



# Hibrit Gri Kurt Optimizasyonu ile Geçitli Tekrarlayan Birim Modeli Kullanılarak Zaman Serisi Tahmini

Hüseyin Çağan Kılınç<sup>1\*</sup>, Yunus Öztürk<sup>2</sup>

<sup>1\*</sup> İstanbul Esenyurt Üniversitesi, İstanbul, Türkiye, (ORCID: 0000-0003-1848-2856), [cgknlnc@gmail.com](mailto:cgknlnc@gmail.com)

<sup>2</sup> Kilis 7 Aralık Üniversitesi, Kilis, Türkiye (ORCID: 0000-0001-8032-9292), [ynsemre@kilis.edu.tr](mailto:ynsemre@kilis.edu.tr)

(İlk Geliş Tarihi 25 Ocak 2022 ve Kabul Tarihi 25 Mart 2022)

(DOI: 10.31590/ejosat.1062777)

**ATIF/REFERENCE:** Kılınç, H. Ç. & Öztürk, Y. (2022). Hibrit Gri Kurt Optimizasyonu ile Geçitli Tekrarlayan Birim Modeli Kullanılarak Zaman Serisi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 259-267.

## Öz

Sürdürülebilir su kaynakları sağlamak için akış tahmini gereklidir. Son zamanların popüler programları arasında yer alan makine öğrenmesi (ML), nehir akışlarını tahmin etmede giderek daha önemli hale gelmiştir. Makine öğrenmesi bu alanda uzun süredir kullanılmaktadır ancak, tahmin kalitesindeki iyileşme halen devam etmektedir. Bu çalışmada, Seyhan Havzası üzerinde yer alan Göksu Himmetli ve Körkün Hacılı akım ölçüm istasyonlarının performansı, GWO (Gri Kurt Algoritması) entegre edilmiş Kapalı Tekrarlayan Birim (GRU) ile oluşturulan hibrit model kıyas modeli olan (GRU) ve Liner Regresyon modeli ile karşılaştırılmıştır. Çalışmada Göksu Himmetli istasyonunun zaman aralığı 2002-2011 yılları arasındadır. Körkün istasyon verileri ise 2003-2012 yılları arasındadır. Veri setleri günlük akış değerlerinden oluşmaktadır. Modelin performansını doğrulamak için, verilerin ilk %80'i eğitim için, verilerin kalan %20'si ise test için kullanıldı. Gözlemlenen ve tahmin edilen akış verileri karşılaştırılarak hangi modelin daha iyi sonuç verdiği incelenmiştir. İstatistiksel değerlendirme kriterleri olarak RMSE, MAE, MAPE, R<sup>2</sup> ve STD kullanılmıştır. Tüm değerlendirme kriterleri incelendiğinde hibrit modelin performansının başarılı olduğu görülmüştür.

**Anahtar Kelimeler:** Derin öğrenme, gri kurt algoritması, nehir akımı, tekrarlayan kapalı birim, zaman serisi, hibrit model.

## Time Series Forecasting Using a Gated Recurrent Unit Model Hybridized with a Gray Wolf Optimization

### Abstract

Flow forecasting is necessary to ensure sustainable water resources. Machine learning (ML), which is among the popular programs of recent times, has become more and more important in predicting river flows. Machine learning has been used in this field for a long time, but the quality of prediction is still improving. In this study, the performance of Göksu Himmetli and Körkün Hacılı flow measurement stations located on the Seyhan Basin were compared with the hybrid model benchmark model (GRU) and Liner Regression model created with GWO (Grey Wolf Algorithm) integrated Gated Repetitive Unit (GRU). In the study, the timespan of Göksu Himmetli station is between 2002-2011. The timespan of the Körkün station is between 2003-2012. The data sets consist of daily flow values. To validate the performance of the model, the first 80% of the data was used for training and the remaining 20% of the data was used for testing. Observed and predicted flow data were compared and it was examined which model gave promise results. RMSE, MAE, MAPE, R<sup>2</sup> and STD were used as statistical evaluation criteria. When all evaluation criteria were examined, it was seen that the performance of the hybrid model was successful.

**Keywords:** Deep learning, gray wolf optimization, streamflow, gated recurrent unit.

\* Sorumlu Yazar: [cgknlnc@gmail.com](mailto:cgknlnc@gmail.com)

## 1. Giriş

Havzalardaki tahmin çalışmalarının modellenmesi gün geçtikçe daha farklı modellerle yapılmaktadır (Kuru ve Tezer, 2020). Havzalarda geleneksel modellerden farklı olarak maliyeti düşük ve hızlı sonuçlar elde edebilen yapay zekâ ile su kaynaklarının tahmini yapılabilmektedir. Veriye dayalı bu yöntem, fiziksel süreçleri dikkate almadan verimli alternatifler sunabilmekte, ancak bazı uygulamalarda havzaların durağan olmama durumu nedeniyle bu yöntemden sınırlı verim alınmaktadır (Tanyıldızı ve Çelik, 2020). Bu nedenle karşılaşılan problemlerin çözümü için kullanılan metoda bağlı olarak farklı optimizasyonlar havzalarda uygulanmaktadır. Modellerdeki verimliliği artırma amacıyla optimizasyon algoritmaları geliştirilmektedir (Garip vd., 2021). Son yıllarda bu optimizasyon algoritmalarına olan ilgi hızla artmaktadır. Optimizasyon, mühendislik durumunun matematiksel bir modelini oluşturmak için temel bileşenleri yakalamaya yardımcı olur ve modelleme sürecinde daha iyi kararları daha hızlı verme konusunda güven sağlar (Çelik vd., 2019). Bu algoritmalar arasında, zor problemlere daha az vakit harcayarak çözümler üretebilmesi, problemden bağımsız çalışabilmesi ve kolay uygulanabilirliği metasezgisel algoritmalara olan ilgiyi arttırmaktadır (Durgut ve Aydın, 2021). Meta-sezgisel terimi, problemin sınırını tanımlayan arama uzayında daha iyi sonuçlar elde etmek için diğer sezgisel yöntemlere rehberlik etmek için kullanılan üst düzey bir sezgisel terimi tanımlamak için önerilmiştir (Glover, 1986). Meta sezgisel algoritmalar; fiziksel temelli algoritmalar, evrimsel algoritmalar, sürü zekâsı algoritmaları, biyocoğrafik ilhamlı algoritmalar ve doğadan ilham alan diğer algoritmalar olarak sınıflandırılabilirler (Haznedar vd., 2021). Bu algoritmalar başlangıç çözümü veya çözümlerin oluşturduğu popülasyon ile arama sürecine başlar. Algoritmalar, arama sürecinde yeni çözümlerin daha iyiye gidemeyip sıkışıp kaldığı durumlarda (yerel minimuma takılma) arama uzayının farklı konumlarındaki çözümleri kullanmaya çalışır (Kılınc, 2021). Böylece tüm arama uzayı etkin bir biçimde kullanılmış olur (Deliloğlu vd., 2021). Algoritmanın amacı, etkin bir yol ile küresel en uygun çözüme ulaşabilmesidir. Çoğu metasezgisel algoritma her zaman en iyi çözümü bulmaz ve elde edilen sonuçlar yalnızca yaklaşık sonuçlar verir, kesinlik yoktur. Ancak metasezgisel yöntemin en iyi özelliği, çözmeye çalıştığı optimizasyon problemi hakkında herhangi bir özel bilgi gerektirmemesidir. Bu nedenle, genel bir çözüm modeli kavramını tanımlamak için kullanılabilir (Morales vd., 2020). Metasezgisel optimizasyon algoritmalarının etkinliği problem çözümünde büyük önem arz eder. Bir algoritmanın etkinliği çözüm uzayındaki iki temel hareket etme kabiliyetine bağlıdır. Bunlardan ilki arama süreçlerindeki yeni ve iyi çözümleri keşfedebilme (exploration) kabiliyetidir. İkincisi ise elde edilen bilgi ve çözümleri kullanarak (exploitation) geliştirebilme kabiliyetidir. Bu iki kabiliyet arasında denge kurulması gerekmektedir. Aksi takdirde algoritmadan iyi bir performans elde edilemeyecektir. Eğer arama/keşif fazı baskın olursa, algoritma var olan çözümleri geliştirmek için yeterli fırsat bulamayabilir ve yakınsama hızı oldukça yavaşlar. Eğer kullanma/geliştirme fazı baskın olursa, daha iyi çözümler sunabilecek bölgelere ulaşmakta zorlanılır ve algoritma yerel minimuma takılır (Avcu ve Ekmekçi, 2020). Son yıllarda araştırmalarda sıklıkla kullanılan birçok metasezgisel algoritma bulunmaktadır. Bu algoritmalar arasında, Genetik Algoritma, Karınca Kolonisi Optimizasyonu, Parçacık Sürüsü Optimizasyonu, Yapay Arı Kolonisi, Diferansiyel Gelişim Algoritması, Benzetim Tavlama, Yerçekimi

