



Hibrit Parçacık Sürüsü Optimizasyonu ile Geçitli Tekrarlayan Birim Modeli Kullanılarak Nehir Akım Tahmini: Ceyhan Havzası Örneği

Yunus Öztürk¹, Hüseyin Çağan Kılınç^{2*}, Ahmet Polat³

¹ Kilis 7 Aralık Üniversitesi, Mühendislik-Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Kilis, Türkiye, (ORCID: 0000-0001-8032-9292), ynsemre@kilis.edu.tr

^{2*} İstanbul Esenyurt Üniversitesi, Mühendislik-Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0003-1848-2856),

huseyncagankilinc@esenyurt.edu.tr

³ İzmir Katip Çelebi Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, İzmir, Türkiye (ORCID: 0000-0001-8135-3681), polatrom@gmail.com

(İlk Geliş Tarihi 16 Haziran 2022 ve Kabul Tarihi 22 Temmuz 2022)

(DOI: 10.31590/ejosat.1131657)

ATIF/REFERENCE: Öztürk, Y., Kılınç, H. Ç. & Polat, H. (2022). Hibrit Parçacık Sürüsü Optimizasyonu ile Geçitli Tekrarlayan Birim Modeli Kullanılarak Nehir Akım Tahmini: Ceyhan Havzası Örneği. *Avrupa Bilim ve Teknoloji Dergisi*, (41), 202-210.

Öz

Su kaynaklarının verimli bir şekilde kullanılmasının en önemli yöntemlerinden biri havza bazlı yönetimin etkin bir şekilde gerçekleştirilmesidir. Su kaynaklarının sürdürülebilir olması, nehir akım tahminlerinin önemini ortaya koymaktadır. Bu çalışmada, nehir akım tahminine yardımcı olabilecek hibrit model kullanılmıştır. Derin öğrenme modellerinden olan kapalı tekrarlayan birim ve (GRU) ve parçacık sürüsü algoritması (PSO) hibritlenmiştir. Çalışmada Ceyhan Havzasının farklı kolları üzerinde yer alan Fırınz Deresi ve Aksu Çayı akım gözlem istasyonlarına ait 2001-2010 yıllarına ait günlük akış verileri kullanılmıştır. İstasyon verileri kıyaslama modeli (GRU) hibrit model (PSO-GRU) ve klasik yöntemlerden olan lineer regresyon (LR) ile kıyaslanmıştır. Sonuçlar karşılaştırıldığında hibrit modelin kıyaslama ve lineer regresyon modellerine göre daha başarılı sonuçlar verdiği gözlemlenmiştir. Ayrıca değerlendirme kriterlerinden olan RMSE, MAE, MAPE, SD ve R² değerlerine göre de hibrit model bu başarıyı doğrulamıştır.

Anahtar Kelimeler: Parçacık sürüsü algoritması, nehir akımı, kapalı tekrarlayan birim, hibrit model.

River Flow Forecasting Using the Gated Recurrent Unit Model with Hybrid Particle Swarm Optimization: The Case Study of Ceyhan Basin

Abstract

One of the most important methods of efficient use of water resources is the effective implementation of watershed-based management. The sustainability of water resources reveals the importance of stream flow estimations. In this study, a hybrid model was proposed to river flow estimation. Deep learning methods named, gated recurrent unit (GRU) and particle swarm algorithm (PSO), are hybridized. In the study, daily flow data of the Fırınz River and Aksu River, flow measurement stations, which are located on different branches of the Ceyhan Basin, were used with the timespan of 2001-2010. Benchmark model (GRU) was compared with hybrid model (PSO-GRU) and linear regression (LR) which is one of the classical methods. Once the results were compared, it was observed that the hybrid model was more successful than the comparison and linear regression models. In addition, the hybrid model confirmed this success according to the RMSE, MAE, MAPE, SD and R² values, which are among the evaluation criteria.

Keywords: Particle swarm optimization, streamflow, gated recurrent unit, hybrid model.

1. Giriş

Su yaşamın kaynağıdır ve ekolojik döngüler ve sosyal faaliyetler için önemli bir temeldir. Su kaynaklarının içme, tarım, rekreasyon ve sanayi gibi çeşitli kullanım amaçları için kritik önem taşımaktadır. Bununla birlikte, son yıllarda, ekonomik fayda sağlayan sayısız faktör çevreye zarar vermiştir ve Dünyadaki birçok ülke, hızlı ekonomik gelişme ile sınırlı tatlı su kaynaklarının önemli ölçüde azaldığını görmüştür (Zhou vd., 2022). Suyun Dünya üzerindeki dağılımı ve arzı düşünüldüğünde, sürdürülebilir kalkınmanın yanı sıra insanların tatlı su

kaynaklarına olan ihtiyaçları ciddi bir sorun haline gelmeye başlamıştır. Bu durum su kaynakları yönetiminin önemini daha da arttırmıştır. Bu şartlar altında yeterli bir yönetim planının oluşturulması tarım endüstrisi, insan sağlığı ve şehir toplumu için hayati önem taşımaktadır. Diğer yandan, toplam sistemin yönetimi, bilgisayar destekli modeller için uygun bir görev olan verilerin sürekli izlenmesini ve işlenmesini gerektirir. Bununla birlikte, son yıllarda su kaynakları ile ilgili çalışmaların artma eğiliminde olduğu görülmektedir (Akdeğirmen, 2019). Su kaynaklarını sürdürülebilir kılmanın en etkin yollarından birisi de havza bazlı yönetimin gerçekleştirilmesidir. Özellikle su kıtlığı problemi ile karşılaşan ülkelerde havza, nehir akış tahmini, sel-

taşkın önleme gibi modellemeler üzerinde fazlasıyla durulmaktadır. Son yıllarda modellerin oluşum süreçlerine bakıldığında, kavramsal ve veriye dayalı modeller ile nehir akım tahmin modelleri geliştirilmiştir. Bu modeller değişen dünyaya uyum sağlamak için yeni modelleri incelemeye odaklanmıştır. Kavramsal (fiziksel) modeller, insanların yüzeysel akış oluşum sürecini net bir şekilde anlamalarına yardımcı olsa da önemli hidrolojik ve meteorolojik parametrelere ve bir dizi matematiksel ve fiziksel denklemlere ihtiyaç duyarlar. Bu nedenle, bu tür modellerin uygulanmasında, zayıf tahmin performansı ve belirsizliğe neden olan birçok kısıtlayıcı faktör vardır (Bitelli vd., 2010). Ayrıca nehir akışlarının doğal karmaşıklığı, fiziksel modellerin kullanılmasını zorlaştırır. Son yıllarda, veriye dayalı akış tahmin modelleri geniş çapta çalışılmış ve uygulanmıştır. Bu tür modellerin akış sürecinin oluşum mekanizmasını derinlemesine anlaması gerekmez, yalnızca girdi ve çıktı örnekleri arasındaki doğrusal olmayan haritalama ilişkisini kurarak akışı tahmin etmesi gerekir. Bu nedenle, veriye dayalı tahmin modelleri giderek daha popüler hale gelmektedir (Xu vd., 2021). Veriye dayalı modeller, fiziksel modellere kıyasla daha basit model yapılarına sahiptir ve daha az modelleme verisine ihtiyaç duyar. Veriye dayalı modeller arasında otoregresif hareketli ortalama (ARMA), doğrusal regresyon (LR), otoregresif entegre hareketli ortalama modelleri gibi regresyon modelleri yer almaktadır. Ancak bu modeller nehir akışlarının doğrusal olmayışı ve belirsizlikleri nedeniyle istenilen başarıya ulaşmamaktadır (Sun vd., 2022; Chen vd., 2018).

