



EEG SİNYALLERİNDEN META-SEZGİSEL OPTİMİZASYON ALGORİTMALARINA DAYALI ÖZELLİK SEÇİMİ

Eyüp GEDİKLİ^{1*}, Taner YURDUSEVER²

¹Karadeniz Technical University, Of Technology of Faculty, Department of Software Engineering, 61830, Trabzon, Türkiye

²Gümüşhane University, Kelkit Sema Doğan Health Science Vocational School, 29600, Gümüşhane, Türkiye

Özet: Özellik seçimi makine öğrenmesi alanında, sınıflandırma işlemlerinin öncesinde bulunan önemli bir aşamadır. Ayırt edici özelliklerin iyi belirlendiği durumlarda, sınıflandırma başarı performansı artar ve daha az özellik değerlendirildiği için hesaplama maliyeti azalır. Elektroensefalografi (EEG) yöntemi ile beynin spontan elektrik aktiviteleri ölçülmektedir. EEG sinyallerinin analiz edilmesiyle, duyu durumu, hastalık teşhisi, anomali tespiti yapılabilmektedir. Bu çalışmada, EEG sinyallerinden epilepsi teşhisi amacıyla, sınıflandırmada kullanılan özelliklerin seçilmesine çalışılmıştır. Kullanılan verisetinde, epileptik ve sağlıklı bireylerden oluşan 2 sınıf mevcuttur. Verisetinde, EEG sinyallerinin alt bileşenlerinden 667 özellik vardır. Sınıflandırma için bu 667 özellikten meta-segisel optimizasyon algoritmaları ile ayırt edici özellikler seçilmiştir. Sınıflandırma için k en yakın komşuluk algoritması kullanılmıştır. EEG sinyallerinin alt bileşenlerinin tamamı ile yapılan sınıflandırmada, %60,05 doğruluk başarı elde edilmiştir. Gri Kurt Optimizasyonu, Balina Optimizasyonu ve Harris Şahinler Optimizasyonu metasegisel algoritmaları ile özellik seçimi sonucunda, sınıflandırma başarı %80,16 olarak elde edilmiştir. Bu sınıflandırma başarı 5-10 özellik kullanılarak elde edilebilmektedir. Sonuç olarak meta-segisel optimizasyon algoritmaları ile daha az özellik seçilerek doğruluk oranı artmış ve hesaplama maliyeti azalmıştır.

Anahtar kelimeler: Balina optimizasyonu algoritması, Elektroensefalografi, Gri kurt optimizasyon algoritması, Harris şahini optimizasyonu algoritması, Özellik seçimi

Feature Selection Based on Meta-Heuristic Optimization Algorithms from EEG Signals

Abstract: Feature selection is an important stage in the field of machine learning before classification processes. In cases where distinguishing features are well determined, classification success performance increases. Another advantage is that the computational cost is reduced because fewer features are evaluated. Electroencephalography (EEG) is a method that measures spontaneous electrical activities of the brain. By analyzing EEG signals, emotional state, disease diagnosis and anomaly detection can be made. In this study, feature selection for classification in epilepsy diagnosis from EEG signals was attempted. The dataset used has two classes, consisting of epileptic and healthy individuals. There are 667 features in the dataset from subcomponents of EEG signals. For classification, distinctive features were selected from these 667 features with metaheuristic optimization algorithms. The k nearest neighbor algorithm was used for classification. In the classification made with all subcomponents of EEG signals, 60.05% accuracy was achieved. As a result of feature selection with Gray Wolf Optimization, Whale Optimization and Harris Hawks Optimization metaheuristic algorithms, the classification success was achieved as 80.16%. This classification success can be achieved by using 5-10 features. As a result, it is seen that the accuracy rate increases and the computational cost decreases by selecting fewer features with meta-heuristic optimization algorithms.

Keywords: Whale optimization algorithm, Electroencephalography, Grey wolf optimization algorithm, Harris hawks optimization algorithm, Feature selection

*Sorumlu yazar (Corresponding author): Karadeniz Technical University, OfTehnology Faculty, Department of Software Engineering, 61830, Trabzon, Türkiye

E mail: gediklie@ktu.edu.tr (E. GEDİKLİ)

Eyüp GEDİKLİ



<https://orcid.org/0000-0002-7212-5457>

Taner YURDUSEVER



<https://orcid.org/0000-0001-9536-8171>

Gönderi: 26 Mayıs 2024

Kabul: 02 Temmuz 2024

Yayınlanma: 15 Temmuz 2024

Received: May 26, 2024

Accepted: July 02, 2024

Published: July 15, 2024

Cite as: Gedikli E, Yurdusever T. 2024. Feature selection based on meta-heuristic optimization algorithms from EEG signals. BSJ Eng Sci, 7(4): 717-723.

