hâkim rüzgâr yönü, yamaçların yönelimi ve rakım etkili parametrelerdir (DKMP, 2016; Beyazlı vd. 2021).


Türkiye'nin en yüksek yağış oranına sahip olan bölgesinde su kaynakları açısından zenginlik bulunmak taktadır. Akarsular, dağlardan doğmaktadır ve dar ve derin vadilerde denize dik bir şekilde hareket etmektedir. Dereler sağanak yağıştan sonra yamaçlardan akan su nedeniyle oluşmaktadır. Bu nedenle yağışların etkisi ile düzensiz sel rejimine göre taşkınlar görülmektedir. Ayrıca bölgenin çok eğimli olması nedeniyle denize dökülen kısımlarda akarsu katı madde taşınımı fazladır (DKHKEY, 2013).



Şekil 11. Çalışma alanının coğrafi koordinatları

Taşkın hidrografi tahminleri için Ordu-Turna suyundaki 2009 ve 2013 yılında meydana gelen taşkın verileri kullanılarak yapılmıştır. Bu taşkınlara ait hidrograflar Şekil 12’de gösterilmiştir. Modelleme sırasında memba istasyonundaki (22A093) 30 dakikalık akımlar girdi ve


mansaptaki (22A063) 30 dakikalık akımlar hedef değışkeni olarak kullanılmıştır. Şekil 11’de çalışma alanının coğrafi koordinatları sunulmuştur.



Şekil 12. Çalışmada kullanılan taşkın verileri

### 3.9. Çalışmanın Akışı

Bu çalışmada çeşitli metasezgisel optimizasyon teknikleri ile ANN modelinin önyargı ve ağırlıkları optimize edilmiştir. Kurulan hibrit algoritmalar ile tekil ANN modelinin performansı karşılaştırılarak optimizasyon yaklaşımlarının taşkın tahminine etkileri değerlendirilmiştir. Tez çalışmasının detaylı akış diyagramı Şekil 13’te verilmiştir.



Şekil 13. Çalışmanın akış diyagramı

#### 4. BULGULAR


Bu çalışmada Ordu ilindeki 2009 ve 2013 taşkın hidrograflarının tahmini için ANN modeli 5 farklı metasezgisel optimizasyon algoritması ile birleştirilerek hibrit modeller kurulmuştur. Kurulan hibrit modellerin taşkın öteleme performansı tekli ANN ile karşılaştırılmıştır. Kurulan modellerde Levenberg Marquard eğitim algoritması, ileri beslemeli sinir ağı, 1 gizli katman ve gizli katmanda 10 nöron, 200 iterasyon, öğrenme oranı 0.1 ve metasezgisel optimizasyonda popülasyon sayısı 30 seçilmiştir.

##### 4.1 2009 Yılı Taşkınlarının Tahmin Değerlendirmesi

Bu çalışmada taşkın öteleme tahmin sonuçlarının karşılaştırılması için ısı haritaları, kümülatif dağılım grafikleri, Taylor diyagramları, keman grafikleri, kutu diyagramları, saçılma grafikleri, sütun grafikleri ve çizgi grafikleri ile sonuçlar görselleştirilmiştir. Ayrıca elde edilen test çıktıları çeşitli istatistiksel metriklere göre değerlendirilmiştir.


Şekil 14'te ısı haritaları ile taşkın tahmin modellerinin test aşamasına ait Pearson korelasyon katsayıları analiz edilmiştir. Bu grafiğe göre gözlemlenen veriler ile tahmin edilen değerlerin ilişkileri renklendirilmiştir. Değerlerin yoğunluğu veya büyüklüğü renk tonlarıyla ifade edilmiştir. Koyu kırmızı değerler en yüksek ilişkiyi gösterirken koyu mavi değerler en düşük ilişkiyi göstermektedir. Buna göre gözlemlene veriler ile tahmin edilen veriler arasında genellikle hibrit modeller yüksek ilişki gösterirken tekil ANN modeli orta düzey ilişki göstermiştir. Ayrıca gözlemlene veriler ile FFA-ANN modeli en yüksek korelasyon gösterirken PSO-ANN modeli ikinci en yüksek ilişkiye sahiptir.






Şekil 14. Isı haritaları ile taşkın tahminlerinin değerlendirilmesi

Şekil 15’te test verilerinin kümülatif dağılım grafikleri ile 2009 yılı taşkın tahminlerinin karşılaştırılması yapılmıştır. Buna göre taşkın verilerinin kümülatif olarak nasıl dağıldığı görselleştirilmiştir. Yatay eksen taşkın değerlerinin gösterirken dikey eksen ise verilerin kümülatif olarak görülme olasılığını göstermektedir. Bu olasılık değerleri karşılaştırıldığında gözlemlenen akım değerleri ile ABC-ANN ve PSO-ANN hibrit modelleri en iyi uyum sergilerken tekil ANN modeli en zayıf uyumu göstermektedir. Buna göre hibrit modellerin ANN modeline göre çok daha doğru taşkın tahminlerinde bulunduğu ortaya çıkarılmıştır.




Şekil 15. Kümülatif dağılım grafikleri ile taşkın tahminlerinin değerlendirilmesi

Şekil 16’da 2009 yılına ait taşkınların Taylor diyagramları ile performans değerlendirmesi yapılmıştır. Grafikte merkezden uzaklaştıkça standart sapma artar. Ayrıca referans noktasına en yakın standart sapmaya, en yüksek korelasyona ve en düşük hata değerlerine göre en iyi model seçimi yapılabilmektedir. Buna göre hibrit modellerin standart sapması referans noktasına yakınken, ANN modelinin standart sapması en uzaktır. Ayrıca PSO-ANN ve FFA-ANN modelleri en yüksek korelasyon ve en düşük hata değerleri ile diğer modellere göre az da olsa öne çıkmaktadır.