Makine öğrenimine dayalı bir dizi veriye dayalı modelleme yöntemi akış tahminlerinde başarıyla kullanılmaktadır. Örneğin yapay sinir ağları (YSA)'lar regresyon modellerine göre hidrolojik parametrelerin tanımlanmasında daha başarılı sonuçlar elde etmektedir. Bu modeller arasında; destek vektör makinesi (SVM), uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS), aşırı öğrenme makineleri (ELM), uzun kısa süreli bellek ağları (LSTM), kapalı tekrarlayan birim ağları (GRU) literatürde sıkça kullanılan modeller arasında yer almaktadır. Bununla birlikte, nehir akış verileri yalnızca önceki girdi bilgisi ile geliştirildiğinde makine öğrenme modelleri tahmin başarısında zayıf kalabilmektedir (Mosavi vd., 2018). Akış verilerinin durağan ve doğrusal olmayışı nedeniyle bahsedilen modelleri geliştirmek amacıyla kullanılan metotlara bağlı olarak farklı optimizasyonlar uygulanmaktadır (Kılınç ve Haznedar, 2022). Optimizasyon, belirli bir problemin verilen şartlar altında tüm mevcut çözümleri arasından en uygun çözümü bulma sürecidir (Bunday, 1984). Optimizasyon algoritmaları ile hibritlenen modeller ile tahmin doğruluğundaki artışlar gözlemlenmektedir. Bu durum optimizasyonlara olan ilgiyi arttırmaktadır (Çelik vd., 2019).

Hidroloji ve akış tahmini gibi diğer çalışma alanları ile ilgili farklı süreçleri tahmin etmek için gerekli optimum parametreleri seçmek için YSA'ları çeşitli optimizasyon teknikleri ile birleştiren farklı hibrit modeller geliştirilmiştir (Yeraltı suyu kalitesinin modellenmesi (Kişi vd., 2019), yağış tahmini (Azad vd., 2019), yağış akış sürecini modelleme, akış deşarjını tahmin etme vb.). Bu optimizasyon teknikleri arasında optimuma yakın çözümler üretebilmesi ve kolay uygulanabilir olması metasezgisel algoritmaları ön plana çıkarmaktadır (Samanataray ve Sahoo, 2021).

Literatürde yaygın olarak kullanılan birçok metasezgisel algoritma bulunmaktadır. Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO), Su Dalgaları Optimizasyonu (WWO), Klonal Seçim Algoritması (CLONALG), Kimyasal Reaksiyon

Optimizasyonu (CRO), Uyum Araması (HS) gibi popüler algoritmalar bu duruma örnek olarak gösterilebilir (Kırtıl, 2022).

Mevcut çalışma, nehir akım tahminlerinde yüksek verimlilik için küresel ve hızlı yakınsamayı iyileştirmek amacıyla parçacık sürüsü optimizasyonu (PSO) algoritmasına dayalı, bir optimizasyon yaklaşımları geliştirmeye çalışmaktadır. Ayrıca çalışmada kullanılan PSO algoritması GRU ile hibritlenmiştir. GRU ve LSTM birçok soruda çok benzer performans gösterse de bu çalışmada GRU tercih edilmiştir. GRU modeli daha az parametreye ve daha basit bir yapıya sahip olduğu için daha hızlı bir öğrenme eğrisine sahiptir (Zhang et al. 2018). GRU modelinin eğitim süresi LSTM modeline göre daha kısadır (Stergiou ve Karakasidis 2021). Birçok bilim adamı, hidrolojik tahminde GRU'yu uygulamış veya ilgili modeller kurmuş ve tatmin edici sonuçlar elde etmiştir.

Parçacık Sürüsü Optimizasyonu (PSO) algoritması, bir zekâ optimizasyon teorisidir ve en parlak optimizasyon yaklaşımlarından biridir, çünkü uygulama kolaylığı, küre yakınsama yeteneği ve sağlamlık açısından diğer optimizasyon yöntemlerinden daha fazla avantajlara sahiptir. Kennedy ve Eberhart tarafından 1995 yılında arama ve optimizasyon problemlerini azaltmak için sunulan balık gruplarının ve kuşların normal davranışları gözlemlenerek geliştirildi. Bu teknikte bir parçacık sürüdeki her bir üyeyi temsil eder ve her parçacığın bir hız ve konum vektörü vardır. Bu parçacıklar aynı şekilde davranırlar: Her parçacık, sürüdeki değeri hedefe en yakın olan optimum yere yeniden konumlanır (Abdolrasol vd., 2022; Alzerkani, 2022).

Litaretür çalışmaları incelendiğinde metasezgisel algoritmalar ile hibritlenmiş çok sayıda çalışma bulunmaktadır. Bu çalışmalar hidroloji ve diğer alanlar olmak üzere sınıflandırılabilir. Bu çalışmalar kısaca özetlenirse; Chaudhury vd., (2022) çalışmalarında, aylık yağış tahmini için hibrit ANFIS-PSO modelini geliştirmiştir. Oluşturulan hibrit model kıyaslama modeli olan ANFIS ile karşılaştırıldığında sonuçlar son derece başarılı olmuştur. Achite vd., (2022) meteorolojik kuraklık tahmininde bulunmak için PSO, SSA (salp sürü algoritması) ve sinüs kosinüs algoritması (SCA)'yı kullanmıştır. Bu algoritmalar ANN ile hibritlenerek model başarısı gözlemlenmiştir. Sonuçlar incelendiğinde, üç algoritmanın da ANN modeline kıyasla performansı arttığı görülmüştür. Barutçu ve Erduman, (2022) PSO algoritması ile yenilenebilir enerji kaynaklarındaki güç kayıplarını incelemiştir. PSO algoritmasının sistem içerisindeki güç kaybını azaltmaya yönelik etkisinin başarılı olduğu sonucuna varılmıştır. Muhammad vd., (2019) popüler derin öğrenme modellerinden olan LSTM ve GRU modellerini kullanarak nehir akım tahmininde bulunmuştur. Bu iki model model tahmin geliştirme parametre modeli (MOPEX) ile hibritlenmiştir. Önerilen hibrit modelin performansı, geleneksel LSTM ve GRU modelleriyle karşılaştırılmıştır. Önerilen hibrit modelin akış tahmini açısından geleneksel LSTM'den daha iyi performans göstermesine rağmen, performansın GRU ile hemen hemen aynı olduğunu ve bu nedenle hidrolojik alanlarda verimli ve güvenilir bir yaklaşım olarak şiddetle tavsiye edildiğini göstermektedir. Ahmed vd., (2022) konveksiyonel sinir ağları (CNN) ve GRU modellerini hem kendi aralarında hem de karınca koloni algoritması (ACO) ile hibritlemiştir. Hibrit CNN-GRU modeli diğer modellere göre daha iyi bir performans göstermiştir. Singh vd., (2022) destek vektör makinesi (SVM) ile arı kolonisi algoritması ile hibritlemiştir. Sonuçlar incelendiğinde hibrit

modelin kıyaslama modeline göre daha başarılı olduğu görülmüştür.