1. Giriş

EEG sinyalleri ile hastalık teşhisi, duyu analizi, yalan makinesi, fiziksel hareketlere göre beynin tepkisi belirlenebilir. Kumar ve Bhuvanewari (2012) çalışmasında, 20 prob ile aldığı EEG sinyallerini, koku, görme, göz hareketi, yüz hareketi, duyma ve denge gibi fonksiyonlara ayırmıştır. Çalışmalarında veri süzgeçlendikten sonra özellik çıkarımı ve sınıflandırma yapılmaktadır. Epilepsi, hafıza kaybı, alzheimer ve otizm gibi bazı beyin hastalıklarında EEG sinyalleri yaygın olarak kullanılmaktadır (Claassen ve ark., 2003). Epilepsi

hastalığı, çocukluk ve ergenlik çağında en sık görülen nörolojik hastalıklar arasında yer alır. Genel olarak titremeler ve nöbetler şeklinde kendini gösteren epilepsi, beyin nöronlarında görülen anormal aktivitelerin normal seyri etkilemesi sonucunda bireylerde ani ve istemsiz kasılmalara, bilincin kapanmasına ve/veya duygusal değişimlere neden olur (Acharya ve ark., 2013). Epilepsi teşhisi için kan testleri, MR, bilgisayarlı tomografi ve PET gibi teknikler kullanılsa da, nöronlarda olan bu değişimlerin takip edilip teşhis konması için elektroensefalografi (EEG) tanısı oldukça önemlidir



(Iasemidis ve ark., 2003).

EEG, beynin spontan elektriksel aktivitesinin elektrogramını kaydetme yöntemidir. EEG kayıtları, ortalama 21 tane küçük elektrot ile çok sayıda kanaldan ölçümler yapan farklı cihazlardan üretilen sinyallerdir (Kumar ve Bhuvanewari, 2012). Nöbet dalga formlarının oldukça karmaşık olduğu durumlarda EEG kayıtlarının değerlendirilmesi oldukça güçleşebilmekte ve yanlış teşhisler konulmasına ya da tekrar tekrar kayıtlar alınmasına sebep olmaktadır. Çok fazla sayıda veriden oluşan bu kayıtların sinyal işleme yaklaşımları ile işlenmesi, makine öğrenimi teknikleri ile sınıflandırılması daha doğru tanı ve teşhis konmasına yardımcı olmaktadır. EEG sinyalleri oldukça fazla olduğundan, yorumlanırken aranan tanıya göre hareket edilebilir. Bu işlem bilgisayarla görmeye dayalı olarak otomatik ya da kısmi-otomatik olarak yapılabilir. Anomali tespit edilen durumlar uzmanlar için rapor edilebilir. Bunun için çok sayıda özelliğin tanıya göre seçilmesi gerekmektedir. Çoğu kez fazla özelliğin kullanılması sınıflandırma başarısını olumsuz etkilemektedir. Bundan ötürü, amaca yönelik anomali belirtisi olan özelliklerin seçimi önem arz etmektedir.

Makine öğrenmesi yaklaşımlarında, verinin çok fazla özellik içermesi sınıflandırma başarısını ve hesaplama karmaşıklığını doğrudan etkiler. Çok fazla özellik her zaman daha iyi sınıflandırma başarısı anlamına gelmemektedir. Diğer yandan aynı özelliklerle farklı sınıflandırma yapılabilmektedir. Örneğin yüz görüntülerinden, cinsiyet, yaş ve kimlik tanıma gibi problemlerde aynı verinin farklı özellikleri çıkarılmaktadır. Bu nedenle sınıflandırma aşamasından önce özellik seçimi yapılmaktadır. Böylece fazlalıklar atılıp doğrudan sınıflandırmaya etki eden verilerle çalışılabilmektedir.

Bu çalışmada, meta sezgisel yaklaşımlar kullanılarak epileptik tanı için EEG sinyallerinden özellik seçimine çalışılmıştır. Kullanılan gri kurt optimizasyonunu (Al-Tashi ve ark., 2019; Al-Tashi ve ark., 2020; Abel-Basset ve ark., 2021), balina optimizasyonu (Hussien ve ark., 2019; Hussien ve ark., 2020; Sayed ve ark., 2020; Vijayanand ve Devaraj, 2020; Nadimi-Shahraki ve ark., 2022) ve harris şahini optimizasyonu (Elgamal ve ark., 2020; Thaher ve ark., 2020; Zhang ve ark., 2021) algoritmaları ile 667 özellikten <10 özellik seçilmiş ve k-en yakın komşuluk (k-EYK) algoritması ile sınıflandırma yapılmıştır. Metasezgisel algoritmalarla özellik seçimi, k-EYK algoritmasının başarımını ~%25 artırmıştır.

2. Materyal ve Yöntem

Bu bölümde, kullanılan veriseti, k-EYK sınıflandırma algoritması, tasarlanan amaç fonksiyonu ve kullanılan meta-sezgisel algoritmalarından bahsedilmiştir.