Şekil 16. Taylor diyagramları ile taşkın tahmin modellerinin karşılaştırılması

Şekil 17’de 2009 yılına ait taşkınların Keman diyagramları ile performans değerlendirmesi yapılmıştır. Keman şeklindeki çizgiler ile verilerin dağılımın genişliği, yoğunluğu ve simetrisini karşılaştırmakta kullanılmaktadır. Gözlemlenen taşkın verileri ve yapay zekâ algoritmaları ile tahmin edilen taşkın değerlerinin dağılım benzerliklerine göre en iyi model seçilmiştir. Buna kriterlere göre PSO-ANN ve ABC-ANN modellerinin dağılımları gözlemlenen verileri en iyi temsil etmesi nedeniyle en iyi modeller olarak değerlendirilebilir. Ayrıca FFA-ANN ve tekil ANN gözlemlenen veriler ile önemli sapma sergilemesi açısından en zayıf modeller olarak ifade edilmiştir.




Şekil 17. Keman grafikleri ile taşkın tahmin modellerinin karşılaştırılması

Şekil 18’de kutu diyagramları ile taşkın tahminlerinin karşılaştırılması yapılmıştır. Kutu diyagramları veri kümesinin dağılımını, merkeziliğini ve yayılımını görselleştirmek için kullanılır. Kutunun üst kenarı verilerin birinci ve alt kenarı üçüncü çeyreklerini ifade eder. Kutunun ortasındaki çizgi ise verilerin medyan değerini göstermektedir. En üstün tahmin modelinin seçilmesi için gözlemlenen veriler ile tahmin edilen verilerin karakteristikleri ve dağılımları karşılaştırılmıştır. Buna göre PSO-ANN ve ABC-ANN modellerinin dağılımları gözlemlenen verileri en iyi temsil etmesi nedeniyle en iyi modeller olarak tespit edilmiştir. Ayrıca FFA-ANN ve tekil ANN gözlemlenen veriler ile büyük sapma göstermesi nedeniyle en zayıf modeller olarak değerlendirilmiştir.




Şekil 18. Kutu diyagramlar ile taşkın tahminlerinin değerlendirilmesi

Şekil 19’da merkezi saçılma grafikleri ile taşkın ötelemesi sonuçları karşılaştırılmıştır. Bu grafikler veri noktalarının merkezi eğilimini, dağılımını ve yoğunluğunu açıklamak için kullanılmaktadır. Buna göre SFLA-ANN başta olmak üzere PSO-ANN, ABC-ANN ve GA-ANN hibrit modelleri sırası ile en yüksek oranda merkezde kümelenmiş ve lineer bir ilişki göstermesi açısından gözlemlenen akım verileri ile örtüşmektedir. Ayrıca FFA-ANN ve ANN modeli gözlemlerden büyük ölçüde sapmış ve aykırı değerlere sahip olduğu dikkat çekmektedir. Şekil 20’de ise çizgi grafikleri ile tahmin değerleri ile gözlemlenen akım değerleri karşılaştırılmıştır. Kurulan hibrit modellerin genellikle gözlemlenen verilere paralel hareket etmesi nedeniyle güvenilir tahminlerde bulunduğu çıkarımı yapılabilmektedir. Ayrıca ABC-ANN modeli gözlemlenen veriler ile en yüksek benzerlik göstermesi açısından en üstün model olarak seçilmiştir.



Şekil 19. Merkezi saçılma grafikleri ile taşkın tahmin modellerinin karşılaştırılması



Şekil 20. Çizgi grafikleri ile taşkın tahmin modellerinin karşılaştırılması

Tablo 2’de 2009 yılı taşkın tahminlerine ait test aşamasındaki istatistiksel değerler gösterilmiştir. Bu değerlere göre en doğru ve güvenilir model analiz edilmiştir. En düşük hata,


AIC ve Pbias değerleri ve en yüksek KGE,  $R^2$ , NSE ve BF değerlerine sahip olan model optimum olarak seçilmiştir. Buna göre ABC-ANN tüm kriterler bütünlüklü düşünülüğünde en doğru sonuçları ürettiği ortaya çıkarılmıştır. PSO-ANN ise ikinci en iyi model iken tekli ANN EN zayıf model olarak belirlenmiştir.

Tablo 2. 2009 yılı taşkın tahminlerinin test sonuçları

|       | ANN**  | SFLA-ANN | FFA-ANN | <b>ABC-ANN</b> | GA-ANN | PSO-ANN* |
|-------|--------|----------|---------|----------------|--------|----------|
| RMSE  | 22.33  | 7.49     | 12.13   | <b>1.84</b>    | 9.44   | 2.38     |
| MAE   | 19.35  | 7.42     | 12.11   | <b>1.54</b>    | 9.35   | 2.27     |
| AIC   | 356.09 | 231.49   | 286.50  | <b>71.63</b>   | 257.95 | 101.06   |
| NSE   | -4.60  | 0.37     | -0.65   | <b>0.96</b>    | 0.00   | 0.94     |
| KGE   | 0.13   | 0.77     | 0.62    | <b>0.94</b>    | 0.70   | 0.93     |
| $R^2$ | 0.14   | 0.99     | 1.00    | <b>0.97</b>    | 0.99   | 0.99     |
| MBE   | -19.35 | -7.42    | 12.11   | <b>0.35</b>    | -9.35  | -2.27    |
| BF    | 1.51   | 1.33     | 0.72    | <b>0.99</b>    | 1.50   | 1.08     |
| Pbias | -59.84 | -22.93   | 37.45   | <b>1.07</b>    | -28.91 | -7.02    |

Not: Koyu karakter en iyi modeli, \* işareti 2. İyi modeli ve \*\* en zayıf modeli göstermektedir.