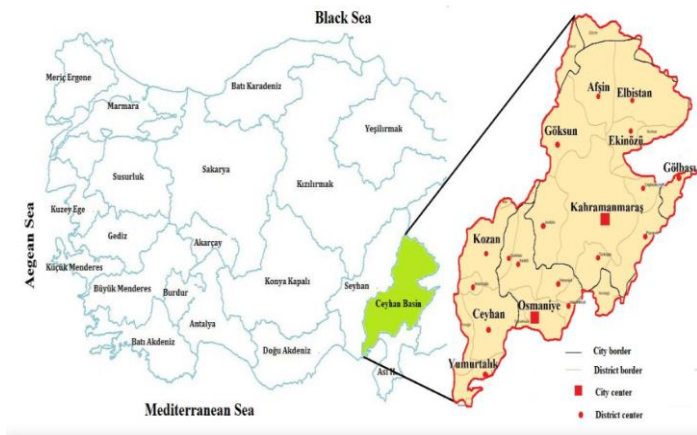
Bu çalışmanın amacı Ceyhan Nehri üzerinde bulunan iki farklı istasyonun günlük akım verileri ile tahminde bulunmaktır. Metasezgisel algoritmalarından olan PSO ve derin öğrenme modellerinden olan GRU ağları hibritlenerek, algoritmanın modele olan katkısı tartışılmaktadır. Ayrıca algoritmanın uygulanabilirliğini göstermek ve uygulandığında önerilerin tekniklerin doğruluğu ve verimliliği çalışmanın diğer amacıdır.

2. Materyal ve Metot

2.1. Çalışma Bölgesi

Şekil 1’de konumu gösterilen ve çalışma alanını oluşturan Ceyhan Havzası, Türkiye’deki 25 nehir havzasından birisidir. Kahramanmaraş ve Osmaniye İllerinin tamamına yakın kısmı; Adana İlinin Ceyhan ve Yumurtalık İlçeleri ile Merkez ilçe ve Kozan ilçelerinin bir bölümü Ceyhan Havzası sınırları içerisinde yer alır. Kuzey ve doğudan Fırat Havzası, batıdan Seyhan Havzası ve güneyden Asi Havzası ile komşu olan Ceyhan Havzasında, Gaziantep, Adıyaman, Malatya, Sivas ve Kayseri illerinin havzaya katkısı düşüktür. Türkiye yüzölçümünün yaklaşık %3,4’ünü kapsayan Ceyhan Havzası 26.875 km² yağış alanına sahiptir (ÇŞB, 2010).

Ceyhan Havzası’nda Akdeniz ve karasal iklim arasında kalan bir geçiş iklimi hakimdir. Havzanın güneyi Akdeniz İklimi etkisini yaşarken, kuzeyde ise karasal iklim özellikleri görülür. Yıllık toplam yağışın çoğu kış aylarında düşen Ceyhan Havzası’nda yazlar sıcak ve kurak geçmektedir (Çuhadar, 2019).

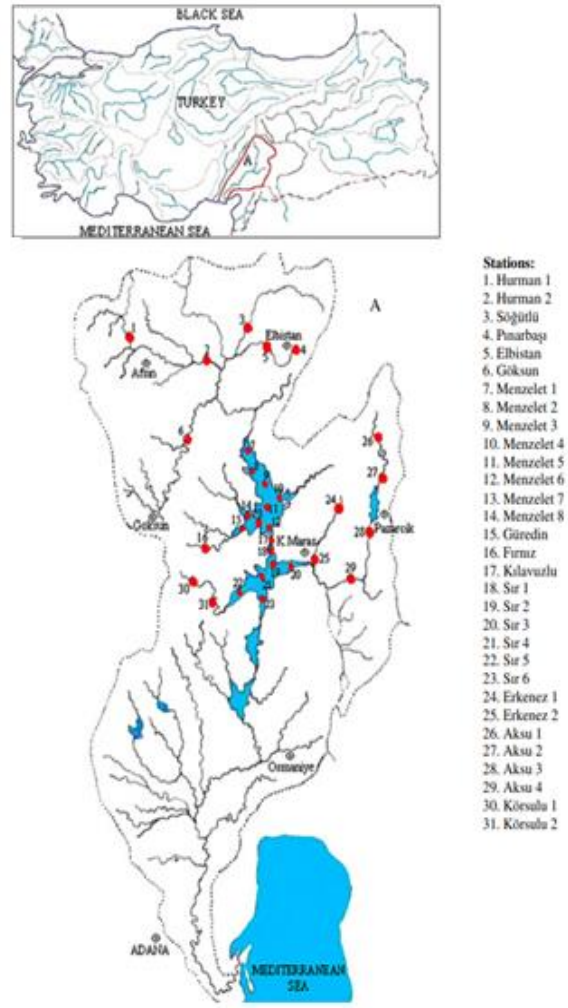


Şekil 1. Ceyhan Havzasının konumu

2.2. Veri Seti ve Akım Gözlem İstasyonları


Bu çalışmada, Ceyhan Havzasında bulunan akım gözlem istasyonlarından elde edilen veriler (Şekil 3’te görüldüğü gibi) kullanılmıştır. Ceyhan Nehrin’in dar ve derin vadiler içinde akıyor olması, üretim potansiyelleri açısından önem arz etmektedir. Ayrıca, Meteoroloji Genel Müdürlüğü (MGM)’nin yayınladığı ‘Türkiye Kuraklık Değerlendirme’ raporlarına göre, Ceyhan Havzası, Dicle-Fırat Havzası ile birlikte en fazla sıcaklık artışına

maruz kalacak havzalar arasında gösterilmiştir. Bu durum havzada ilerleyen zamanlarda yaşanması muhtemel su kıtlığına karşı etkin bir su kaynakları ve havza yönetimi koşulunu ön plana çıkarmaktadır. Havzada gözlemlenen faktörler Ceyhan Havzası’nın çalışma konusu olarak belirlenmesinde etkili olmuştur. Elde edilen veriler, 2001-2010 yıllarına ait günlük akış verilerinden oluşmaktadır. Şekil 2’de havza üzerindeki konumları verilen AGİ’lerin farklı kollarda yer alması koşulu Ceyhan Havzasında bu lokasyonların seçilmesinde birincil etken olmuştur. Çalışmada yer alan iki istasyondan birisi olan Fırınz Deresi AGİ (D20A053), 36°41’56" doğu boylamı, 37°45’37" kuzey enlemi koordinatları arasında yer almaktadır. Diğer istasyon olan Aksu Çayı (D20A002), 37°26’52" doğu boylamı, 37°42’26" kuzey enlemi koordinatları arasında yer almaktadır.