2.1. Epilepsi Hastalığı EEG Sinyalleri Veri Seti

Çalışmada kullanılan veri seti internette herkese erişime açık olup, 1020 epileptik ve 1196 normal, toplam 2216 kişinin kaydından oluşur (Hassine, 2024a; Hassine, 2024b). Veri setindeki sinyaller 23 kanaldan alınmış,

gamma (>30 Hz), beta (12-30 Hz), alpha (8-12 Hz), theta (4-8 Hz) ve delta (< 4 Hz) frekans bantlarından üretilmiştir. Her banttan, dalgacık dönüşümü ve alt bileşenlerinin ortalama, standart sapma, güç bileşenleri üretilerek her bir örnek için 667 tane özellik üretildiği belirtilmiştir. Her bir sinyal normalize edilerek standartlaştırılmıştır (Hassine, 2024a; Hassine, 2024b).

2.2. k-En Yakın Komşuluk Algoritması

k-en yakın komşuluk algoritması, yaygın kullanılan parametrik olmayan bir sınıflandırma algoritmasıdır. Denetimli sınıflandırma algoritması olduğundan veriden eğitim ve test kümeleri seçilir. Bu çalışmada her bir sınıftan 1/3 oranında veri test kümesi ve diğerleri eğitim kümesi olacak şekilde rastgele seçilmiştir. Seçilmemiş özelliklerden sınıflandırma yapmak için $k=7$ ve seçilmiş özelliklerle sınıflandırma yapılırken $k=3$ deneysel olarak kaba kuvvetle seçilmiştir. Kullanılan uzaklık ölçütü öklit mesafesidir. Özellikler, min-max normalizasyonuna tabi tutulmuştur. Sınıflandırıcının hata oranı Eşitlik 1'deki gibi hesaplanmıştır.

$$error = 1 - \frac{\text{doğru sınıflandırılmış test örnek sayısı}}{\text{toplam test örnek sayısı}} \quad (1)$$

2.3. Amaç Fonksiyonu

Amaç fonksiyonu meta-sezgisel algoritmaların optimize etmeye çalıştığı fonksiyondur. Arama uzayında belirli kısıtlar altında optimum noktaların bulunmasında kullanılır. Çalışmada arama uzayının boyut sayısı, eğitim verisinin toplam özellik sayısı olarak belirlenmiştir. Özellik seçimi probleminde çözüm kümesinin her bir uygunluk değeri, veri setindeki bir özelliğin sınıflandırmada kullanılıp kullanılmayacağını belirtir. Özellik seçimi için verilen Eşitlik 2'de, eşik değeri kısıtları altında özellikleri seçilir. Eğer çözümdeki bir değer belirlenen eşikten daha büyükse özellik sınıflandırma için seçilir. Eşikten küçük değerlerde, ilgili özellik sınıflandırılmaya dahil edilmez. Eşitlik 2'de ayrıca, sınıflandırma hata oranı da optimize edilmeye çalışılmıştır. Her iki amaç belli oranda birleştirilerek maliyeti hesaplanmıştır.

$$cost(x) = \alpha \times error + (1 - \alpha) \times \frac{\sum_{i=1}^d s_i}{d} \quad (2)$$

$$\begin{cases} s_i = 1, & x_i \geq threshold \\ s_i = 0, & x_i < threshold \end{cases}$$

Burada α , katsayı; s_i , $threshold$ eşik değerine göre atanan seçim değerini; d , özellik boyutunu; $error$, sınıflandırma hata oranını; x_i , i . özellik vektörünü ifade eder. Çalışmada, deneysel olarak α katsayısı 0,8 ve $threshold=0,9$ olarak alınmıştır. Tüm optimizasyon algoritmaları için arama uzayının alt sınırı 0, üst sınırı 1 olarak belirlenmiştir. α katsayısı büyüdükçe hata daha çok optimize edilir ve $threshold$ büyüdükçe daha fazla özellik seçilebilir.

2.4. Gri Kurt Optimizasyon Algoritması

Gri kurt optimizasyonu (grey wolf optimization, GWO), Mirjalili ve ark. (2014) tarafından 2014'te geliştirilmiştir. GWO algoritması gri kurtların (canis lupus) liderlik ve av arama davranışlarından esinlenilerek geliştirilen bir sürü tabanlı meta-sezgisel optimizasyon algoritmasıdır.