Arama Algoritması, Gaz Brownian Hareketi Optimizasyonu, Isı Transferi Arama, Elektromanyetik Alan Optimizasyonu, Ağırlıklı Süperpozisyon Çekimi, Orman Optimizasyonu Algoritması bulunmaktadır. Bu algoritmalar gerçek dünya optimizasyonu ile başa çıkmak için büyük bir potansiyele sahiptir (Çelik, 2019).

GWO, 2014 yılında Mirjalili tarafından önerilen doğadaki gri kurt temel avlanma prosedüründen ve sosyal hiyerarşisinden esinlenen optimizasyon algoritmasıdır (Mirjalili vd., 2014). Algoritma, gri kurtların çoğunlukla grup halinde yaşamaları ve avlanma stratejileri modellenerek, numerik optimizasyon problemlerine çözüm üretilmesi amacıyla geliştirilmiştir (Banerjee ve Mukhopadhyay, 2019). GWO algoritmasının en önemli dezavantajı yakınsama ve durgunluktur. GWO'da arama süreci her yinelemede en iyi üç kurt (alfa, beta, gama) tarafından motive edilir. Bu yüzden güçlü sömürü meydana gelir ancak arama çeşitliliği etkilenir. Ayrıca çözüm kalitesine bağlı olarak gerçekleştirilen çözüm seçim işlemi arama sürecinin sonlarına doğru rassal hale gelmektedir (Gendreau vd., 2016).

Prosedürün yoğunluğu, yakınsama ve durgunluk düşüldüğünde makine öğrenme modeli, GRU ile güçlendirilerek nehir akım tahminlerinin performans durumu gözlenebilir. GRU modelinin yerel optimum noktalarına takılmadan global sonuca ulaşabilme yeteneği model performansında değerlendirilir (Rodriguez, 2021). Ayrıca, bu modeller Tekrarlayan Sinir Ağı (RNN), Kapılı Tekrarlayan Birim (GRU) ve Çok Katmanlı Algılayıcı (MLP) ağı gibi modellere entegre edilerek hibrit bir model oluşturulabilir. Bu yeni yöntem, ileriye yönelik akış tahmini için geçmiş özellikleri yakalayan gecikmeli veri kümelerinin toplanması yoluyla geliştirilmiş bir ilişkiyi tanımlayabilir (Kaltah, 2013).

GRU, bellek ve kümeleme ile ilişkili makine öğrenme görevlerini gerçekleştirmek ve tekrarlayan sinir ağlarında sık görülen bir sorun olan gradyan sorununu çözmek adına sinir ağı giriş modelinin ayarlanmasına yardımcı olur. Uzaysal-zamansal analizi GRU ile birleştiren kısa vadeli bir nehir akışı tahmin modellerinde akış verileri üzerinde zaman korelasyon analizi ve mekansal korelasyon analizi yapıldığında optimal giriş zaman aralığı ve mekansal veri hacmini belirlemek için mekansal-zamansal öznitelik seçim algoritmaları da kullanılır. GRU modeli GWO algoritmasıyla güçlendirildiğinde verimin artması ve doğru yönetime ulaşılması hedeflenir (Kratzert, 2018). Son dönemlerde literatürdeki çözüm üretme odaklı çalışmalar için algoritmaların geliştirme arayışına devam edilmiştir. Gao vd. akış tahmini için GRU ve LSTM modellerini karşılaştırarak performanslarını incelemiştir. Bu modellerin tahmin doğruluğunun, artan zaman adımı ile arttığını ve stabilize olduğunu, GRU modelinin ise LSTM'ye kıyasla daha iyi performans sergilediği görülmüştür. GRU'nun, eğitimi için daha az zaman gerektirmesi sebebiyle kısa vadeli akış tahminlerinde kullanılabilirliği görülmüştür (Xiang ve Demir, 2020). Dai vd. (2018), Uyarlamalı Gürültü ile Komple Ampirik Mod Ayırıştırması ve Modifiye Gri Kurt Optimizasyon Algoritması ile Optimize Edilmiş Destek Vektör Makinesi (CEEMDAN-MGWO-SVM) modellerini analiz etmiştir. Birlikte uygulanan bu algoritmalar olumlu sonuçlar vermiştir. Hou vd. (2021), Bulut Sunucusu Yük Tahmini için GWO-BP Modelinin Optimizasyonu Üzerine Araştırma yapmıştır ve modelin tahmin doğruluğunu verimli bir şekilde desteklemiştir. Mirjalili vd. (2016) GWO ve Çok Amaçlı Gri Kurt Optimizasyon (MOGWO) modellerini tasarlamıştır. Turabieh (2016), GWO ve ANN hibritleşmesinin gücünü araştırmıştır. Kaveh ve Zakian geliştirilmiş bir GWO (IGWO) algoritması ile GWO algoritmasını geliştirmiştir. Her iki algoritmada da başarılı veriler

elde etmiştir. Emary vd. (2016), GWO'nun yeni bir ikili versiyonunu önererek sınıflandırma amaçları için en uygun özellik alt kümesini seçmek için kullanmıştır. Mohanty vd. (2015), kısmi gölgeleme koşulları altında GWO tekniğini kullanan yeni bir maksimum güç noktası izleme (MPPT) tasarımı uygulamıştır. El-Fergany ve Hasanien (2015), GWO ve DE algoritmalarını kullanarak tek ve çok amaçlı optimal modelleri ortaya koymuştur. Tikhamarine vd. (2019), Cezayir'deki Ain Bedra ve Fermatou adlı iki ölçüm istasyonundan aylık akış tahmininde destek vektörü regresyonu (SVR) doğruluğunu iyileştirmek için GWO adı verilen yeni bir meta-sezgisel algoritma uygulamıştır. GWO algoritması, hem tahmin doğruluğu hem de yakınsama açısından diğer algoritmalarından daha iyi performans göstermiştir. Zhao vd. (2021), Shangjingyou istasyonundaki Fenhe Nehri'nin üst kesimlerindeki Fenhe rezervuar çalışmasındaki aylık akış verileriyle GRU modeli tahmin çalışması yapmıştır GRU modeli kullanılarak geçmiş ve gelecek tahminleri arasındaki ilişki inceleyerek aşırı öğrenme makinesi (ELM) ve en küçük kareler destek vektör makinesi (LSSVM) kullanan paralel deneylerle karşılaştırmıştır. GRU modelinin tatmin edici performans sergilediği görülmüştür. Muhammed vd. (2019), LSTM ve GRU modellerinin akım tahmininde karşılaştırılmasını incelemiştir. Çalışmasını ABD'deki on havzanın ardışık 35 yıllık Model Parametre Tahmin Deneyi (MOPEX) veri setini kullanarak hibrit bir model oluşturmuştur. LSTM'nin daha iyi performans göstermesine rağmen, GRU modeli hidrolojik alanlarda verimli ve güvenilir bir yaklaşım olduğu sonucuna ulaşmıştır.