Şekil 21’de radar grafiğine göre 2009 taşkının tahmin performansları analiz edilmiştir. RMSE ve MAE değerlerine göre ABC-ANN en düşük hataya sahip olması nedeniyle en iyi model iken PSO-ANN ikinci en iyi model olarak tespit edilmiştir.  $R^2$  değerlerine göre ANN dışındaki tüm modeller gerçek veriler ile mükemmel yakın ilişki göstermektedir. Yanlılık faktörüne göre ABC-ANN modeli 1’e yakın değerler göstermesi nedeniyle tahmin edilen ve gözlemlenen taşkın hidrografi büyük ölçüde örtüştüğünü kanıtlamaktadır.



Şekil 21. Radar grafiğine göre 2009 taşkınının tahmin doğruluğunun değerlendirilmesi


Tablo 3'te 2009 yılına ait hibrit taşkın tahminlerinin ANN modeline göre yüzde değişimleri gösterilmiştir. ABC-ANN modeli, RMSE:-91.75, MAE:-92.04, AIC: -79.88 ve MBE:-101.79 değişimler en düşük hata ve en yüksek doğruluğa sahiptir. Yüzde eğişimler dikkate alındığında ANN modelinin performansını sırası ile ABC, PSO, SFLA, GA ve FFA ile artırdığı görülmektedir. Ayrıca RMSE değerlerinin yüzde değişlerine göre metasezgisel optimizasyon algoritmaları tekil ANN modelini hata düzeyini taşkın tahmininde %45 ile %93 aralığında azalttığı tespit edilmiştir.



Tablo 3. 2009 taşkın tahminlerinin ANN modeline göre yüzde değişimler

|      | SFLA-ANN | FFA-ANN | ABC-ANN | GA-ANN | PSO-ANN |
|------|----------|---------|---------|--------|---------|
| RMSE | -66.48   | -45.69  | -91.75  | -57.72 | -89.32  |
| MAE  | -61.67   | -37.41  | -92.04  | -51.69 | -88.27  |
| AIC  | -34.99   | -19.54  | -79.88  | -27.56 | -71.62  |
| MBE  | -61.67   | -162.59 | -101.79 | -51.69 | -88.27  |

Şekil 22’de sütun grafiğine göre 2009 taşkın tahmin hatalarının tekli ANN modeline göre yüzde değişimi görselleştirilmiştir. Buna göre ABC-ANN modelinde hata değerleri yaklaşık %92 civarında düşerek ANN modeline göre tahmin doğruluğu büyük ölçüde iyileştirilmiştir. Ayrıca tüm hibrit modellerin taşkın tahmininde ANN modelinin doğruluğunun önemli ölçüde geliştirdiği ortaya çıkarılmıştır.




Şekil 22. Sütun grafiğine göre taşkın tahmin hatalarının tekli ANN modeline göre değişimi

#### 4.2 2013 Yılı Taşkınlarının Tahmin Değerlendirmesi


Şekil 23’te 1s1 haritaları ile taşkın tahmin modellerinin test aşamasına ait Pearson korelasyon katsayıları değerlendirilmiştir. İlişkinin büyüklüğü kırmızı renk tonlarıyla gösterilmiştir. Bu grafiğe göre gözlemlene veriler ile tahmin edilen veriler arasında genellikle hibrit modeller

mükemmele yakın çok kuvvetli ( $R>0.94$ ) ilişki gösterirken tekil ANN modeli de  $R=0.79$  değeri ile kuvvetli ilişki göstermiştir. Ayrıca gözlemlene veriler ile PSO-ANN modeli en yüksek korelasyon gösterirken ABC-ANN modeli ikinci en yüksek ilişkiye sahiptir.




Şekil 23. Isı haritaları ile taşkın tahminlerinin değerlendirilmesi

Şekil 24’te test verilerinin kümülatif dağılım grafikleri ile 2013 yılına ait taşkın tahminlerinin analiz edilmiştir. Buna göre taşkın verilerinin kümülatif dağılımı, olasılığı ve merkeziliği görselleştirilmiştir. Bu olasılık değerleri karşılaştırıldığında gözlemlenen akım değerleri ile ABC-ANN hibrit modeli en iyi uyum sergilerken tekil ANN modeli en zayıf uyumu sergilemiştir.




Şekil 24. Kümülatif dağılım grafikleri ile taşkın tahminlerinin değerlendirilmesi

Şekil 25’te 2013 yılına ait taşkınların Taylor diyagramları ile modellerin tahmin doğrulukları karşılaştırılmıştır. Grafikte İdeal bir model, merkeze yakın olan ve en düşük hata değeri gösterme kriterleri göre seçilmektedir. Buna göre PSO-ANN ve ABC-ANN modelleri en düşük hata değerleri ile öne çıkmaktadır. Bu modellerin standart sapma değerleri karşılaştırıldığında referans noktası ile neredeyse aynı standart sapmaya sahip olan ABC-ANN modeli PSO-ANN modeline göre üstünlük sağlaması nedeniyle en üstün model olarak seçilebilmektedir.