Algoritmada, liderlik hiyerarşisi dört kurt tipiyle belirlenir. Bunlar hiyerarşinin en tepesinden aşağıya doğru alfa (α), beta (β), delta (δ) ve omega (ω) kurtlarıdır. GWO'da en iyi çözüm alfa (α) olarak adlandırılır. Sonraki en iyi çözümler ise sırasıyla beta (β) ve delta (δ) çözümleridir. Geriye kalan omega (ω) kurtlar ise aday çözümler olarak değerlendirilir. GWO algoritması aşamaları sırasıyla; av arama, avı kuşatma ve ava saldırma şeklindedir (Das ve Das, 2020). Gri kurtlar öncelikle avlarına ait yerleri belirler ve alfa kurt öncülüğünde kuşatma yapılır. Diğer kurtlar ise konumlarını hiyerarşik sıraya göre güncelleyerek en iyi çözüme ulaşmaya çalışırlar (Wang and Li, 2019).

$$D = |C * X_p(t) - X(t)| \quad (3)$$

$$X(t + 1) = |X_p(t) - A.D| \quad (4)$$

GWO algoritmasında, 3 ve 4 eşitlikleri avın çevrenmesini yani avlanma aşamasını ifade eder. Eşitliklerde, t iterasyon sayısı, X_p avın konumu, X gri kurt bireyinin konumu için kullanılır. A ve C katsayıları eşitlik 5 ve 6'daki gibi hesaplanır. Eşitlik 5 ve 6'da, r_1 ve r_2 [0,1] arasında rastgele reel değerler alır. α , iterasyona bağlı olarak "2"den "0" doğru doğrusal olarak azalan bir katsayıdır. i . iterasyondaki α , $\alpha_i = 2 - i * \left(\frac{2}{\text{iterasyon_sayısı}}\right)$ şeklinde hesaplanabilir.

$$A = 2\alpha r_1 - \alpha \quad (5)$$

$$C = 2r_2 \quad (6)$$

GWO algoritması iklendirmesinde, bireylerin dağılımı rastgele olup sonraki aşamalarda her bir kurt için uygunluk değeri ayrı ayrı hesaplanır. En iyi uygunluk değerine sahip konumlardaki kurtlara, sırasıyla alfa, beta ve delta kurtlar olarak atama yapılır. Alfa, beta ve delta kurtlarının konumları, eşitlik 3'e göre her adımda güncellenir. Bu güncellemeden sonra alfa, beta ve delta kurtlarının sırası değişebilir. Avın bir sonraki konumu (X_p), alfa, beta ve delta kurtlarının konumlarının aritmetik ortalaması olarak alınır.

Ava saldırı işlemine, A değerine göre karar verilir. A değeri 1'den büyükse gri kurtlar avdan uzaklaşır ve daha uygun bir av aramaya başlarlar. Eğer 1'den küçükse gri kurtlar ava saldırmaya zorlanır. Böylece yerel minimumlara takılmalar engellenir. GWO algoritmasında avlanma işlemine durdurma kriteri sağlanıncaya kadar veya belirlenen iterasyon sayısına ulaşıncaya kadar devam edilir.

2.5. Balina Optimizasyonu Algoritması

Balina optimizasyonu algoritması (whale optimization algorithm, WOA) kambur balinaların "kabarık-ağı" adı verilen avlanma tekniğinden ilham alan sürü tabanlı bir optimizasyon algoritmasıdır (Mirjalili ve Lewis, 2016; Aljarah ve ark., 2018). Bu balinalar avlarının yerini belirlemek için öncelikle araştırma yaparlar daha sonra daralan çemberler şeklinde hareket ederek kuşatma ya da sarmal konum güncelleme adlı iki saldırı mekanizmasından biri ile hedefe saldırırlar.

Optimizasyonda bu aşamalar sırasıyla keşif ve sömürü olarak adlandırılır. Başlangıçta algoritma mevcut en iyi aday çözüme göre konumlarını güncellerken, sonraki aşamalarda, diğer balinaların konumları en iyi çözüme göre güncellenir.

Balinalar keşif aşamasında, birbirlerinin konumlarına göre rastgele avlarını ararlar. Küresel bir araştırma yapabilmek için arama ajanları, rastgele seçilen bir referans balinadan uzaklaşmaya zorlanır. Avın çevresini sarma işlemi, 7. ve 8. eşitliklerle yapılır.

$$D = |C * X^*(t) - X(t)| \quad (7)$$

$$X(t + 1) = |X_p(t) - A.D| \quad (8)$$

Eşitlik 7 ve 8'de; t , mevcut iterasyon adımını; A ve C yakınsama vektörlerini; X^* en iyi çözüme en yakın çözüm vektörünü ifade eder. A ve C sırasıyla eşitlik 9 ve 10 ile bulunur. Eşitlik 9 ve 10'da r rastgele bir vektörü ve α iterasyon sayısına bağlı olarak "2" 'den "0" doğru doğrusal, gri kurt optimizasyonu algoritmasında verildiği gibi hesaplanan, azalan bir vektörü ifade eder.