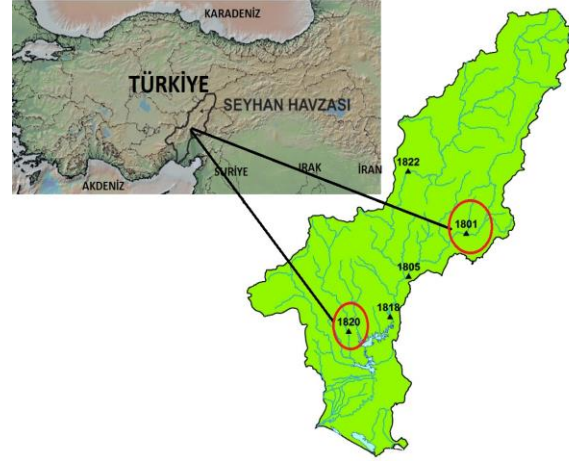
Önerilen çalışma, algoritma temelli tahmin modeli literatürüne katkı sağlamaktadır. Var olan literatüre katkısı, mevcut yöntemlerden daha hızlı ve verimli çözümler üretilmesi için tek bir model kullanmak yerine bir algoritma ile modelin güçlendirilerek uygulanmasıdır. Çalışmada üretilen sonuçlar güncel literatürde yer alan metasezgiseller diğer yöntemler dikkate alınarak karşılaştırılmıştır (Kılınc ve Haznedar, 2022). Önerilen yöntemin literatürdeki yöntemler ile karşılaştırmalarının istatistiksel olarak anlamlılığı da ortaya konulmuştur. Seyhan havzası üzerindeki Zamanti Nehri'nde günlük zaman serileri Akım Gözlem İstasyonu'ndan (AGİ) toplanarak GWO algoritması ile GWO-GRU modeli karşılaştırmalı analiz ile entegre edilerek istatistiksel analizin, akış tahmininde uygulanabilirliğini araştırılmıştır.

## 2. Materyal ve Metot

### 2.1. Çalışma Bölgesi

Seyhan Havzası Çukurova'dan Kuzeye doğru kama biçiminde uzanmakta olup yukarı bölümü İç Anadolu, orta ve aşağı bölümü Akdeniz Bölgesi'nde yer almaktadır. Şekil 1'de konumu ve topografyası verilen Seyhan Havzası 36° 30' ile 39° 15' kuzey enlemleri ve 34° 45' ile 37° 00' doğu boylamları arasında yer almaktadır. Havza, Seyhan Nehri ile Göksu ve Zamanti nehrinin kollarının su toplama alanlarını içinde bulundurmaktadır. 22042 km<sup>2</sup> 'lik yüzölçümüne sahiptir. Türkiye'nin Akdeniz'e dökülen nehirlerinin en büyüklerinden birisidir. Uzunluğu Zamanti ve Göksu Nehirleri başta olmak üzere tüm kollarıyla birlikte 560 km'dir. Seyhan havzası iklim değişikliği dolayısı ile kuraklıktan önemli derecede etkilenen havzaların başında gelmektedir. Yüzey su kaynakları, kar depolaması ve yeraltı suyu potansiyelinde %30'a varan önemli azalışların gerçekleşeceği öngörülmektedir (Ekmekçi, 2008). Akdeniz Bölgesi'nde Akdeniz iklimi, İç Anadolu Bölgesi'nde karasal iklim özelliklerine

rastlanır. Akdeniz ikliminde kışlar ılık ve bol yağmurlu, yazlar sıcak ve kuraktır; karasal iklimde ise kışlar soğuk ve genellikle kar yağışlı, yazlar sıcak ve kuraktır.



Şekil 1. Seyhan havzası ve çalışma istasyonlarının konumu

### 2.2. Veri Kümeleri ve Ön İşleme

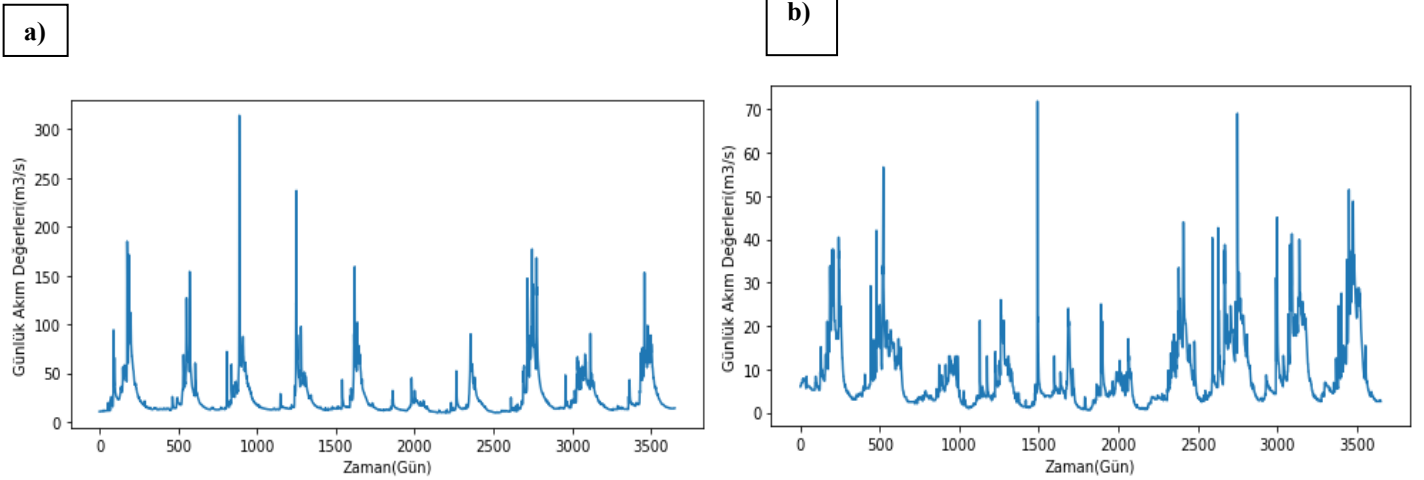
Bu çalışmada, uzun vadeli 10 yıllık akış verilerini toplamak için günlük akış ölçüm istasyonları (AGİ'ler) kullanılmıştır. Şekil 2'de gösterilen Seyhan Nehir havzasının çeşitli kollarında bulunma koşullarına göre seçilmiştir.