Şekil 25. Taylor diyagramı ile taşkın tahmin modellerinin karşılaştırılması

Şekil 26’da 2013 yılına ait taşkınların keman diyagramları ile performans değerlendirmesi yapılmıştır. Keman şeklindeki çizgiler ile verilerin dağılımın genişliği, yoğunluğu ve simetrisini değerlendirilmektedir. Gözlemlenen taşkın verileri ve tahmin modellerinin dağılım benzerliklerine göre en optimum modele kara verilmiştir. Buna kriterlere göre ABC-ANN modeli dağılımları gözlemlenen verileri en iyi temsil etmesi nedeniyle optimum modeller olarak seçilmiştir. Ayrıca tekil ANN gözlemlenen veriler ile önemli sapma sergilemesi açısından en zayıf modeller olarak ifade edilmiştir.




Şekil 26. Keman grafikleri ile taşkın tahminlerinin değerlendirilmesi

Şekil 27’de kutu diyagramlar ile test aşamasına ait taşkın tahminlerinin değerlendirilmesi yapılmıştır. Kutu diyagramları veri kümesinin dağılımını, merkeziliğini ve yayılımını görselleştirilmiştir. Buna göre ABC-ANN ve FFA-ANN modellerinin dağılımları, medyan değerleri çeyreklik dilimleri ve aykırı değerleri gözlemlenen verileri en iyi ifade etmesi açısından en iyi modeller olarak seçilmiştir. Ayrıca tekil ANN modeli, gözlemlenen verilerin dağılımına uymaması nedeniyle en zayıf modeller olarak seçilmiştir.




Şekil 27. Kutu diyagramlar ile taşkın tahminlerinin değerlendirilmesi

Şekil 28’te merkezi saçılma grafikleri ile taşkın ötelemesi sonuçları karşılaştırılmıştır. Buna göre SFLA-ANN başta olmak üzere PSO-ANN, ABC-ANN ve GA-ANN hibrit modelleri sırası ile en yüksek oranda merkezde kümelenmiş ve lineer bir ilişki göstermesi açısından gözlemlenen akım verileri ile benzerlik göstermektedir. Ayrıca ANN modeli gözlemlerden büyük ölçüde sapmış ve aykırı değerlere sahip olduğu dikkat çekmektedir. Şekil 29’da ise çizgi grafikleri ile tahmin değerleri ile gözlemlenen akım değerleri karşılaştırılmıştır. Kurulan hibrit modellerin genellikle gözlemlenen veriler ile örtüştüğü görülmektedir. Ayrıca ABC-ANN modeli gözlemlenen veriler ile en yüksek benzerlik göstermesi nedeniyle en iyi model olarak seçilmiştir.



Şekil 28. Merkezi saçılma grafikleri ile taşkın tahmin modellerinin karşılaştırılması



Şekil 29. Çizgi grafikleri ile taşkın tahmin modellerinin karşılaştırılması

Tablo 4'te 2013 yılı taşkın tahminlerine ait test aşamasındaki istatistiksel değerler gösterilmiştir. Bu değerlere göre en doğru ve güvenilir model analiz edilmiştir. En düşük hata, AIC ve Pbias değerleri ve en yüksek KGE,  $R^2$ , NSE ve BF değerlerine sahip olan model optimum olarak seçilmiştir. Buna göre ABC-ANN tüm kriterler bütünlüklü düşünülüğünde en doğru sonuçları ürettiği ortaya çıkarılmıştır. GA-ANN ise ikinci en iyi model iken tekli ANN en zayıf model olarak belirlenmiştir.


Tablo 4. 2013 Yılı taşkın tahminlerinin test sonuçları

|       | ANN**  | SFLA-ANN | FFA-ANN | <b>ABC-ANN</b> | GA-ANN* | PSO-ANN |
|-------|--------|----------|---------|----------------|---------|---------|
| RMSE  | 18.56  | 5.94     | 2.51    | <b>1.23</b>    | 2.86    | 4.96    |
| MAE   | 15.05  | 5.78     | 2.29    | <b>0.98</b>    | 2.51    | 4.78    |
| AIC   | 253.22 | 155.21   | 81.22   | <b>19.99</b>   | 92.37   | 139.65  |
| NSE   | -10.78 | -0.21    | 0.78    | <b>0.95</b>    | 0.72    | 0.16    |
| KGE   | -0.75  | 0.88     | 0.61    | <b>0.97</b>    | 0.72    | 0.79    |
| $R^2$ | 0.63   | 0.94     | 0.95    | <b>0.95</b>    | 0.89    | 0.97    |
| MBE   | 15.05  | 5.78     | 0.97    | <b>0.30</b>    | 1.91    | 4.78    |
| BF    | 0.78   | 0.89     | 0.98    | <b>0.99</b>    | 0.96    | 0.91    |
| Pbias | 31.37  | 12.06    | 2.03    | <b>0.63</b>    | 3.99    | 9.96    |

Not: Koyu karakter en iyi modeli, \* işareti 2. İyi modeli ve \*\* en zayıf modeli göstermektedir.

Şekil 30'de radar grafiğine göre 2013 taşkının tahmin performansları analiz edilmiştir. RMSE ve MAE değerlerine göre ABC-ANN en düşük hataya sahip olması nedeniyle en iyi model iken FFA-ANN ve GA-ANN birbirine oldukça yakın ve ikinci en iyi model olarak tespit edilmiştir.  $R^2$  değerlerine göre ANN dışındaki tüm modeller gerçek veriler ile mükemmel yakın ilişki göstermektedir. Yanlılık faktörüne göre ABC-ANN ve FFA-ANN modeli 1'e yakın değerler göstermesi nedeniyle tahmin edilen ve gözlemlenen taşkın hidrografi büyük ölçüde örtüştüğünü kanıtlamaktadır.