$$A = 2\alpha * r - \alpha \quad (9)$$

$$C = 2 * r \quad (10)$$

Ava doğru hareket etme işlemi, balinanın ava doğru ilerlerken avın etrafındaki çemberi daraltma ve spiral hareket oluşturma şeklinde ele alınır. Çember daraltması 9 eşitliğindeki α 'nın küçültülmesi ile sağlanır. Spiral hareket en iyi arama ajanına göre yapılır. En iyi arama ajanı ile diğer arama ajanı arasındaki ilişki eşitlik 11 ile hesaplanır.

$$X(t + 1) = D' * e^{bl} * \cos(2\pi l) + X(t) \quad (11)$$

$$D' = X^*(t) - X(t) \quad (12)$$

Eşitlik 11'de, b , logaritmik spiral sabiti; l , [-1,1] arasında rastgele bir reel sayıdır. Algoritmada spiral hareket veya çember hareketten hangisinin yapılacağına %50 olasılıkla karar verilir. Bu olasılığa göre eşitlik 8 veya eşitlik 11 hareketleri yapılır.

Avı arama işleminde, arama ajanının konumu güncellenirken o zamana kadar bulunmuş en iyi arama ajanı yerine rastgele seçilen bir arama ajanı kullanılır. Bu taktik yerel minimumlara takılmayı önleme amaçlıdır. Eşitlik 13 ve 14'de X_{rand} rastgele seçilen arama ajanı olarak ifade edilmiştir.

$$D' = C * X_{rand} - X \quad (13)$$

$$X(t + 1) = X_{rand} - A.D \quad (14)$$

$|A| > 1$ olduğu durumlarda en iyi arama ajanından daha uzak bir konum seçilmiş olur. Bu durumda global arama yapılmış olur.

2.6. Harris Şahini Optimizasyonu Algoritması

Harris şahini optimizasyonu (harris hawks optimization, HHO), kara şahinlerinin avlanma davranışını simüle eden popülasyon tabanlı, gradyansız bir algoritmadır (Heidari ve ark., 2019). Kara şahinler, özellikle tavşan avlama sürecinde sürü olarak hareket ederler. Sürünün bir lideri

bulunur. Lider ve sürünün diğer üyeleri öncelikle av tespiti için keşif uçuşları yapar (keşif aşaması). Keşif aşamasında avın tespit edilmesiyle avlanma sürecine geçilir (sömürüye geçiş aşaması). Kara şahinler, avlarına dört kovalama-saldırma taktiğinden birini kullanarak saldırır (sömürü aşaması). Bu taktikler; yumuşak kuşatma, sert kuşatma, ilerlemeci hızlı dalışlar ile yumuşak kuşatma ve ilerlemeci hızlı dalışlar ile sert kuşatmadır.

HHO algoritmasında, arama davranışı genel keşif aşaması olarak kabul edilir. Eşitlik 15'de keşif stratejisi verilmiştir.

$$x(t+1) = \begin{cases} x_{rand}(t) - r_1 |x_{rand} - 2r_2 x(t)| & , q \geq 0,5 \\ (x_{rabbit}(t) - x_m(t)) - r_3(LB + r_4(UB - LB)) & , q < 0,5 \end{cases} \quad (15)$$

Eşitlik 15'de, $x(t+1)$, harris şahinlerinin her bir iterasyondaki konum vektörleri, $x_{rabbit}(t)$, avın konum vektörü, $x(t)$, harris şahininin mevcut konumu vektörünü gösterir. r_1, r_2, r_3, r_4 ve q değerleri, $[0,1]$ aralığında rastgele reel değerler alır. LB ve UB sırasıyla popülasyonun alt ve üst sınırlarını belirler. $x_{rand}(t)$ rastgele seçilen bir şahindir. $x_m(t)$, t . anındaki şahin popülasyonunun konumlarının ortalama değeridir.

Harris şahini keşif işlemini tamamladıktan sonra avın enerjisine bağlı olarak farklı saldırı biçimleri geliştirebilir. Avın enerjisi eşitlik 16'da verilmiştir.

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (16)$$

Eşitlik 16'da, $[-1,1]$ aralığında değer alan E_0 avın başlangıç enerjisini, T maksimum yineleme sayısını, t mevcut iterasyonu gösterir.

HHO'da sömürü aşaması, $[0,1]$ arasında değer alan, avın kaçıp kaçamayacağına karar veren r rastgele sayısı ve E 'nin değerine göre 4 farklı strateji ile sömürü aşaması gerçekleştirilir. $r \geq 0.5$ ve $|E| \leq 0.5$ durumu yumuşak kuşatma ve $r \geq 0.5$ ve $|E| \leq 0.5$ durumu sert kuşatma stratejisinin geliştirildiği durumlardır. Yumuşak kuşatma 17 ve 18 eşitlikleri ile yapılır. Eşitlik 19 ile sert kuşatma gerçekleştirilir.

$$x(t+1) = \Delta x(t) - E |J x_{rabbit}(t) - x(t)| \quad (17)$$

$$\Delta x(t) = x_{rabbit}(t) - x(t) \quad (18)$$

$$x(t+1) = x_{rabbit}(t) - E |\Delta x(t)| \quad (19)$$

Eşitlik 17-19'da, $\Delta x(t)$ t . anındaki konum ile avın konumu arasındaki mesafeyi, J av hareketini benzetmek için her iterasyonda değişen bir değeri ifade eder.