Şekil 2. Seyhan Nehir havzasındaki AGİ çalışma alanları

Körkün AGİ (E18A020), 37° 17' 44" kuzey enlemi, 36° 09' 17" doğu boylamı koordinatlarında yer alarak oluşturduğu vadi ile özel bir coğrafik alanın oluşmasına neden olmaktadır. Körkün Çayı ve Çakıt Suyu ile bunlara katılan muhtelif dereler, derin vadiler ve yer yer kanyonlar meydana getirmektedir (Paksoy ve Savran, 2011). Körkün alt havzasındaki tek istasyon olan 1820 nolu AGİ'nin akım ve sediment verilerinin düzeltilmeden kullanılabileceği belirlenmiştir. Göksu Himmetli AGİ (E18A001), Türkiye'nin güneyinde bulunan Seyhan Havzası içerisinde 37° 51' 59" kuzey enlemi, 36° 03' 32" doğu boylamı koordinatlarında yer almaktadır. Toplam drenaj alanı yaklaşık olarak 2596,8 km<sup>2</sup> ve ortalama yüksekliği 665 metredir. Körkün ve Göksu-Himmetli sınırları ile Elektrik İşleri Etüt İdaresi (EİEİ)'ne ait 1820 ve 1801 nolu akım gözlem istasyonlarının konumu Şekil 2'de verilmiştir. Seyhan Nehri üzerindeki istasyonların konumları coğrafi koordinatlar ile Tablo 1'de gösterilmektedir. Şekil 3'te görüldüğü gibi gözlem döneminde, iki nehir istasyonuna ait minimum ve maksimum akış hızları sırasıyla 1.72 m<sup>3</sup>/s ve 314 m<sup>3</sup>/s'tür





Şekil 3. (a) Göksu Himmetli ve (b) Körkün Hacılı istasyonları için günlük verileri

Tablo 1. Seyhan Nehri boyunca yer alan AGİ'lere ilişkin genel bilgiler

AGİ	Nehir- AGİ	Koordinatlar		Yağış Alanı (km <sup>2</sup> )	Yükseklik(m)	Gözlem(yıl)
		Doğu	Kuzey			
		(° ‘ ‘‘)	(° ‘ ‘‘)			
1801	Göksu Himmetli	36 3 32	37 51 59	2596	665	2002–2011
1820	Körkün Hacılı	35 9 17	37 17 44	1440	167	2003–2012

Oluşturulan hibrit modelde Python programlama dilinin sürümlerinden biri olan Python 3.9, yeni bileşenler ve optimizasyon ile kullanılmıştır. Çalışmada eğitim süreçleri ve tahmin süreçleri için Keras kütüphanesi ve Deep kütüphanesinden yararlanılmıştır. Günlük nehir akış verilerinin analiz edildiği hibrit modelde GWO, eğitim sürecinde GWO-GRU için 100 periyot ve performans analizi için 8 parti büyüklüğünden oluşuyordu. Birçok iyileştirici test aşamasında değerlendirilmiş ve içlerinden optimum koşulu sağlayan ADAM çalışmada kullanılmıştır. Kayıp fonksiyonu olarak ise MSE kullanılmıştır. Veri seti, her gün için doğrudan akış değerlerine bağlanmıştır ve akış değerleri, EİEİ'den (Elektrik İşleri Etüt İdaresi Genel Müdürlüğü) alınan günlük akımlarından oluşturulmuştur. Akış gözlem istasyonlarından toplanan orijinal veriler, her istasyon için 10 yıllık (3651 gün) operasyon içeriyordu. Verilerin %80'i eğitim seti, kalan %20'si ise test seti olarak elde edilmiştir. Veriler, model içindeki göstergeleri incelemek ve karşılaştırmak için eğitilmiş ve test verileri için hibrit model performansı analiz edilmiştir. Ayrıca hibrit model, bir yoğun katman ve iki gizli katmandan oluşmaktadır.

Bu çalışmada, gelecekteki nehir akışlarını tahmin etmek ve önerilen modelleri değerlendirmek için istasyonların geçmiş akış verileri analiz edilmiştir. Bu nedenle, doğru bir tahmin elde etmek için uzun süredir bozulmayan akış verileri çalışmaya dahil edilmiştir. Alınan akış verilerinin eksiksiz olarak kaydedilmesi ve kesilmemesi önemlidir. Bu aşamada, akış verilerinde kısa vadeli kesintiler kabul edilebilir. Ancak havza bazında yapılan birçok çalışmada, kurumlardan meteorolojik veriler (yağış, kar, sıcaklık, buharlaşma vb.) ve hidrolojik veriler (akış gözlemi veya akış ölçümü) alındığında geçmiş tarihlere ait veriler eksik veya

iklimsel zorluklar, ulaşım güçlükleri, ölçüm cihazı ile ilgili sorunlar vb. gibi çeşitli nedenlerle kesintiye uğramaktadır. Olumsuz iklim koşulları veya çeşitli nedenlerle içeri akış verilerinde boşlukların oluşması, etkin planlama, tasarım ve işletme açısından önemli sorunlar oluşturmaktadır. Seyhan Nehri'nin çeşitli iklim bölgelerini ve hidrolojik koşullarını gösteren GRU-GWO modelini doğrulamak için Körkün ve Göksu Himmetli olmak üzere iki hidroloji istasyonu seçilmiştir. Bu çalışma için veri setlerini bir araya getirmek için E18A20 ve E18A01 istasyonları kullanılmıştır. Çalışmadaki Göksu Himmetli ve Körkün Hacılı istasyonlarının zaman aralığı sırasıyla 2010-2019 yılları arasındadır. Samandağ istasyon verileri 2002-2011 ve 2003-2012 yılları arasındadır. Veri setleri günlük akış değerlerinden oluşmaktadır.

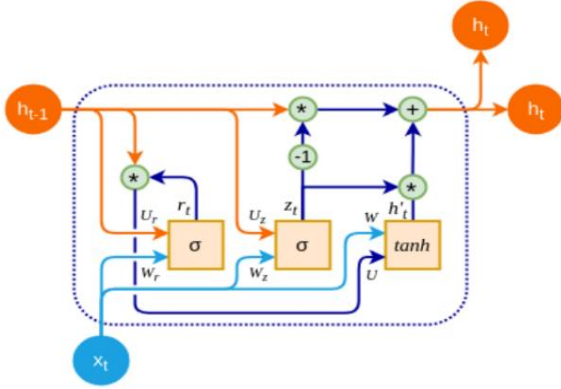
## 2.3 Metot

Çalışmanın bu bölümünde, tekrarlayan sinir ağlarının güçlü varyasyonlarından biri olan GRU ve oluşturulacak hibrit modelde iyileştirici olacak GKA kısaca tartışılmıştır.

### 2.3.1. Kapalı Tekrarlayan Birim

Kapalı Tekrarlayan Birim (GRU) ilk olarak Cho vd. (2014) tarafından geliştirilmiş ve tekrarlayan sinir ağının (RNN) en umut verici algoritmalarından biri haline gelmiştir. GRU'nun ana görevi, standart bir tekrarlayan sinir ağında meydana gelen kaybolan gradyan problemiyle ilgilenmektir. GRU, LSTM'nin bir varyasyonu olarak kabul edilir, çünkü bu algoritmaların her ikisi de bazı durumlarda mükemmel sonuçlar sağlayabilir. GRU'nun üç sigmoid katmanı vardır: güncelleme kapısı, sıfırlama kapısı ve

tanh katmanı. GRU, kaybolan gradyan sorunu için güncelleme geçidini ve sıfırlama kapısını kullanır ve ayrıca çıktının ne olacağına karar verir (Islam vd., 2020).



Şekil 4. GRU modeli

Veri işleme, ‘güncelleme kapısı’ ile başlar. İlk olarak, t zaman adımında güncelleme kapısı  $z_t$ 'nin hesaplanması denklem (1) ile kullanılarak yapılır.

$$z_t = \sigma(w_z \cdot [h(t-1), x_t]) \quad (1)$$

Denklem (1)'de ifade edilen  $x_t$  ve  $h(t-1)$  kendi ağırlığı ile çarpılır ve fonksiyona eklenir. Ardından sonucu 0 ile 1 arasında dönüştürmek için bir sigmoid aktivasyonu kullanılır. Güncelleme kapısı, modelin geçmiş bilgilerin ne kadarının gelecek zaman adımına aktarılması gerektiğinin belirlenmesine yardımcı olur.