Şekil 30. Radar grafiğine göre 2013 taşkınının tahmin doğruluğunun değerlendirilmesi

Tablo 5. 2013 taşkın tahminlerinin ANN modeline göre yüzde değişimler


|             | SFLA-ANN | FFA-ANN | ABC-ANN | GA-ANN | PSO-ANN |
|-------------|----------|---------|---------|--------|---------|
| <b>RMSE</b> | -68.01   | -86.47  | -93.36  | -84.59 | -73.30  |
| <b>MAE</b>  | -61.59   | -84.78  | -93.47  | -83.36 | -68.25  |
| <b>AIC</b>  | -38.70   | -67.92  | -92.10  | -63.52 | -44.85  |
| <b>MBE</b>  | -61.57   | -93.53  | -98.01  | -87.27 | -68.24  |

Not: Koyu yeşil en fazla değişim gösteren modeli göstermektedir.

Tablo 5'te 2013 yılına ait hibrit taşkın tahminlerinin ANN modeline göre yüzde değişimleri gösterilmiştir. ABC-ANN modeli, RMSE:-93.36, MAE:-93.47, AIC: -92.10 ve MBE:-98.01

değişimler en düşük hata ve en yüksek doğruluğa sahiptir. Yüzde eğitimler dikkate alındığında ANN modelinin performansını sırası ile ABC, FFA, GA, PSO ve SFLA ile artırdığı görülmektedir.

Şekil 31’de sütun grafiğine göre 2013 taşkın tahmin hatalarının tekli ANN modeline göre yüzde değişimi görselleştirilmiştir. Buna göre ABC-ANN modelinde hata değerleri yaklaşık %93 civarında düşerek ANN modeline göre tahmin doğruluğu büyük ölçüde iyileştirilmiştir.



Şekil 31. Sütun grafiğine göre taşkın tahmin hatalarının tekli ANN modeline göre değişimi

## 5. TARTIŞMA ve SONUÇ

Bu çalışmada ötelemesi için ABC-ANN modelinin diğer metasezgisel algoritmalarından üstün olduğunu ortaya çıkartmıştır. Ayrıca PSO-ANN ve GA-ANN modellerinde taşkın ötelemesinde umut verici sonuçlar ürettiği ortaya çıkarılmıştır. Hassanvand vd. (2018) taşkın tahmini için ANN ve ANFIS modellerini BA ve ICA ile optimize etmiştir. ANN-ICA'nın hidrograf hacmini, pik akışını ve taşkın süresini daha doğru bir şekilde tahmin ettiği ortaya çıkarılmıştır. Ayrıca kurulan hibrit modellerin taşkın tahmininde tatmin edici sonuçlar üretmesi açısından yapılan çalışma ile örtüştüğü tespit edilmiştir. Pourghasemi vd. (2020) ANFIS ile GA, simüle edilmiş tavlama (SA), ICA ve diferansiyel evrim (DE) optimizasyon algoritması birleştirilerek Çin'in Dingnan İlçesi'ndeki tahminleri yapılmıştır. Analiz sonuçları tüm modellerin umut verici tahmin sonuçları ürettiği ve en doğru modelin ANFIS-GA olduğunun göstermiştir. Pourghasemi vd. (2020) çalışmasının sonuçları hibrit yapay zekâ tekniklerinin taşkın tahminindeki etkinliği açısından yapılan çalışmayı desteklemektedir. Çalışmanın sonuçları Zerouali vd. (2023) ile GA, PSO, FFA tabanlı ANN modellerin yağış tahmininde taşkına benzer şekilde umut verici tahminler üretmesi açısından örtüşürken FFA'nın GA ve PSO dan daha üstün doğrulukta olması açısından ters düşmektedir. Meydana gelen çelişkinin kullanılan girdi kombinasyonu ve tahmin edilen değişken ve iklimsel farklılıktan kaynaklandığı düşünülmektedir.

Çalışma sonucunda tüm optimizasyon tekniklerinin tekli ANN modelinin parametrelerin optimize etmesi sayesinde taşkın hidrografi tahmin doğruluğunu önemli ölçüde geliştirdiği ortaya çıkarılmıştır. Malleswari ve Likitha (2023) çalışmalar metasezgisel optimize teknikleri ile ANN'nin performansının artırması açısından çalışma ile örtüşmektedir. Malleswari ve Likitha (2023) yapay zekâ algoritmalarıyla birlikte optimizasyon teknikleri, taşkın izlenmesi ve erken tahmini için etkili olduğu tespit edilmiştir. Yani guguk kuşu arama algoritması parametre ayarlaması için kullanılarak ANN modelin hibritleştirildiğinde tekli modellere göre daha üstün sonuçlar elde edildiği ortaya çıkarılmıştır. Ayrıca guguk kuşu Arama metasezgisel algoritmasının ile erken uyarı sistemini tahmin etmemize yardımcı olmaktadır. Ayrıca taşkın yönetiminde önemli katkı sağladığı vurgulanmıştır. Sahoo vd. (2021) Hindistan Mahanadi Nehri'ndeki taşkın tahmini için ANFIS modeli doğadan ilham alan Gri Kurt Optimizasyonu (GWO) ve Çekirge Optimizasyon Algoritması (GOA) birleştirilmiştir. Her iki optimizasyon tekniği de tekli ANFIS modelinin doğruluğunun artırmıştır. Sahoo vd. (2021) çalışmasının

sonuçları kullanılan tüm doğadan ilham alan optimizasyon tekniklerini ANN modelinin doğruluğunun geliştirilmesi açısından örtüşmektedir.