Şekil 2. Ceyhan Havzası ve AGİ’lerin lokasyonu

AGİ’lere ait bazı karakteristik özelliklerin yer aldığı bilgiler Tablo 1’de verilmiştir. Şekil 3’te istasyonlardan elde edilen verilerin dağılımı gösterilmektedir. Bu veriler test ve eğitim dağılımlarına göre verilmiştir. İstasyonlardaki veriler incelendiğinde maksimum akış verisi 28.2 m³/s ile Fırınz Deresi AGİ’sine, minimum akış verisi ise 0.372 m³/s ile Aksu Çayı AGİ’sine aittir.



Şekil 3. (a) Firnız Deresi ve (b) Aksu Çayı akım gözlem istasyonlarına ait günlük akım verilerinin test dağılımı

Tablo 1. Firnız Deresi ve Aksu Çayı istasyonlarına ait bilgiler

İstasyon	Nehir	Koordinatlar		Yağış Alanı (km ²)	Yükseklik(m)	Gözlem(yıl)
		Doğu	Kuzey			
		(° ‘ ‘‘)	(° ‘ ‘‘)			
D20A053	Firnız Deresi	36 41 56	37 45 37	147	648	2001–2010
D20A002	Aksu Çayı	37 26 52	37 42 26	216	895	2001–2010

Oluşturulan modelde Python sürümlerinden 3.10 kullanılmıştır. Yorumlanmış bir dil olarak Python donanım belleğini verimli kullanır, hata ve ayıklaması kolaydır ve geliştiricilerin birkaç adımda karmaşık görevleri gerçekleştirmelerine, kodları hızlıca düzenlemelerine olanak tanımaktadır. Python dinamik bir proglama dilidir. Python, çalışma zamanında, ancak derleme sırasında (kaynak kod makine koduna dönüştürüldüğünde) türleri ve hataları doğrular. Bu durum daha az kod, daha hızlı gelişme olarak açıklanabilir (Koç, 2019). Çalışmada yer alan GRU modeli, PSO algoritması ile hibritlenerek model doğrulukları test edilmiştir. Veriler analiz edilirken elde edilen günlük akış verilerinin eksiksiz olması ya da az kesintili olmasına özen gösterilmiştir. Havza bazlı çalışmalarda bu durum büyük önem taşımaktadır. Çünkü etkin planlama ve doğru tahmin analizleri gerçekleştirilebilir verilerin düzenli kayıtları ile mümkün olmaktadır. Bu nedenle zaman aralığı her iki istasyon içinde kesintilerin en az gözlemlendiği 2001-2010 yılları olarak belirlenmiştir.

2.3 Metot

Çalışmanın bu bölümünde, parçacık sürüsü algoritması ile hibritlenen kapılı tekrarlayan birim modeline ait akış şemaları ve formülasyonlara ait bilgiler yer almaktadır.

2.3.1. Kapılı Tekrarlayan Birim

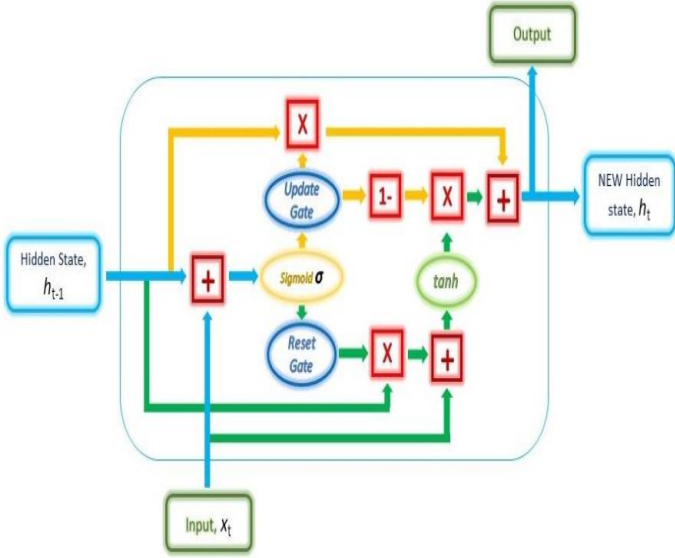
Cho vd. (2014) tarafından geliştirilen GRU modeli giriş ve unutma kapılarını güncelleme kapısında birleştiren yeni nesil LSTM'dir. Bu nedenle, LSTM'den daha az parametreye, daha hızlı çalışma süresine ve performansa sahiptir. Şekil 4, GRU'nun gizli katmanındaki nöronun yapısını göstermektedir. Bu gizli nöronun, LSTM'nin yapısını basitleştiren güncelleme ve sıfırlama kapıları adında iki kapısı vardır. Bu kapılar her adımda nöral durumu güncelleyerek bilgi akışı sağlamaktadır (Zhao vd., 2021; Wegayehu ve Muluneh, 2022). Güncelleme ve sıfırlama kapıları, GRU'da bulunan iki kapıdır. Güncelleme kapısı, değerli bilgilerin ezberlenmesini sağlayan mevcut belleği yenilerken sıfırlama kapısı, herhangi bir zaman adımında çok değerli bilgileri unutmak için mevcut belleği siler. GRU ağının yapısı ve gizli birimlerin ayrıntılı denklemleri aşağıdaki gibi tanımlanır;

$$Z_t = \sigma(W_z X_t + U_z h_{t-1} + b_z) \quad (1)$$

$$r_t = \sigma(W_r X_t + U_r h_{t-1} + b_r) \quad (2)$$

$$\hat{h}_t = \tanh(W_h X_t + (r_t \odot h_{t-1})) U_h + b_h \quad (3)$$

$$h_t = (1 - Z_t) \odot h_{t-1} + Z_t \odot \hat{h}_t \quad (4)$$



Şekil 4. GRU modeli

Bir GRU modeli, iki kapı işlevi içerir, yani bir güncelleme kapısı ve sıfırlama kapısı. Bunların arasında, x_t , t anındaki (Eşitlik 1) giriş verisidir. h_t , t (Eşitlik 4) zamanındaki çıkış verisi veya gizli katman birimi çıkışıdır, Eşitlik 3, bir aday aktivasyon vektörüdür. C iki vektör bağlantılı işlem anlamına gelir, X , giriş verisinin iki parçasının çarpılması anlamına gelir ve $1-$ verinin çıkarılması anlamına gelir modüle 1 ile giriş yapın ut , ana işlevi önceki andan mevcut duruma durum bilgisinin derecesini kontrol etmek olan güncelleme kapısı anlamına gelir ve daha büyük bir değer, mevcut anın önceki durumdan daha fazla durum bilgisi içerdiği anlamına gelir. rt , (Eşitlik 2) ana işlevi, önceki durumdan mevcut durum gizli hücre adayına ht bilgi oranını kontrol etmektir. σ , çıkış aralığı (0, 1) olan sigmoid etkinleştirme işlevidir ve \tanh , çıkış aralığı (-1, 1) olan hiperbolik tanjant etkinleştirme işlevidir (Zhou vd., 2022).