Diğer bir strateji aşamalı hızlı dalışlarla yumuşak kuşatma olarak adlandırılır. Yumuşak kuşatma, $r < 0.5$ ve $|E| \geq 0.5$ olduğunda gerçekleşir. Bu aşamada av kaçmak için yeterli enerjiye sahiptir. Bu strateji iki adımda gerçekleşir. İlk adımda 17 eşitliği kullanılır ve konum iyileşmezse ikinci adımla konum güncellenir. İkinci adımda eşitlik 20 ve 21 uygulanır.

$$z = \Delta x_i(t) - E |J x_{rabbit} - x_i(t)| + s \text{levy}(D) \quad (20)$$

$$\text{levy}(x) = 0.01 \frac{u \sigma}{|\mu|^{\frac{1}{\beta}}}, \quad \sigma = \left(\frac{|(1 + \beta) \sin(\frac{\pi\beta}{2})|}{\left| \left(\frac{1 + \beta}{2} \right) 2^{\frac{\beta-1}{2}} \right|} \right)^{\frac{1}{\beta}} \quad (21)$$

Eşitlik 20 ve 21'de u ve v , $[0,1]$ aralığında rastgele değerler alır, β değeri 1,5 olan bir sabit ve D problemin boyutudur. Son olarak yumuşak kuşatma 17 eşitliğine Y dersek, bu stratejide karar, eşitlik 22'ye göre verilir. Burada $s \in \mathbb{R}^D$ olup D boyutunda rastgele bir vektördür.

$$x(t+1) = \begin{cases} Y & f(Y) < f(x(t)) \text{ ise} \\ Z & f(Z) < f(x(t)) \text{ ise} \end{cases} \quad (22)$$

Son strateji ilerlemeli hızlı dalışlar ile sert kuşatmadır ki bu durumda av kaçmak için yeterli enerjiye sahip değildir. Bu durumda eşitlik 23-25 kullanılır.

$$x(t+1) = \begin{cases} y & f(y) < f(x(t)) \text{ ise} \\ z & f(z) < f(x(t)) \text{ ise} \end{cases} \quad (23)$$

$$y = x_{rabbit} - E |J x_{rabbit} - x_{mean}(t)| \quad (24)$$

$$z = y + s \text{levy}(D) \quad (25)$$

3. Bulgular ve Tartışma

Deneylerde, tüm meta-sezgisel optimizasyon algoritmalarında popülasyon sayısı 50 ve iterasyon sayısı 50 olarak alınmıştır. Her bir algoritma 30 kere koşturulmuştur. Optimizasyon öncesi k -EYK ile yapılan sınıflandırma doğruluk performansı %60,05 olarak elde edilmiştir. Çalışmalar, i7 işlemcili ve 8 GB belleğe sahip bilgisayarda Matlab 2017 ile yapılmıştır.

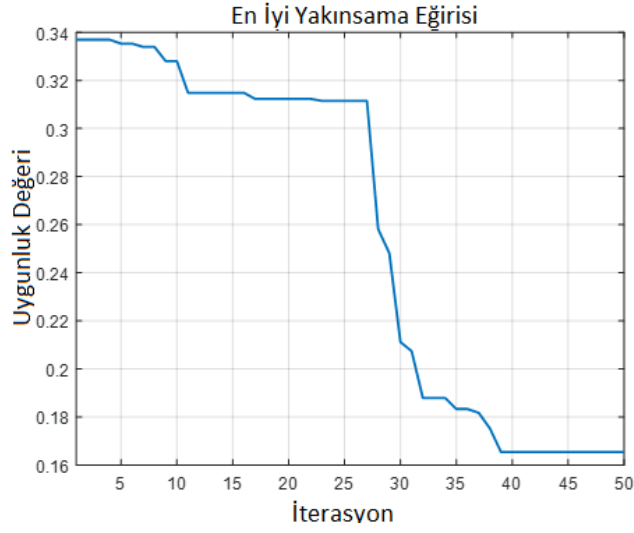
Tablo 1'de; $ortA$ tekrarlı koşturulmaların doğruluk ortalamasının yüzdelik (%) değeridir. $maxA$ erişilen en yüksek ve $minA$ en düşük doğruluk yüzdesidir. Koşturularda elde edilen doğrulukların standart sapmaları sda sütununda verilmiştir. $CPUs$ ortalama işlem süresini saniye cinsinden ifade eder. Koşturularda elde edilen en küçük uygunluk değeri (fitness) $minF$ ile gösterilmiştir. Çalışmada elde edilen en küçük özellik sayısı $minFM$ sütununda verilmiştir.