Denklem (2)'de belirtilen ‘sıfırlama kapısı’  $r_t$ 'nin hesaplanması, zaman adımında t kullanılarak hesaplanır.

$$r_t = \sigma(w_r \cdot [h(t-1), x_t]) \quad (2)$$

Denklem (2)'de ifade edilen hesaplamalar,  $x_t$  ve  $h(t-1)$ 'in kendi değeriyle çarpılmasıyla başlar. Daha sonra çıktıyı 0 ile 1 değeri arasında dönüştürmek için bir sigmoid aktivasyonu kullanılır. Sıfırlama kapısı, modelin geçmiş bilgilerin ne kadarının unutulması gerektiğini belirlemesine yardımcı olur.

Bir sonraki adımı ‘geçerli bellek içeriği’ oluşturmaktadır. Bu bölüm, sıfırlama kapısı ile ilgilidir. Bu adım, sıfırlama kapısını kullanacak ve geçmişten ilgili bilgileri depolayacak yeni bellek içeriğini ifade eder. Matematiksel Denklemi (3) aşağıdaki gibidir:

$$h_t = \tanh(w \cdot [r_t \cdot h(t-1), x_t]) \quad (3)$$

Daha sonra çoklu sıfırlama kapısı  $r_t$  ve önceki çıkış  $h_{t-1}$ 'e uygulama yapılır. Bu uygulama sadece ilgili geçmiş bilgilerin iletilmesine izin verir. Daha sonra hesaplanan sonuçların ikisi birlikte toplanır ve bir tanh fonksiyonu uygulanır.

Son olarak, GRU, bilgileri tutan  $h_t$  vektörünü hesaplamalıdır. Denklem (4)'te formülasyonu ifade edilen güncelleme kapısı  $z_t$  bunda önemli bir rol oynar.

$$h_t = (1 - z_t) \cdot h(t-1) + (z_t \cdot h_t) \quad (4)$$

Denklem (4)'teki hesaplamalarda,  $z_t$  vektörü 0'a yakınsa, büyük bir kısmı tahmin için alakasız olduğu için mevcut içerik yok sayılacaktır. Aynı zamanda bu zaman adımında  $z_t$  0'a yakın olacağı için  $1 - z_t$  1'e yakın olacak ve geçmiş bilgilerin çoğunun

saklanması izin verecektir. 1'e yakın olacak ve geçmiş bilgilerin çoğunun saklanması izin verecek

### 2.3.2 Gri Kurt Algoritması

GWO, gri kurtların hiyerarşi liderliğinden ve avlanma davranışlarından ilham almıştır. Bu algoritma, küresel optimizasyon problemlerini çözmek için uyarlanmış, avların zulmü, etrafını sarması ve saldırmasına dayanan kurt avının şeklini taklit eder (Mirjalili vd., 2014). GWO, alternatif bir sürü zekası optimizasyonu olarak sınıflandırılır ve basitlik, esneklik ve türetme gerektirmeyen mekanizmalar gibi çeşitli avantajlar sunabilir. Ayrıca ayarlanması gereken daha az kontrol parametresine sahiptir ve hızlı bir yakınsamaya sahiptir. Bazı yazarlar, GWO'nun diğer geleneksel optimizasyon tekniklerine kıyasla yerel optimumdan kaçınmak için daha iyi sayısal özelliklere sahip olduğu sonucuna varmış ve oldukça doğrusal olmayan, çok değişkenli ve çok modlu optimizasyon problemlerini çözmek için uygun bir stokastik yöntem olarak önerilmiştir (Kadalia vd., 2017).

GKA, doğadaki gri kurtların sosyal liderlik hiyerarşisini ve avlanma davranışlarını simüle eder. Sosyal liderlik hiyerarşisi, alfa ( $\alpha$ ), beta ( $\beta$ ), delta ( $\delta$ ) ve omega ( $\omega$ ) olmak üzere dört ana kurt seviyesinden oluşur. Hiyerarşinin ilk seviyesi alfadır, burada alfa kurt baskın kurt ve sürünün lideridir. Alfa kurt çoğunlukla uyumak, uyanmak ve avlanmakla ilgili kararlar vermekle ilgilenir. Gri kurtlar hiyerarşisinin ikinci seviyesi, beta kurtlarının karar verme sürecinde alfa kurtu güçlendirmek ve yardımcı olmak için danışmanlar olarak hareket ettiği ve ona geri bildirim sağladığı betadır. Delta kurtları, alfa ve beta kurtlarının dikte edilen emirlerine itaat eder ve omega kurtlarına hükmederler. Nöbetçileri, avcıları, izcileri ve bakıcıları kapsar. Omega kurtları hiyerarşideki en düşük baskın seviyedir ve diğer baskın alfa, beta ve delta kurtlarına boyun eğerler. Omega kurtlar yemelerine izin verilen son birey görevi görürler. GWO algoritmasının da omega kurtu kullanılmamıştır. Gri kurtların avlanma mekanizması, aşağıda verilen denklemler kullanılarak modellenmiştir. Gri kurt avlama sürecinin ana aşamaları, avı takip etme, kuşatma ve saldırıyı içerir (İnaç, 2021).

$$D^{\rightarrow} \alpha = |C^{\rightarrow} \alpha \cdot X^{\rightarrow} \alpha - X^{\rightarrow} i| \quad (5)$$

$$D^{\rightarrow} \beta = |C^{\rightarrow} \beta \cdot X^{\rightarrow} \beta - X^{\rightarrow} i| \quad (6)$$

$$D^{\rightarrow} \delta = |C^{\rightarrow} \delta \cdot X^{\rightarrow} \delta - X^{\rightarrow} i| \quad (7)$$

$$U^{\rightarrow} \alpha = X^{\rightarrow} \alpha - A^{\rightarrow} \alpha D^{\rightarrow} \alpha \quad (8)$$

$$U^{\rightarrow} \beta = X^{\rightarrow} \beta - A^{\rightarrow} \beta D^{\rightarrow} \beta \quad (9)$$

$$U^{\rightarrow} \delta = X^{\rightarrow} \delta - A^{\rightarrow} \delta D^{\rightarrow} \delta \quad (10)$$

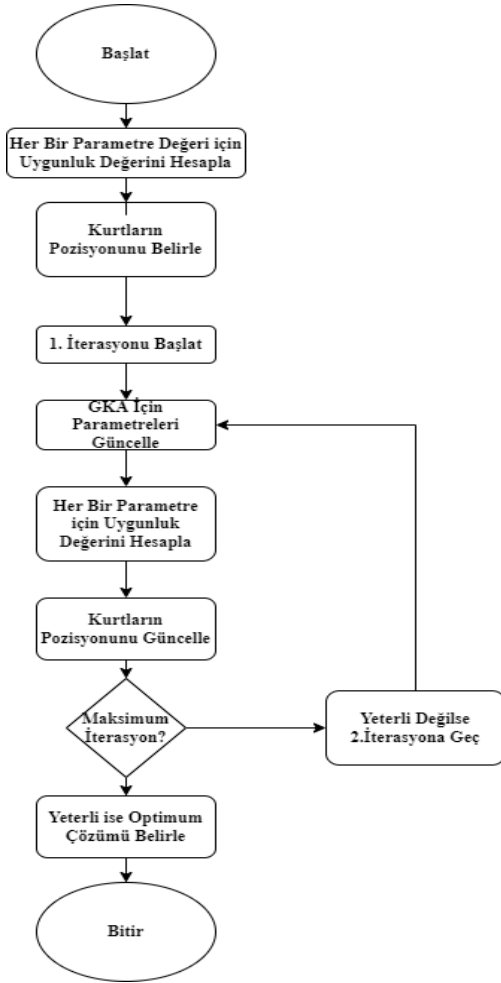
$$X^{\rightarrow} i = (U^{\rightarrow} \alpha + U^{\rightarrow} \beta + U^{\rightarrow} \delta) / 3 \quad (11)$$