2.3.2 Parçacık Sürüsü Algoritması

Eberhart ve Kennedy (1995) popülasyon temelli sürü zekasına dayalı bir meta-sezgisel esnek evrimsel algoritma olan PSO'yu ilk öneren kişilerdi. PSO, kuşların yön tayininde birbirlerinden faydalanmalarından ve balık sürülerinin sosyal davranışlarından esinlenilerek geliştirilmiştir (Roshanrayan, 2018). Şekil 5 üzerinde detayları verilen PSO algoritmasının, karmaşık doğrusal olmayan problemleri çözmek için anlık yakınsama, basit bir yapı ve yüksek esnekliğe sahip olduğu bilinmektedir (Eldem, 2014; Chi vd., 2015). Bu özelliği sayesinde nehir akım tahmini modellemelerinde, taşkın hesaplarında ve diğer hidrolojik parametrelerle ile yapılan tahmin modeli çalışmalarında yaygın olarak kullanılmaktadır. PSO algoritmasının parçacık sürüsü, eldeki durumu ele almak için sürekli olarak en iyi çözümü arar.

Parçacık konumları karar değişkenleri olarak kabul edilir ve parçacıklar en iyi konumu bulmaya çalışır. İlk olarak, algoritma başlangıç konumlarını ($P(k)$) dikkate alır ve bu şekilde parçacığın $xis(k)$ konumu ($Pi \in Pk$) eşittir ($k = 0$, k : düzey sayısı), ki bu ilk adım olarak bilinir. Her parçacığın F fonksiyonu aşağıdaki denkleme göre hesaplanır. PSO parçacıkları arama uzayını rastgele takip eder. Sürüdeki parçacıklar, kendi ve komşularının bilgilerine bağlı olarak arama uzayında hareket eder. Gruptaki parçacıklar öğrenmeleri birbirlerinden yaparlar ve bilgilerine bağlı olarak en iyi komşuya doğru hareket eder. PSO'nun, her

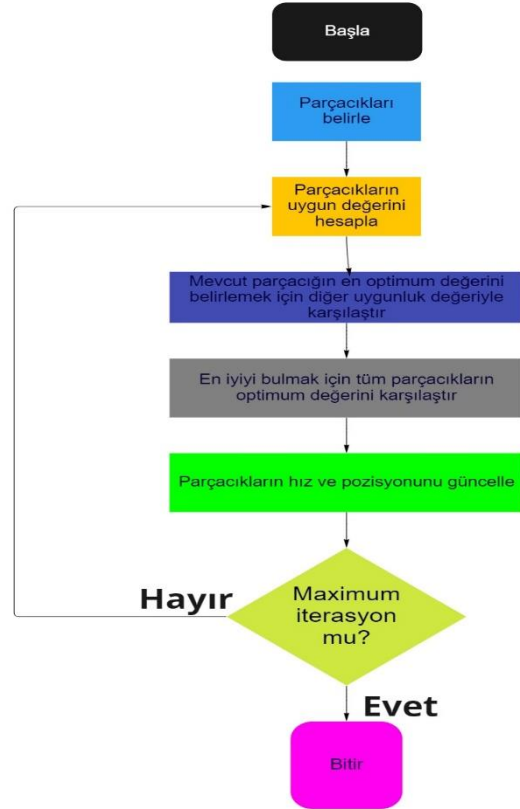
parçacık sürüsünün, şimdiye kadar bulunduğu en iyi konumu veya konumu ve komşusuna en yakın konumu bulmak için arama uzayında hareket ettiği öncülüne dayandığı söylenerek özetlenebilir (Islam vd., 2022).

$$\text{if } (F(x_i(k))) < pbest_i \rightarrow \text{then } \begin{cases} pbest_i = F(x_i^k) \\ x_{pbest_i} = x_i(k) \end{cases} \quad (5)$$

$$\text{if } (F(x_i(k))) < gbest_i \rightarrow \text{then } \begin{cases} gbest_i = F(x_i^k) \\ x_{gbest_i} = x_i(k) \end{cases} \quad (6)$$

$$v_i^k = wv_i^{k-1} + r_1c_1(x_{pbest_i} - x_i^k) + r_2c_2(x_{gbest_i} - x_i^k) \quad (7)$$

Eşitlik (5), bireysel parçacıkların optimal verimliliğini incelemek için kullanılır. Burada $pbest_i$, i th. parçacığın en iyi konumudur. Her parçacığın hızı Eşitlik (6)'e göre hesaplanır. Burada $gbest_i$, farklı parçacık sürüleri tarafından elde edilen en iyi küresel konumdur. Eşitlik 7'de ifade edilen (r_1 ve r_2) rastgele parametrelerdir ayrıca ' w ' eylemsizlik ağırlığıdır ve (c_1 ve c_2) ivme katsayılarıdır.



Şekil 5. Parçacık sürüsü algoritması diyagramı

2.3.3 PSO-GRU Hibrit Modeli

GRU modelinde parametrelerin özellikleri analiz performansını etkilemektedir. Bu çalışmada modele ait önemli hiperparametreler arasında yer alan, katman sayısı ve gizli katmanlardaki nöron sayısı, pencere büyüklüğü, aktivasyon fonksiyonu gibi parametreleri iyileştirmek için PSO algoritmasından yararlanılmıştır. Test sonuçları onbeş kez rastgele parametreler ile eğitilmiş ve veriler karşılaştırılmıştır. Optimum

değere sahip sonuçlar kıyaslama (benchmark) modeli olarak kullanılmıştır. PSO algoritmasından elde edilen optimum sonuçlar ise bir parametre olarak GRU ağına eklenmiş ve oluşturulan yeni hibrit model tekrar eğitilmiştir. Şekil 6'da PSO algoritmasının GRU ağına eklenme safhaları akış şeması üzerinden açıklanmıştır. Hibrit modelin doğruluğu kıyaslama modeli ile karşılaştırılarak gözlemlenmiştir. Daha sonra klasik yöntemlerden olan lineer regresyon yönteminden de sonuçlar elde edilmiştir. Bu yöntemden elde edilen sonuçlar hibrit ve kıyaslama modelleri ile kıyaslanmıştır.

Modelin eğitim aşaması için veriler ayıklanmış ve düzenlenmiştir. Veri seti değişik oranlarda eğitim ve test veri setlerine bölünerek analiz edilmiştir. Sonuçlar incelendiğinde optimum değerlerin %80 eğitim %20 test veri setlerinden olduğu gözlemlenmiştir. Hibrit modelde her iki istasyona ait veri setindeki parametreleri optimize etmek için çeviri ve normalizasyon teknikleri uygulanmıştır. Elde edilen PSO sonuçları, GRU parametreleri olacak şekilde ayarlanarak eğitilen hibrit model, 1 dense 1 gizli katman ile eğitilmiştir.