Tablo 1'de algoritmaların 50 iterasyon ile 30 kez tekrar edildiğinde elde edilen sonuçların ortalamaları verilmiştir. Tablodan 10 özellik seçimi ile GWO algoritmasının en yüksek başarıyı yakaladığı görülmektedir. Diğer yandan doğruluk ortalaması en yüksek HHO algoritmasının doğruluk standart sapmasına göre daha kararlı sonuçlar elde ettiği gözlemlenmektedir. Özellik sayısını 667'den 5'e kadar azaltan WOA ve HHO algoritmaları olmuştur. Algoritmalar birbirine yakın fitness değerleri üretmiştir.


Şekil 1-3'te sırasıyla gri kurt, balina ve harris şahini algoritmalarının en iyi yakınsama eğrilerinden örnekler verilmiştir. Şekillerde, gri kurt algoritmasının 40, balina optimizasyonu algoritmasının 5 iterasyonda yakınsamayı sağladığı gözükmektedir. Harris şahini algoritmasının yakınsaması 50 iterasyondan daha fazlasına ihtiyaç duyduğu söylenebilir. Ancak mevcut yakınsamada, diğer algoritmalarından daha iyi sonuçlar elde edebilmiştir.

Tablo 1. Meta-sezgisel algoritmaların başarımları


Algoritma	orta	maxA	minA	sdA	CPUs	minF	minFM
GWO	67,0862	80,164	62,107	0,063542	86,487	0,16535	10
WOA	71,9015	79,207	61,286	0,042895	67,450	0,16968	5
HHO	74,0173	79,343	64,432	0,036386	82,955	0,16859	5



Şekil 1. Gri kurt optimizasyonu algoritmasının en iyi yakınsama eğrisi.



Şekil 2. Balina optimizasyonu algoritmasının en iyi yakınsama eğrisi.



Şekil 3. Harris Şahinleri Optimizasyonunun en iyi yakınsama eğrisi.

4. Sonuç

Bu çalışmada, meta-sezgisel algoritmaların özellik seçiminde kullanılarak sınıflandırma başarısının artırılmasına çalışılmıştır. Yapılan çalışmalar sonucunda epilepsi tanısı için kullanılan verisetindeki tüm özelliklerin sınıflandırılmada kullanılmasına gerek olmadığı anlaşılmaktadır. Bu özelliklerin meta-sezgisel yöntemlerle seçilmesi sonucunda doğruluk performansı artış gözlemlenmiştir. Tablo 1’de görüldüğü gibi, kullanılan algoritmalar kendi içinde değerlendirildiğinde, ortalama doğruluk performansı, standart sapma ve özellik sayısı bakımından HHO algoritmasının diğerlerine göre daha başarılı performans sergilemiş olarak kabul edilebilir.

Bu çalışmada, epileptik sinyallerin sınıflandırılmasına çalışılmış ve 5 özellik ile en yakın komşuluk algoritmasının sınıflandırma performansında artış sağladığı gözlemlenmiştir. EEG sinyallerinin başka tanı veya eylemler için kullanılmasında farklı özelliklerin seçilmesi gerekebilir. Sonuç olarak çalışma EEG sinyallerinden özellik seçiminin meta-sezgisel algoritmalarla yapılabileceğini göstermektedir. Yine EEG sinyallerinin yorumlanmasında, anomali tespiti için normal sinyaller meta-sezgisel olarak elimine edilerek uzmanlara daha temiz veri sunulabilir. Çalışmada, meta-sezgisel yöntemlerin başarısını test amacıyla 3 tane meta-sezgisel algoritma kullanılmıştır. EEG sinyalleri için daha büyük verisetleri ile pek çok algoritma yarıştırlıp en başarılı algoritmalar belirlenebilir.

Katkı Oranı Beyanı

Yazar(lar)ın katkı yüzdesi aşağıda verilmiştir. Tüm yazarlar makaleyi incelemiş ve onaylamıştır.

	E.G.	T.Y.
K	60	40
T	60	40
Y	80	20
VTI	20	80
VAY	60	40
KT	20	80
YZ	70	30
KI	80	20
GR	80	20
PY	70	30

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu araştırmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

- Abdel-Basset M, Sallam KM, Mohamed R, Elgendi I, Munasinghe K, Elkomy OM. 2021. An improved binary grey-wolf optimizer with simulated annealing for feature selection. *IEEE Access*, 9: 139792-139822.
<https://doi.org/10.1109/ACCESS.2021.3117853>.
- Acharya UR, Sree SV, Swapna G, Martis RJ, Suri JS. 2013. Automated EEG analysis of epilepsy: A Review. *Knowledge Based Syst*, 45: 147-165.
<https://doi.org/10.1016/j.knosys.2013.02.014>.
- Aljarah I, Faris H, Mirjalili S. 2018. Optimizing connection weights in neural networks using the whale optimization