Bura da  $D^{\rightarrow} \alpha$ ,  $D^{\rightarrow} \beta$ ,  $D^{\rightarrow} \delta$ , alfa, beta ve delta gri kurtları ile av arasındaki mesafe vektörünü göstermektedir.  $X^{\rightarrow} \alpha$ ,  $X^{\rightarrow} \beta$ ,  $X^{\rightarrow} \delta$ , alfa, beta ve delta gri kurtları için avın konum vektörünü temsil etmektedir.  $X^{\rightarrow} i$  iterasyondaki konum vektörünü,  $U^{\rightarrow} \alpha$ ,  $U^{\rightarrow} \beta$ ,  $U^{\rightarrow} \delta$  alfa, beta ve delta gri kurtları için deneme vektörünü göstermektedir.  $C^{\rightarrow} \alpha$ ,  $C^{\rightarrow} \beta$ ,  $C^{\rightarrow} \delta$ ,  $A^{\rightarrow} \alpha$ ,  $A^{\rightarrow} \beta$ ,  $A^{\rightarrow} \delta$  ise alfa, beta ve delta gri kurtları için katsayı vektörlerini ifade etmektedir. Bu katsayı vektörleri aşağı da verilen denklemlere göre bulunmaktadır (Mirjalili vd., 2014).

$$A^{\rightarrow} i = 2a^{\rightarrow} r^{\rightarrow} i - a^{\rightarrow}, i = \alpha, \beta, \delta \quad (12)$$

$$C^{\rightarrow} i = 2r^{\rightarrow} i^2, i = \alpha, \beta, \delta \quad (13)$$

Burada  $a^T$  2'den 0'a doğrusal olarak azaltılmış bir vektörü ifade eder.  $r^T i 1$  ve  $r^T i 2$  [0 1] aralığının da seçilen rasgele vektörü temsil etmektedir. Şekil 5'te gri kurt algoritmasının akış diyagramı gösterilmiştir.




Şekil 5. Gri Kurt Algoritması akış şeması

### 2.3.3 Önerilen GWO-GRU Hibrit Modeli

GRU sinir ağında, parametrelerin başlangıç değerleri ağın performansını kritik olarak etkiler. Bu çalışmada, GRU ağıının önemli bir parametresi olan pencere büyüklüğünü optimize etmek için GWO algoritması kullanılmıştır. Önerilen model oluşturulurken öncelikli olarak standart bir GRU ağı tahmin modeli gerçekleştirilmiştir. Test sonuçları, rastgele parametrelerle yirmi kez eğitim verilerek karşılaştırılmış ve en umut verici sonuçlar, kıyaslama modeli olarak belirlenmiştir. Hemen ardından, GWO algoritmasının optimal sonuçları belirlenmiş, daha sonra bir parametre olarak GRU ağına eklenmiş ve GRU modeli yeniden eğitilmiş ve sonuçlar kıyaslama modeli ile karşılaştırılmıştır. Ayrıca, sonuçların doğruluğunu doğrulamak için doğrusal regresyon modeli uygulanmıştır ve sonuçlar her iki model ile karşılaştırılmıştır.

Öncelikle eğitim için veriler düzenlenmiştir. Bu nedenle veri seti süreç için %80 ve %20 oranında eğitim ve test veri setlerine bölünmüştür. Şekil 6'da akış şeması verilen hibrit modelde her iki veri setindeki parametreleri optimize etmek için çeviri ve normalizasyon teknikleri uygulanmıştır. Daha sonra eğitim için

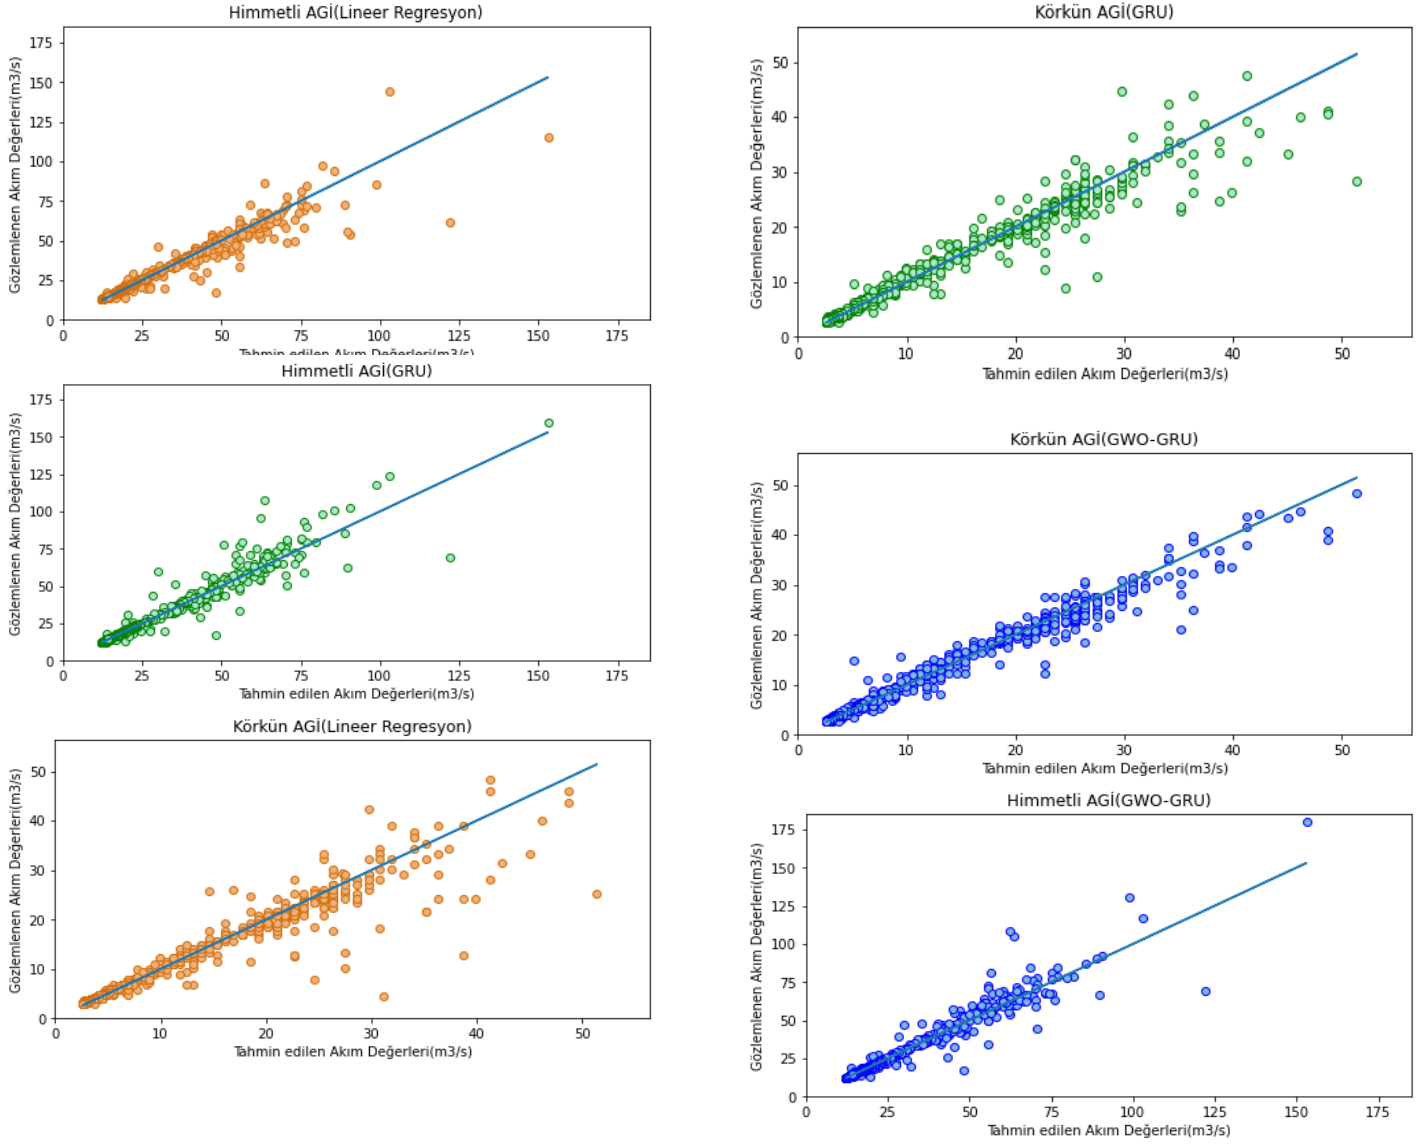
uygun bir versiyona dönüştürülmüştür. Daha sonra GRU ağı ilk olarak 1 dense 1 gizli olmak üzere toplam 2 katman ile eğitilmiştir. Ancak daha tatmin edici bir performans elde etmek için 1 dense ve 2 gizli katmanda gözlenlenmiştir. Bu durum ağı yapısı için daha uygun kabul edilmiş ve sonraki işlemlerde 3 gizli katman yapısı kullanılmıştır. Gizli katmanlardaki nöron sayısı değiştirilerek ağı 20 kez çalıştırılmış ve 3 katmanlı ağıın en kabul edilebilir sonuçları referans olarak kabul edilmiştir. GWO parametreleri ve GRU parametreleri arasındaki eşleme daha sonra bu yapıyla birleştirilmiştir.