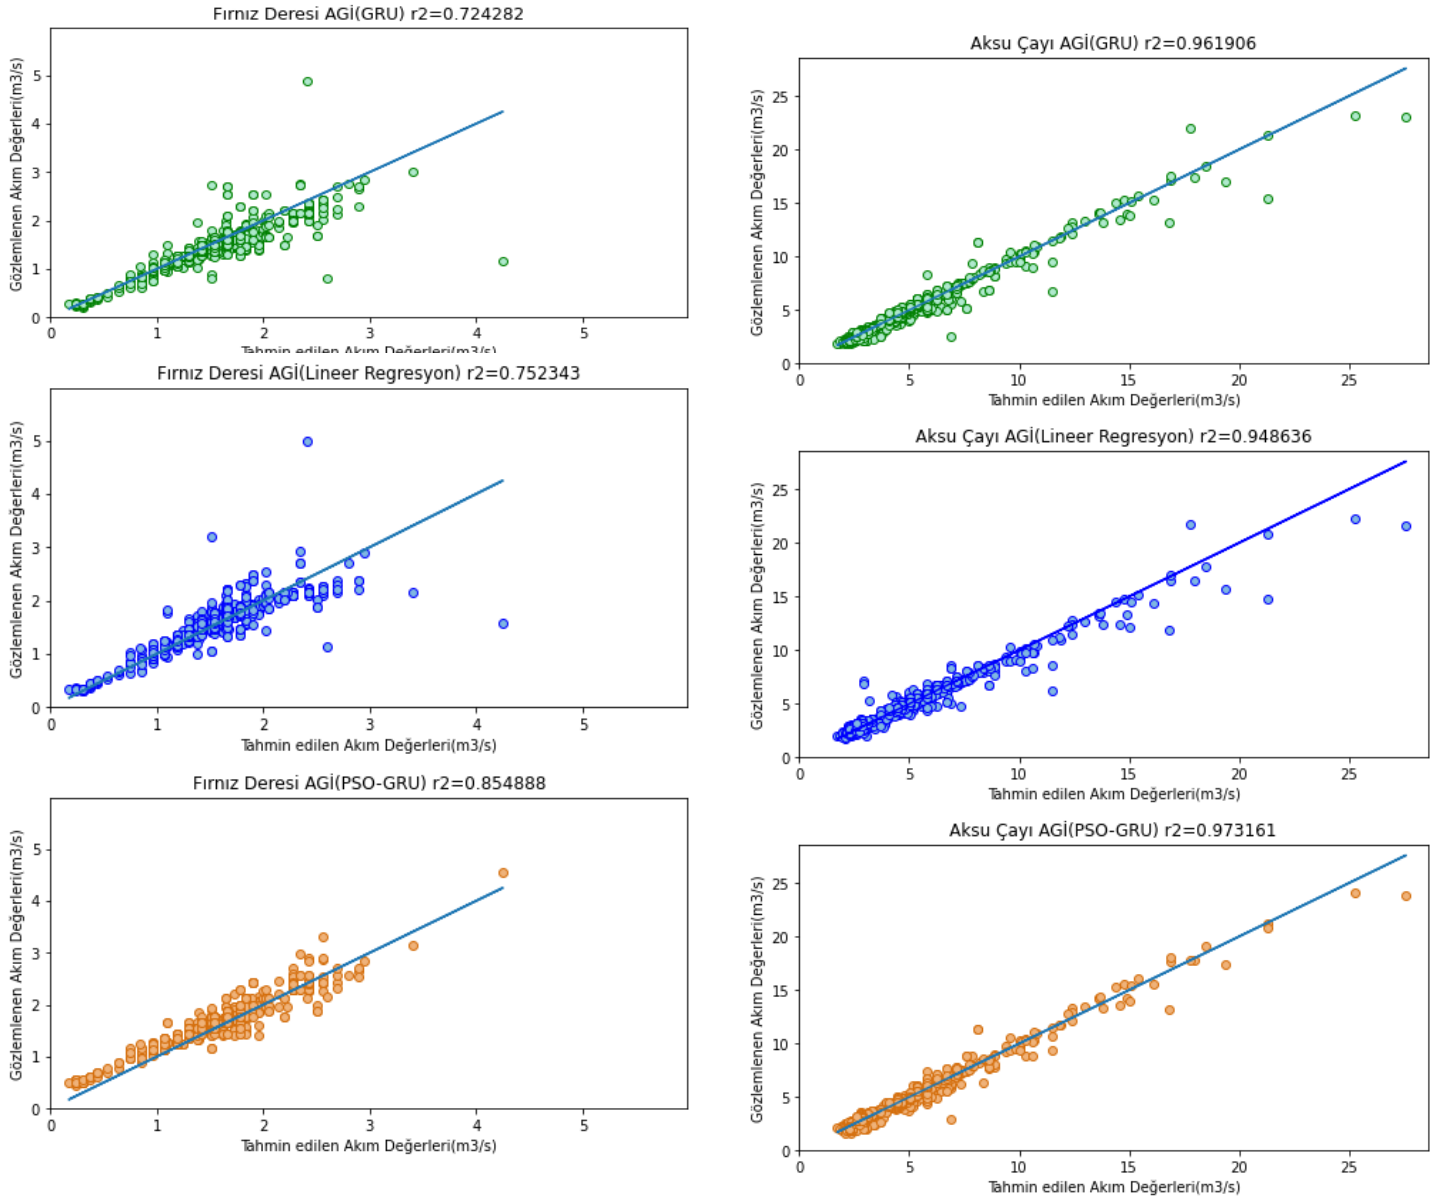
Şekil 6. Önerilen hibrit modele ait akış şeması

3. Analiz Sonuçları

Bu çalışmada, PSO ve GRU yapısındaki parametreler optimize edilerek Şekil 2'de lokasyonları verilen Fırız Deresi ve Aksu Çaylarına ait istasyonlara ait hidrolojik zaman serisi problemine çözüm aranmıştır. Bu kapsamda, derin öğrenme modellerinden kapılı tekrarlayan birim model, parçacık sürüşü algoritması ile hibritlenerek, klasik yöntemlerden olan lineer regresyon modeli ile kıyaslanmıştır. İyileştirici fonksiyonu olarak 'ADAM' iyileştiricisi uygulanmış, kayıp fonksiyonu ise 'MSE' olarak belirlenmiştir. Çalışmada kullanılan yöntemlerin performans ölçümlerinde, ortalama karekök hata (RMSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), determinasyon katsayısı (R^2) ve standart sapma (SD) istatistikleri kullanılmıştır. Bu değerlendirme metrikleri, günlük akış değerlerinin tahmin edilmesi ve etkinliğin belirlenmesinde birçok çalışmada yaygın olarak kullanılan ölçüm araçları olarak sunulmaktadır (Abyaneh vd., 2011; Arslan vd., 2019). Bu çalışmada kullanılan PSO-GRU, GRU ve Lineer regresyon yöntemlerine ait performans ölçümleri Tablo 2'de verilmiştir. Modellere ait saçılma grafikleri incelendiğinde Hibrit PSO-GRU modelinin, kıyaslama modeli ve lineer regresyon modeli karşısındaki performansının oldukça başarılı olduğu görülmektedir.