## 6. SONUÇ ve ÖNERİLER

Bu çalışmada meta sezgisel optimizasyon algoritmaları ile ANN modelinin ağırlık ve yanlılık parametreleri optimize edilerek hibrit yaklaşımlar kurulmuş ve taşkın ötelemesi tahminindeki performansları değerlendirilmiştir. Çalışma alanı olarak Ordu-Turna suyundaki 2009 ve 2013 yılında meydana gelen taşkın verileri seçilmiştir. Model performansları çeşitli istatistiksel metrikler ve görsellere göre değerlendirilmiştir. Buna göre elde edilen temel sonuçlar aşağıdaki gibi özetlenmiştir:

- ABC-ANN hibrit modeli 2009 taşkınlarını RMSE:1.84, AIC:71.63, KGE:0.94,  $R^2$ :0.97, ve Pbias:1.07 değerleri ve 2013 taşkınlarını ise RMSE:1.23, AIC:19.99, NSE:0.95,  $R^2$ :0.95, ve Pbias:0.63 değerleri ile en doğru sonuçları göstermiştir.
- RMSE değerlerinin yüzde değişlerine göre hibrit modeller, tekil ANN modelini hata düzeyini taşkın tahmininde %45 ile %93 aralığında azalttığı ve tahmin doğruluğunun önemli ölçüde geliştirdiği vurgulanmıştır.
- Isı haritalarına göre 2009 yılında gözlemler ile en yüksek korelasyon gösteren model FFA-ANN iken 2013 yılında PSO-ANN'dir
- Taylor diyagramlarına göre 2009 yılına ait en doğru sonuçları gösteren yaklaşım PSO-ANN iken 2013 yılında ABC-ANN'dir
- Keman grafiklerine göre veri dağılımları karşılaştırılması sonucunda 2009 yılı taşkınlarını en iyi ABC-ANN modeli gösterir iken 2013 yılında ABC-ANN modeli en iyi çıktıları göstermiştir.
- Saçılma grafiklerine göre 2009 yılına ait en iyi model, PSO-ANN iken 2013 yılında SFLA-ANN modelidir.
- Sütun, radar, çizgi, kümülatif dağılım ve kutu diyagramları göre hem 2009 hem de 2013 yıllarına ait en iyi model, ABC-ANN modelidir.
- Sürü üyelerinin birbirleriyle etkileşimini taklit ederek yerel optimuma takılma riskini azaltan meta sezgisel optimizasyon tekniklerinin taşkın ötelemesinde ANN modelinin performansının önemli ölçüde geliştirdiği vurgulanmıştır.
- Kurulan hibrit modeller aracılığıyla daha doğru ve zamanında taşkın tahminler yapılabilir ve taşkın riskine maruz kalan bölgelerin daha önceden uyarılabilmektedir. Böylece can ve mal kaybının azaltılmasına karşı önlem alınma imkânı vermektedir.
- Çalışmanın sonuçları su yöneticilerine olası taşkın risklerini önceden görme, proaktif önlemler alma açısından katkı sunmaktadır.

- Taşkın ötelemelerinin doğru tahmini, taşkın risklerinin etkilidir şekilde yönetilmesine ve kontrol altına alınmasına imkân tanımaktadır. Böylece riskli bölgeler, zamanında belirlenerek gerekli önlemler alınabilir, uygun müdahale yapılabilir, tahliye planları hazırlanabilir ve maddi kayıplar en az düzeye indirilebilir.

Çalışmanın sonuçları karar vericilere ve politika yapıcılara olası taşkın risklerini önceden görme, proaktif önlemler alma ve uygun müdahale stratejileri geliştirme açısından yardımcı olmaktadır. Böylece uygun müdahale yapılabilir, tahliye planları hazırlanabilir ve maddi kayıplar en az düzeye düşürülebilmektedir.

Araştırmanın sınırlamaları ve geliştirilmesi gereken alanlar açısından, farklı bölgelerdeki taşkın verilerinin kullanılması ve daha geniş bir veri setine dayanarak modellerin test edilmesi önemli bir adım olabilir. Ayrıca, taşkın sürecini etkileyen diğer faktörlerin, örneğin iklim değişikliği etkilerinin, modellere dahil edilmesi daha kapsamlı bir taşkın tahmini sağlayabilir. Alternatif yaklaşımlar olarak, derin öğrenme tekniklerinin veya diğer gelişmiş makine öğrenmesi modellerinin hibrit optimizasyon algoritmaları ile birlikte kullanılması denenebilir. Potansiyel uygulamalar açısından, geliştirilen modellerin taşkın erken uyarı sistemlerinde ve taşkın risk haritalarının oluşturulmasında kullanılması mümkündür. Gelecekteki çalışma konuları arasında, tahmin modellerinin gerçek zamanlı veri akışlarıyla entegrasyonu ve taşkın zararlarının azaltılması için müdahale stratejilerinin geliştirilmesi yer alabilir.