Şekil 6. Hibrit GWO-GRU modeli akış şeması

## 3. Araştırma Sonuçları ve Tartışma

Hibrit ve lineer regresyon modelleri, çalışmanın bu bölümünde kıyaslama modeli ile karşılaştırılmıştır. Veriler arasındaki korelasyonu incelemek için doğrusal regresyon modeli kullanılmıştır. Her bir akış ölçüm istasyonunun performans sonuçları Şekil 7'de gösterilmiştir. Tahmin sonuçlarını incelemek ve karşılaştırmak için yaygın istatistiksel dağılım ölçüleri arasında yer alan beş değerlendirme göstergesi kullanılmıştır. Bunlar RMSE, MAE, MAPE, Tablo 2'de belirtilen Standart Sapma (STD. DEV.),  $R^2$ 'dir. İstasyonların istatistiksel ölçüm sonuçları Tablo 2'de açıklanmıştır. Modelin performansı 2 istasyon için yaklaşık 730 test verisinden oluşmaktadır. Çalışmada uygulanan diğer modellere karşı hibrit modelin performansının Tablo 2'de sunulan ölçüm kriterleri incelendiğinde oldukça başarılı olduğu gözlemlenmiştir. Ayrıca, istatistiksel ölçümler hibrit modelin performansını destekledi.



Şekil 7. Körkün ve Himmetli istasyonlarına ait kıyaslama (GRU), hibrit (GWO-GRU) ve Liner Regresyon modelleri

Tablo 2. İstatiksel değerlendirme kriterleri

İstasyon	Model	RMSE	MAE	MAPE	STD.	R <sup>2</sup>
Göksu Himmetli	GWO-GRU	3.077	0.037	3.792	0.074	0.973
	GRU	4.752	0.043	4.307	0.108	0.942
	Liner Regresyon	5.645	0.065	6.523	0.124	0.908
Körkün Hacılı	GWO-GRU	1.682	0.069	6.970	0.111	0.971
	GRU	2.340	0.082	8.286	0.144	0.932
	Liner Regresyon	2.918	0.096	9.682	0.283	0.910



## 4. Sonuç

Bu çalışmada, akış verilerini tahmin etmek için GWO'nun GRU'ya entegre edildiği bir hibrit yöntem önerilmiştir. Elde edilen sonuçlar, önerilen GWO-GRU yaklaşımı ile akış verilerinin tahmin hatalarının kıyaslama ve lineer regresyon modellerine kıyasla oldukça düşük olduğunu göstermektedir. Ayrıca  $R^2$  değerlerine bakıldığında, önerilen model için tahmin doğruluğunun aynı oranda oldukça yüksek olduğu ve iyileştirme etkisinin anlamlı olduğu görülmektedir. Ayrıca bu çalışmada kullanılan GWO algoritmasının parametreleri de ileride yapılacak çalışmalar için geliştirilmesi gereken faktörlerden bazılarıdır. Bu nedenle GWO algoritması ile yapılacak yeni hibrit modellerde başlangıç parametreleri ve pencere boyutu gibi modeli etkileyecek faktörler çalışılarak yeni bir algoritma sunulacaktır. GWO algoritmasını farklı optimizasyon yöntemleriyle birleştirmek ve GWO algoritmasını yeni algoritmalarla karşılaştırmak gelecekteki araştırmalara fayda sağlayacaktır. Ayrıca metasezgisel teknikler kullanılarak oluşturulacak yeni hibrit modeller de ileride yapılacak çalışmalarda faydalı olacaktır.

## Kaynakça

- Kuru, A. & Tezer, A. (2019). İçme suyu havzası koruma sınırlarının belirlenmesine yeni yöntem önerisi: Kırklareli barajı içme suyu havzası örneği. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 35 (1), 519-536. <https://doi.org/10.17341/gazimmfd.486855>
- Tanyıldız, E., Çelik, A. (2020). Güncel İkili Optimizasyon Algoritmalarının Kısıtsız Kıyaslama Fonksiyonlarındaki Performans Karşılaştırmaları, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 32(2), 369-380. <https://doi.org/10.35234/fumbd.770492>
- Deliloğlu, R. A. S., Pehlivanlı, A.Ç. (2021). Hibrit Açıklanabilir Yapay Zekâ Tasarımı ve LIME Uygulaması. Avrupa Bilim ve Teknoloji Dergisi, (27), 228-236. <https://doi.org/10.31590/ejosat.959030>
- Kılınç, H. Ç. (2021). Uzun-Kısa Süreli Bellek Ağlarının Nehir Akım Tahmininde Farklı Optimizasyonlarla Karşılaştırılması ve Tekil Spektrum Analizinin Etkisi. Avrupa Bilim ve Teknoloji Dergisi, (23), 248-253. <https://doi.org/10.31590/ejosat.864496>
- Garip, Z., Çimen, M. E., Boz, A. F. (2021). Fotovoltaik Modellerin Parametre Çıkarımı İçin Geliştirilmiş Bir Kaotik Tabanlı Balina Optimizasyon Algoritması, Politeknik Dergisi, 1-1. <https://doi.org/10.2339/politeknik.878934>
- Çelik, Y., Yıldız, İ., Karadeniz, A. T. (2019). Son Üç Yılda Geliştirilen Metasezgisel Algoritmalar Hakkında Kısa Bir İnceleme, Avrupa Bilim ve Teknoloji Dergisi, 463-477. <https://doi.org/10.31590/ejosat.638431>
- Durgut, R., Aydın, M. (2021). Çok boyutlu sırt çantası problemi için adaptif ikili yapay arı kolonisi algoritması (AİYAK), Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 36(4), 2333-2348. <https://doi.org/10.17341/gazimmfd.804858>
- Glover, F. (1986). Future paths for integer programming and links to artificial intelligence. Computers & operations research, 13(5), 533-549. [https://doi.org/10.1016/0305-0548\(86\)90048-1](https://doi.org/10.1016/0305-0548(86)90048-1)
- Haznedar, B., Arslan, M.T., Kalinli, A (2021). Optimizing ANFIS using simulated annealing algorithm for classification of microarray gene expression cancer data. Med Biol Eng Comput 59, 497–509.