Ayrıca, AGİ'lerinden elde edilen test verilerinin uygulanan yöntemler ile elde edilen dağılım grafikleri sırasıyla Şekil 7'de verilmektedir. Bu saçılma grafiklerine bakıldığında hibrit PSO-GRU yönteminin sonuçları gerçek nehir akım değerlerine daha yakın olup, Fırız Deresi istasyonu için 0,8548 R^2 değeri ve Aksu Çayı istasyonu için 0,9731 R^2 ile en yüksek başarı öngörüsüne sahiptir.

Ayrıca Tablo 2'de değerlendirme kriterleri verilen ölçümlerden, MAE istatistiksel değerlendirme kriterine göre Fırız Deresi ve Aksu Çayında GRU modeli, diğer modellere göre daha başarılı sonuçlar vermiştir. RMSE değerlendirme kriterine göre, hibrit model olan PSO-GRU her iki istasyonda da başarılı olmuştur. MAPE değerlendirme kriterine göre her iki istasyonda da kıyaslama modeli diğer modelleri geride bırakarak daha iyi bir performans gösterdiği gözlemlenmiştir. Standart sapma değerlerine bakıldığında, Aksu Çayı istasyonunda lineer regresyon en başarılı sonucu verirken, Fırız Deresi istasyonunda hibrit model diğer modellere göre daha başarılı olmuştur.



Şekil 7. Firnız Deresi ve Aksu Çayı istasyonlarına ait modellerin saçılma grafikleri

Tablo 2. İstatiksel değerlendirme kriterleri

İstasyon	Model	RMSE	MAE	MAPE	SD	R ²
Firnız Deresi	PSO-GRU	0,1895	0,1041	10,4150	0,1202	0,8544
	GRU	0,2475	0,0901	9,0193	0,1388	0,7242
	Liner	0,2616	0,1028	10,2838	0,1738	0,7523
	Regresyon					
Aksu Çayı	PSO-GRU	0,5025	0,0755	7,5524	0,1141	0,9731
	GRU	0,6019	0,0634	6,3430	0,1153	0,9619
	Liner	0,6981	0,0702	7,0246	0,1071	0,9486
	Regresyon					

4. Sonuç

Bu çalışmada akış verilerini tahmin etmek PSO ve GRU'yu entegre eden bir hibrit yöntem önerilmektedir. Önerilen modelin performansı Fırtın Deresi ve Aksu Çayı akım gözlem istasyonu verileri üzerinde test edilmiştir. Temel olarak, GRU sinir ağı, zaman serisi tahminleri için başarılı bir öğrenme yeteneği gösterse de performansı bazı hiper parametrelerin etkisiz kalması nedeniyle yetersiz kalmaktadır. Örneğin, GRU modellerinde hala yavaş yakınsama hızı ve düşük öğrenme verimliliği gibi sorunlar vardır, bu da çok uzun eğitim süresine ve hatta yetersiz uyumla sonuçlanır. Bu nedenle PSO parametrelerinin etkin güçlerinden yararlanılmıştır. GRU parametrelerinin uygun değerlerini aramak için PSO kullanılmıştır. RMSE, MAE, MAPE, SD, R² gibi istatistiksel ölçüm kriterleri özellikle tahmin ölçümleri ve modelin performansını gözlemek için temel kriterlerdir. Bu kriterler önerilen yöntemin performansını değerlendirmek için kullanılmıştır. Elde edilen sonuçlar, önerilen PSO-GRU yaklaşımı ile akış verilerinin tahmin hatasının kıyaslama modeline göre daha başarılı bir şekilde azaltıldığını göstermiştir. Sonuç olarak, yaklaşımın düşük ölçümlere sahip olduğu tespit edilmiştir ve değerlendirme kriterleri ile bu sonuçlar anlamlı hale gelmiştir. Bu durum hibrit model yaklaşımının kıyaslama modelini iyileştirebildiğini göstermektedir. Değerlendirme kriter sonuçlarının yer aldığı Tablo 2 modelin verilere olan uyumunu belirtmektedir. Popülasyon tabanlı algoritmalar için yüksek olasılık tabanlı arama stratejileri nedeniyle, küresel optimumun bölgesine erişmek için genellikle uzun bir hesaplama süresi gerekir. Bu sebeple, GRU ağının diğer meta-sezgisel arama tekniklerini kullanarak eğitilmesi ve ilgili ağlardaki performansının incelenmesi için gelecekte yapılacak çalışmalar önem arz etmektedir. Ayrıca, küresel ısınma, iklim değişikliği ve su kıtlığı gibi çarpıcı etkilere maruz kalan ülke içerisindeki farklı havzaların da yeni hibrit modeller ile incelenmesi, gelecek için planlamaya esas projelere katkı sağlayacaktır.

Kaynakça

Zhou, S.; Song, C.; Zhang, J.; Chang, W.; Hou, W.; Yang, L. A Hybrid Prediction Framework for Water Quality with Integrated W-ARIMA-GRU and LightGBM Methods. *Water* 2022, 14, 1322. <https://doi.org/10.3390/w14091322>

Akdeğirmen, Ö. (2019). SCS Curve Number ve Soil Moisture Accounting Yöntemleriyle HEC-HMS Havza Modellemesi: Alaşehir Havzası Örneği. Yüksek lisans Tezi. İzmir, Türkiye: İzmir Yüksek Teknoloji Üniversitesi.

Xu, Z., Zhou, J., Mo, L., Jia, B., Yang, Y., Fang, W., Qin, Z. (2021). A Novel Runoff Forecasting Model Based on the Decomposition-Integration Prediction Framework. *Water*, 13, 3390. <https://doi.org/10.3390/w13233390>

Bittelli, M., Tomei, F., Pistocchi, A., Flury, M., Boll, J., Brooks, E.S., Antolini, G. (2010). Development and testing of a physically based, three-dimensional model of surface and subsurface hydrology. *Adv. Water Resour.* 33, 106–122. <https://doi.org/10.1016/j.advwatres.2009.10.013>

Kilinc, H.C.; Haznedar, B. (2022). Hybrid Model for Streamflow Forecasting in the Basin of Euphrates. *Water*, 14, 80. <https://doi.org/10.3390/w14010080>

Chen, L.; Sun, N.; Zhou, C.; Zhou, J.; Zhou, Y.; Zhang, J.; Zhou, Q. (2018). Flood Forecasting Based on an Improved Extreme Learning Machine Model Combined with the Backtracking Search Optimization Algorithm. *Water*, 10, 1362. <https://doi.org/10.3390/w10101362>

Sun, N., Zhang, S., Peng, T., Zhang, N., Zhou, J., Zhang, H. (2022). Multi-Variables-Driven Model Based on Random Forest and Gaussian Process Regression for Monthly Streamflow Forecasting. *Water*, 14, 1828. <https://doi.org/10.3390/w14111828>

Mosavi, A., Ozturk, P., Chau, K. W. (2018). Flood Prediction Using Machine Learning Models: Literature Review. *Water*, 10, 1536. <https://doi.org/10.3390/w10111536>

B. Bunday, Basic Optimization Methods, London: Edward Arnold Ltd, 1984.

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>

Samanataray, S., Sahoo, A. (2021). A Comparative Study on Prediction of Monthly Streamflow Using Hybrid ANFIS-PSO Approaches. *KSCE Journal of Civil Engineering*, 25(10), 4032–4043. <https://doi.org/10.1007/s12205-021-2223-y>

Chaudhury, S., Samantaray, S., Sahoo, A., Bhagat, B., Biswakalyani, C., Satapathy, D.P. (2022). Hybrid ANFIS-PSO Model For Monthly Precipitation Forecasting. In: Bhateja, V., Tang, J., Satapathy, S.C., Peer, P., Das, R. (eds) *Evolution in Computational Intelligence. Smart Innovation, Systems and Technologies*, vol 267. Springer, Singapore. https://doi.org/10.1007/978-981-16-6616-2_33

Kırtıl, H. S. (2022). Mobil Lokalizasyon Problemine Uygulanan Yeni Bir Hibrit Metasezgisel Algoritma. Yüksek lisans Tezi. İstanbul, Türkiye: İstanbul Sabahattin Zaim Üniversitesi.