## KAYNAKÇA

- Abraham, A. (2005). Artificial neural networks. Handbook of measuring system design.
- Abu-Salih, B., Wongthongtham, P., Coutinho, K., Qaddoura, R., Alshaweesh, O., & Wedyan, M. (2023). The development of a road network flood risk detection model using optimised ensemble learning. *Engineering Applications of Artificial Intelligence*, 122, 106081.
- Alexander, D. (2002). *Principles of Emergency planning and Management*. Oxford University Press google schola, 2, 229-238.
- Aslan, S., Akyol, F. N., Dibooğlu, S., Kantarcı, B., ve Serim, D. (2019). Sağlık alanında kullanılan ilişki katsayıları.
- Bellos, V., & Tsakiris, G., (2016). A hybrid method for flood simulation in small catchments combining hydrodynamic and hydrological techniques. *Journal of Hydrology*, 540, 331–339.
- Beyazlı, D., Editörler, Y., Erbay, M., ve Özlü, A. G. S. (2021). Doğu Karadeniz Yapılı Çevre Tartışmaları.
- Bishop, C. M. (1995). Neural networks for pattern recognition. Oxford university press.
- Bui, D. T., Pradhan, B., Nampak, H., Bui, Q. T., Tran, Q. A., & Nguyen, Q. P. (2016). Hybrid artificial intelligence approach based on neural fuzzy inference model and metaheuristic optimization for flood susceptibility modeling in a high-frequency tropical cyclone area using GIS. *Journal of Hydrology*, 540, 317-330.
- CHANGE, Intergovernmental Panel On Climate (2007). Climate change 2007: The physical science basis. Agenda, 6(07), 333.
- Chapi, K., Singh, V. P., Shirzadi, A., Shahabi, H., Bui, D. T., Pham, B. T., & Khosravi, K. (2017). A novel hybrid artificial intelligence approach for flood susceptibility assessment. *Environmental modelling & software*, 95, 229-245.
- Chen, S., Fang, G., Huang, X., & Zhang, Y. (2018). Water quality prediction model of a water diversion project based on the improved artificial bee colony–backpropagation neural network. *Water*, 10(6), 806.
- Choi, J., Peters, M., & Mueller, R. O. (2010). Correlational analysis of ordinal data: from Pearson'sr to Bayesian polychoric correlation. *Asia Pacific education review*, 11, 459-466.
- Dalavi, A. M., Pawar, P. J., & Singh, T. P. (2016). Tool path planning of hole-making operations in ejector plate of injection mould using modified shuffled frog leaping algorithm. *Journal of Computational Design and Engineering*, 3(3), 266–273.

- DKHKEY (2013). *Doğu Karadeniz Havza Koruma Eylem Planı Raporu*, Orman ve Su İşleri Bakanlığı Su Yönetimi Genel Müdürlüğü, 853 ss.
- DKMP (2016). *Doğu Karadeniz Master Plan Raporu*, Orman ve Su İşleri Bakanlığı, DSİ Genel Müdürlüğü, 1496 ss.
- Ekşi, A., ve Kantarlı, İ. C. (2020). Su taşkınlarına karşı stratejik risk yönetimi izmir ili örneği. *Hastane Öncesi Dergisi*, 5(1), 11-27.
- Eusuff, M. M., Lansey, K.E., & Pasha, F., (2006). Shuffled frog-leaping algorithm: a memetic metaheuristic for discrete optimization. *Engineering Optimization*, 38 (2), 129–154.
- Fister, I., Fister Jr, I., Yang, X. S., & Brest, J. (2013). A comprehensive review of firefly algorithms. *Swarm and evolutionary computation*, 13, 34-46.
- Ghalkhani, H., Golian, S., Saghafian, B., Farokhnia, A., & Shamseldin, A. (2013). Application of surrogate artificial intelligent models for real-time flood routing. *Water and Environment Journal*, 27(4), 535-548.
- Gül Gökay, E. ve Taşkın, Ç. (2002). Genetik algoritmalar ve uygulama alanları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21, 129-152.
- Harmel, D. R., & Smith, P. K. (2007). Consideration of measurement uncertainty in the evaluation of goodness-of-fit in hydrologic and water quality modeling. *Journal of Hydrology*, 337(3), 326- 336.
- Harmel, R. D., Smith, P. K., & Migliaccio, K. W. (2010). Modifying goodness-of-fit indicators to incorporate both measurement and model uncertainty in model calibration and validation. *Trans. ASABE* 53(1), 55-63.
- Hassanvand, M. R., Karami, H., & Mousavi, S. F. (2018). Investigation of neural network and fuzzy inference neural network and their optimization using meta-algorithms in river flood routing. *Natural Hazards*, 94, 1057-1080.
- Hirabayashi, Y., Mahendran, R., Koirala, S., Konoshima, L., Yamazaki, D., Watanabe, S., ... & Kanae, S. (2013). Global flood risk under climate change. *Nature climate change*, 3(9), 816-821.
- Karaboga, D. (2005). *An idea based on honey bee swarm for numerical optimization*. Technical Report TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- Karaboga, D. (2010). Artificial bee colony algorithm. *Scholarpedia*, 5(3), 6915.
- Karaboga, D., & Ozturk, C. (2010), A novel clustering approach: Artificial Bee Colony (ABC) algorithm, *Applied Soft Computing*, Elsevier, Netherlands, In Press.