<https://doi.org/10.1007/s11517-021-02331-z>

- Morales-Castañeda, B., Zaldivar, D., Cuevas, E., Fausto, F., Rodríguez, A. (2020). A better balance in metaheuristic algorithms: Does it exist? Swarm and Evolutionary Computation, 54, 100671. <https://doi.org/10.1016/j.swevo.2020.100671>
- Avuçlu, D., Ekmekçi, D. (2020). Geleceğin Dünyasında Bilimsel ve Mesleki Çalışmalar, Bilgisayar Mühendisliği / I, ISBN 978-625-7983-95-2.
- Çelik, Y. (2013). Optimizasyon Problemlerinde Bal Arılarının Evlilik Optimizasyonu Algoritmasının Performansının Geliştirilmesi. Doktora Tezi. Konya, Türkiye: Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Mirjalili, S., Mirjalili, SM., Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Banerjee, N., Mukhopadhyay, S. (2019). HC-PSOGWO: hybrid crossover oriented PSO and GWO based co-evolution for global optimization. In 2019 IEEE region 10 symposium (TENSYP) (pp. 162-167). IEEE. <https://doi.org/10.1109/TENSYP46218.2019.8971231>
- Gendreau, M., Iori, M., Laporte, G., Martello, S. (2006). A tabu search algorithm for a routing and container loading problem. *Transportation Science*, 40(3), 342-350. <https://doi.org/10.1287/trsc.1050.0145>
- Rodríguez, A., Camarena, O., Cuevas, E., Aranguren, I., Valdivia-G, A., Morales-Castañeda, B., Pérez-Cisneros, M. (2021). Group-based synchronous-asynchronous Grey Wolf Optimizer. *Applied Mathematical Modelling*, 93, 226-243. <https://doi.org/10.1016/j.apm.2020.12.016>
- Kalteh, AM. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. *Comput Geosci* 54:1–8. <https://doi.org/10.1016/j.cageo.2012.11.015>
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., Herrnegger, M. (2018). Rainfall–runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, 22(11), 6005-6022. <https://doi.org/10.5194/hess-22-6005-2018>
- Xiang, Z., Demir, I. (2020). Distributed long-term hourly streamflow predictions using deep learning—A case study for State of Iowa. *Environmental Modelling & Software*, 131, 104761. <https://doi.org/10.1016/j.envsoft.2020.104761>
- Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188. <https://doi.org/10.1016/j.jhydrol.2020.125188>
- Dai, S., Niu, D., Li, Y. (2018). Daily peak load forecasting based on complete ensemble empirical mode decomposition with adaptive noise and support vector machine optimized by modified grey wolf optimization algorithm. *Energies*, 11(1), 163. <https://doi.org/10.3390/en11010163>
- Hou, K., Guo, M., Li, X., Zhang H. (2017). Research on Optimization of GWO-BP Model for Cloud Server Load Prediction. *IEEE Access*, 53, 1-9. <https://doi.org/10.1109/ACCESS.2021.3132052>
- Mirjalili, S., Saremi, S., Mirjalili, SM., Coelho, LDS (2016). Multi-objective grey wolf optimizer: a novel algorithm for multi-criterion optimization. *Expert Syst Appl* 47(Supplement C):106–119. <https://doi.org/10.1016/j.eswa.2015.10.039>



- Turabieh, H. (2016). A hybrid ann-gwo algorithm for prediction of heart disease. *American Journal of Operations Research*, 6(2),136-146.  
<http://dx.doi.org/10.4236/ajor.2016.62016>
- Kaveh, A., Zakian, P. (2018). Improved GWO algorithm for optimal design of truss structures. *Engineering with Computers*, 34(4), 685-707. <https://doi.org/10.1007/s00366-017-0567-1>
- Emary E, Zawbaa HM, Hassanien AE (2016). Binary grey wolf optimization approaches for feature selection. *Neurocomputing* 172:371–381.  
<https://doi.org/10.1016/j.neucom.2015.06.083>
- Mohanty S, Subudhi B, Ray PK. (2015). A new mppt design using grey wolf optimization technique for photovoltaic system under partial shading conditions. *IEEE Trans Sustain Energy* 7(1):181–188. <https://doi.org/10.1109/TSTE.2015.2482120>
- El-Fergany AA, Hassanien HM. (2015) Single and multi-objective optimal power flow using grey wolf optimizer and differential evolution algorithms. *Electric Power Components Syst* 43(13):1548–1559.  
<https://doi.org/10.1080/15325008.2015.1041625>
- Tikhmarine, Y., Souag-Gamane, D., Kisi, O. (2019). A new intelligent method for monthly streamflow prediction: hybrid wavelet support vector regression based on grey wolf optimizer (WSVR–GWO). *Arabian Journal of Geosciences*, 12(17), 1-20. <https://doi.org/10.1016/j.jhydrol.2010.06.033>
- Zhao, X., Lv, H., Lv, S., Sang, Y., Wei, Y., Zhu, X. (2021). Enhancing robustness of monthly streamflow forecasting model using gated recurrent unit based on improved grey wolf optimizer. *Journal of Hydrology*, 601, 126607.  
<https://doi.org/10.1016/j.jhydrol.2021.126607>
- Muhammad, A. U., Li, X., Feng, J. (2019). Using LSTM GRU and hybrid models for streamflow forecasting. In *International Conference on Machine Learning and Intelligent Communications* (pp. 510-524). Springer, Cham.  
[https://doi.org/10.1007/978-3-030-32388-2\\_44](https://doi.org/10.1007/978-3-030-32388-2_44)
- Kilinc, H.C.; Haznedar, B. A (2022). Hybrid Model for Streamflow Forecasting in the Basin of Euphrates. *Water*, 14, 80. <https://doi.org/10.3390/w14010080>
- Ekmekçi M, (2008). Jeolojik geçmişten günümüze iklim değişiklikleri: küresel iklim değişimi ve Türkiye. *TMMOB İklim Değişimi Sempozyumu*, 13-14 Mart, Ankara, s. 7-26.
- Paksoy, M.Y., Savran, A. (2011). The Flora of Sarımsak Mountain and Körkün Valley (Pozantı, Adana/Turkey). *Biological Diversity and Conservation*. Vol. 4/2. 55-171.
- Somuncu, M., (2005). Aladağlar: Yaylacılık ve dağ göçebeliği konusunda bir araştırma. *Gündüz eğitim ve yayıncılık*, Ankara, 296 s. [https://doi.org/10.1501/Csaum\\_0000000031](https://doi.org/10.1501/Csaum_0000000031)
- K.S. Kadalı, L. Rajajib, V. Moorthy, J. (2017). Viswanathara, *Energy Procedia*, 117, 509. [DOI10.34049/bcc.51.B.025](https://doi.org/10.1016/j.egpro.2017.03.025)
- İnanç, T. (2021). Geliştirilmiş Gri Kurt Algoritması Tabanlı Karşılaştırmalı Kısa Dönem Hibrit Rüzgâr Gücü Tahmin Modelleri ve Uygulaması (Master's thesis, Bilecik Şeyh Edebali Üniversitesi).
- Islam, M.S., Sultana, S., Roy, U.K., Mahmud J. A., Islam SM. J. (2020). HARC-New Hybrid Method with Hierarchical Attention Based Bidirectional Recurrent Neural Network with Dilated Convolutional Neural Network to Recognize Multilabel Emotions From Text. *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, 7, 142-153.  
<https://doi.org/10.1016/j.jhydrol.2020.125188>