Zhang, D., Lindholm, G., Ratnaw, E., R. H. (2018). Use long short-term memory to enhance Internet of Things for combined sewer overflow monitoring. *Journal of Hydrology* 556: 409-418.

Stergiou, K., Karakasidis, T. E. (2021) Application of deep learning and chaos theory for load forecasting in Greece. *Neural Computing and Applications*.

Abdolrasol, M. G. M., M. A. Hannan, S. M. S. Hussain, and T. S. Ustun. (2022). Optimal PI controller based PSO optimization for PV inverter using SPWM techniques. *Energy Reports*, 8, 1003–1011.

Alzerkani, L. A. R. (2022). Control The Maximum Power Point (MPP) During Rapidly Change of Irradiation in Partially Shaded Photovoltaic System Using Particle Swarm Optimization (PSO). Yüksek lisans Tezi. İstanbul, Türkiye: Altınbaş Üniversitesi.

Achite, M., Banadkooki, F.B., Ehteram, M. *et al.* Exploring Bayesian model averaging with multiple ANNs for meteorological drought forecasts. *Stoch Environ Res Risk Assess* (2022). <https://doi.org/10.1007/s00477-021-02150-6>

Barutcu, İ. Ç. & Erduman, A. (2022). Analysis of the Uncertainty Effect in Power System Losses: Uncertainties of Renewable Energy and Load. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 62-71. DOI: 10.31590/ejosat.1051410

Muhammad, A.U., Li, X., Feng, J. (2019). Using LSTM GRU and Hybrid Models for Streamflow Forecasting. In: Zhai, X., Chen, B., Zhu, K. (eds) *Machine Learning and Intelligent Communications. MLICOM 2019. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, vol 294. Springer, Cham. https://doi.org/10.1007/978-3-030-32388-2_44

Ahmed, A.A.M., Deo, R.C., Feng, Q. *et al.* Hybrid deep learning method for a week-ahead evapotranspiration forecasting. *Stoch Environ Res Risk Assess* 36, 831–849 (2022). <https://doi.org/10.1007/s00477-021-02078-x>

- Singh, U.K., Kumar, B., Gantayet, N.K., Sahoo, A., Samantaray, S., Mohanta, N.R. (2022). A Hybrid SVM–ABC Model for Monthly Stream Flow Forecasting. In: Chakravarthy, V.V.S.S.S., Flores-Fuentes, W., Bhateja, V., Biswal, B. (eds) *Advances in Micro-Electronics, Embedded Systems and IoT. Lecture Notes in Electrical Engineering*, vol 838. Springer, Singapore. https://doi.org/10.1007/978-981-16-8550-7_30
- Cho, K.; van Merriënboer, B.; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, 25–29 October 2014; 1724–1734.
- Zhao, X.; Lv, H.; Wei, Y.; Lv, S.; Zhu, X. Streamflow Forecasting via Two Types of Predictive Structure-Based Gated Recurrent Unit Models. *Water* 2021, 13, 91.
- Wegayehu, E.B., Muluneh, F. B. Short-Term Daily Univariate Streamflow Forecasting Using Deep Learning Models, *Advances in Meteorology*, 2022, 1860460, 21.
- Zhou, S.; Song, C.; Zhang, J.; Chang, W.; Hou, W.; Yang, L. A Hybrid Prediction Framework for Water Quality with Integrated W-ARIMA-GRU and LightGBM Methods. *Water* 2022, 14, 1322.
- Kennedy, J.; Eberhart, R. Particle swarm optimization. In *Proceedings of the ICNN'95-International Conference on Neural Networks*, Perth, WA, Australia, 27 November–1 December 1995; IEEE: Piscataway, NJ, USA, 1995; Volume 4, pp. 1942–1948.
- Roshanravan, B.; Aghajani, H.; Yousefi, M.; Kreuzer, O. Particle Swarm Optimization Algorithm for Neuro-Fuzzy Prospectivity Analysis Using Continuously Weighted Spatial Exploration Data. *Nonrenew. Resour.* 2018, 28, 309–325.
- Chi, S.; Ni, S.; Liu, Z. Back Analysis of the Permeability Coefficient of a High Core Rockfill Dam Based on a RBF Neural Network Optimized Using the PSO Algorithm. *Math. Probl. Eng.* 2015, 2015, 1–15.
- Eldem, H. (2014). Karınca koloni optimizasyonu (KKO) ve parçacık sürüsü optimizasyonu (PSO) Algoritmaları Temelli Bir Hiyerarşik Yaklaşım Geliştirilmesi. Yüksek lisans Tezi. Konya, Türkiye: Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Abyaneh, H.Z.; Nia, A.M.; Varkeshi, M.B.; Marofi, S.; Kisi, O. Performance Evaluation of ANN and ANFIS Models for Estimating Garlic Crop Evapotranspiration. *J. Irrig. Drain. Eng.* 2011, 137, 280–286.
- Arslan, N.; Sekertekin, A. Application of Long Short-Term Memory neural network model for the reconstruction of MODIS Land Surface Temperature images. *J. Atmos. Sol. Terr. Phys.* 2019, 194, 105100.
- Çuhadar, M., Atış, E. (2019). Drought Analysis in Ceyhan Basin Using Standardized Precipitation Index. *Journal of the Institute of Science and Technology*, 9, 2303-2312.
- Tanriverdi, Ç., Alp, A., Demirkıran, A. R., Üçkardeş, F. (2009). Assessment of surface water quality of the Ceyhan River basin, Turkey. *Environmental Monitoring and Assessment*, 167(1-4), 175–184. <https://doi.org/10.1007/s10661-009-1040-4>
- Çuhadar, M. (2019). Mobil Lokalizasyon Problemine Uygulanan Yeni Bir Hibrit Metasezgisel Algoritma. Yüksek lisans Tezi. İstanbul, Türkiye: İstanbul Sabahattin Zaim Üniversitesi. Doktora Tezi. İzmir, Türkiye: Ege Üniversitesi.
- Koç, K. O. (2019). Phyton Üzerinden Derin Öğrenme Algoritmaları Kullanılarak Deri Görüntüsünden Cilt
- Hastalıklarının Tespit Edilmesi. Yüksek lisans Tezi. Bolu, Türkiye: Bolu Abant İzzet Baysal Üniversitesi.