- Katipoğlu, O. M., & Sarıgöl, M. (2023). Prediction of flood routing results in the Central Anatolian region of Türkiye with various machine learning models. *Stochastic Environmental Research and Risk Assessment*, 37(6), 2205-2224.
- Katipoğlu, O. M., Yeşilyurt, S. N., Dalkılıç, H. Y., & Akar, F. (2023). Application of empirical mode decomposition, particle swarm optimization, and support vector machine methods to predict stream flows. *Environmental Monitoring and Assessment*, 195(9), 1108.
- Kaya, Ç. M. (2017). *Akım gözlem istasyonu bulunmayan taşkın havzalarındaki değişimlerin taşkın riskine etkisinin belirlenmesi: Rize, Güneysu örneği*. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Kennedy, J., & Eberhart, R. (1995). *Particle swarm optimization*. Proceedings of ICNN'95 - International Conference on Neural Networks, vol.4. Perth, WA, Australia, pp. 1942-1948.
- Legg, S. (2021). IPCC, 2021: Climate change 2021-the physical science basis. *Interaction*, 49(4), 44-45.
- Liu, K., Li, Z., Yao, C., Chen, J., Zhang, K., & Saifullah, M. (2016). Coupling the k-nearest neighbor procedure with the Kalman filter for real-time updating of the hydraulic model in flood forecasting. *International Journal of Sediment Research*, 31(2), 149-158.
- Liu, M., Huang, Y., Li, Z., Tong, B., Liu, Z., Sun, M., ... & Zhang, H. (2020). The applicability of LSTM-KNN model for real-time flood forecasting in different climate zones in China. *Water*, 12(2), 440.
- Luo, X. H., Yang, Y., & Li, X., (2008). Solving TSP with shuffled frog-leaping algorithm. *Proceeding ISDA*, 3, 228–232.
- Luther, J., Hainsworth, A., Tang, X., Harding, J., Torres, J., & Fanchiotti, M. (2017). *World Meteorological Organization (WMO)—concerted international efforts for advancing multi-hazard early warning systems*. In *Advancing Culture of Living with Landslides: Volume 1 ISDR-ICL Sendai Partnerships 2015-2025* (pp. 129-141). Springer International Publishing.
- Malleswari, A., & Likitha, D. (2023). Identification of Forecasting in Flood rate using Machine learning classification algorithms. *Journal of Science, Computing and Engineering Research*, 6(11), 19-20.
- Mohammadi, B., Linh, N. T. T., Pham, Q. B., Ahmed, A. N., Vojteková, J., Guan, Y., ... & El-Shafie, A. (2020). Adaptive neuro-fuzzy inference system coupled with shuffled frog leaping algorithm for predicting river streamflow time series. *Hydrological Sciences Journal*, 65(10), 1738-1751.

- Moriasi, D. N., Gitau, M. W., Pai, N., & Daggupati, P. (2015). Hydrologic and water quality models: Performance measures and evaluation criteria. *Transactions of the ASABE*, 58(6), 1763-1785.
- Mosavi, A., Ozturk, P., & Chau, K. W. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10 (11), 1536.
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2004). A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291(1-2):52-66.
- Özsağlam, M. Y. ve Çunkaş M. (2008). Optimizasyon problemlerinin çözümü için parçaçık sürü optimizasyonu algoritması. *Politeknik Dergisi*, 11, 299-305.
- Öztuna, D., Elhan, A. H., ve Kurşun, N. (2008). Sağlık araştırmalarında kullanılan ilişki katsayıları. *Türkiye Klinikleri Journal of Medical Sciences*, 28(2), 160-165.
- Özturk, C., Hancer E., ve Karaboga, D. (2014). Küresel en iyi yapay ari koloni algoritması ile otomatik kümeleme. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 29(4).
- Pourghasemi, H. R., Razavi-Termeh, S. V., Kariminejad, N., Hong, H., & Chen, W. (2020). An assessment of metaheuristic approaches for flood assessment. *Journal of Hydrology*, 582, 124536.
- Sahana, M., Rehman, S., Sajjad, H., & Hong, H. (2020). Exploring effectiveness of frequency ratio and support vector machine models in storm surge flood susceptibility assessment: A study of Sundarban Biosphere Reserve, India. *Catena*, 189, 104450.
- Sahoo, A., Samantaray, S., & Paul, S. (2021). Efficacy of ANFIS-GOA technique in flood prediction: a case study of Mahanadi river basin in India. *H2Open Journal*, 4(1), 137-156.
- Sarıgöl, M., & Katipoğlu, O. M. (2023). Estimation of hourly flood hydrograph from daily flows using machine learning techniques in the Büyük Menderes River. *Natural Hazards*, 119(3), 1461-1477.
- Sivanandam, S. N., Deepa, S. N., Sivanandam, S. N., & Deepa, S. N. (2008). Genetic algorithm optimization problems. *Introduction to genetic algorithms*, 165-209.
- Smith, K., & Ward, R. (1998). *Floods: physical processes and human impacts*. xii + 382 pp.
- Şen, Z. (2004). *Yapay sinir ağları*. Su Vakfı.
- Tereshko, V., & Loengarov, A. (2005). Collective decision-making in honey bee foraging dynamics, *Computing and Information Systems*, 9(3), 1-7, University of the West of Scotland, UK.

- Van den Honert, R. C., & McAneney, J., (2011). The 2011 brisbane floods: causes. Impacts and Implications. *Water*, 3 (4), 1149–1173.
- Wetmore, F. (2020). *Floodplain Management*. In *Wetlands and Habitats* (pp. 3-9). CRC Press.
- Yang, X. S. (2009) Firefly algorithms for multimodal optimization. stochastic algorithms: foundations and applications, SAGA 2009. *Lect. Notes Comput. Sci.*, 5792:169–178
- Yang, X. S. (2010). Firefly algorithm, stochastic test functions and design optimisation. *International journal of bio-inspired computation*, 2(2), 78-84.
- Yaseen, Z. M., Ebtehaj, I., Bonakdari, H., Deo R. C., Mehr, A. D., Mohtar, W. H. M. W., Diop, L., El-shafie, A., & Singh, V. P. (2017). Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. *Journal of Hydrology*, 554:263–276.
- Zerouali, B., Santos, C. A. G., de Farias, C. A. S., Muniz, R. S., Difi, S., Abda, Z., ... & Elbeltagi, A. (2023). Artificial intelligent systems optimized by metaheuristic algorithms and teleconnection indices for rainfall modeling: The case of a humid region in the mediterranean basin. *Heliyon*, 9(4).
- Zou, J., Han, Y., & So, S. S. (2009). Overview of artificial neural networks. *Artificial neural networks: methods and applications*, 14-22.