- algorithm. *Soft Comput*, 22(1): 1-15. <https://doi.org/10.1007/s00500-016-2442-1>.
- Al-Tashi Q, Abdulkadir SJ, Rais HM, Mirjalili S, Alhussian H, Ragab MG, Alqushaibi A. 2020. Binary multi-objective grey wolf optimizer for feature selection in classification. *IEEE Access*, 8: 106247-106263. <https://doi.org/10.1109/ACCESS.2020.3000040>.
- Al-Tashi Q, Kadir SJA, Rais HM, Mirjalili S, Alhussian H. 2019. Binary optimization using hybrid grey wolf optimization for feature selection. *IEEE Access*, 7: 39496-39508. <https://doi.org/10.1109/ACCESS.2019.2906757>.
- Claassen J, Hirsch LJ, Mayer SA. 2003. Treatment of status epilepticus: a survey of neurologists. *J Neurol Sci*, 211(1-2): 37-41. [https://doi.org/10.1016/s0022-510x\(03\)00036-4](https://doi.org/10.1016/s0022-510x(03)00036-4).
- Das P, Das A. 2020. Adaptive gabor filtering using grey wolf optimization for enhancement of brain MRI. *IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE)*, December 26-27, Naya Raipur, India, pp: 356-359. <https://doi.org/10.1109/WIECON-ECE52138.2020.9397926>.
- Elgamal ZM, Yasin NBM, Tubishat M, Alswaiti M, Mirjalili S. 2020. An improved harris hawks optimization algorithm with simulated annealing for feature selection in the medical field. *IEEE Access*, 8: 186638-186652. <https://doi.org/10.1109/ACCESS.2020.3029728>.
- Hassine OB. 2024a. Epilepsy Detection Using EEG Signals, Datasets. URL: <https://www.kaggle.com/datasets/oussamabenhassine/epilepsy-detection-using-eeeg-signals> (erişim tarihi: Nisan, 25, 2024).
- Hassine OB. 2024b. Epilepsy Detection Using EEG Signals, Project. URL: <https://github.com/oussamabenhassine/Epilepsy-Detection-using-EEG-signlas/> (erişim tarihi: Nisan, 25, 2024).
- Heidari AA, Mirjalili S, Faris H, Aljarah I, Mafarja M, Chen H. 2019. Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97: 849-872. <https://doi.org/10.1016/j.future.2019.02.028>.
- Hussien AG, Hassanien AE, Houssein EH, Bhattacharyya S, Amin M. 2019. S-shaped binary whale optimization algorithm for feature selection. In: *Recent Trends in Signal and Image Processing. Advances in Intelligent Systems and Computing*, vol 727. Springer, May 10, Singapore. https://doi.org/10.1007/978-981-10-8863-6_9.
- Hussien AG, Oliva D, Houssein EH, Juan AA, Yu X. 2020. Binary whale optimization algorithm for dimensionality reduction. *Mathematics*, 8(10): 1-24. <https://doi.org/10.3390/math8101821>.
- Iasemidis LD, Shiau DS, Chaovalitwongse W, Sackellares JC, Pardalos PM, Principe JC, Carney PR, Prasad A, Veeram B. 2003. Adaptive epileptic seizure prediction system. *IEEE Transact Biomed Eng*, 50(5): 616-627. <https://doi.org/10.1109/TBME.2003.810689>.
- Kumar SJ, Bhuvanewari P. 2012. Analysis of Electroencephalography (EEG) Signals and Its Categorization. *Procedia Eng*, 38: 2525-2536. <https://doi.org/10.1016/j.proeng.2012.06.298>.
- Mirjalili S, Lewis A. 2016. The whale optimization algorithm. *Adv Eng Software*, 95: 51-67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>.
- Mirjalili S, Mirjalili SM, Lewis A. 2014. Grey wolf optimizer. *Adv Eng Software*, 69: 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>.
- Nadimi-Shahraki MH, Zamani H, Mirjalili S. 2022. Enhanced whale optimization algorithm for medical feature selection: A COVID-19 case study. *Comput Biol Medic*, 148: 105858. <https://doi.org/10.1016/j.compbiomed.2022.105858>.
- Sayed GI, Darwish A, Hassanien AE. 2020. Binary whale optimization algorithm and binary moth flame optimization with clustering algorithms for clinical breast cancer diagnoses. *J Classification*, 37(1): 66-96. <https://doi.org/10.1007/s00357-018-9297-3>.
- Thaher T, Heidari AA, Mafarja M, Dong JS, Mirjalili S. 2020. Binary Harris Hawks optimizer for high-dimensional, low sample size feature selection. In *Evolutionary machine learning techniques*. Springer, Singapore, pp: 251-272. https://doi.org/10.1007/978-981-32-9990-0_12.
- Vijayanand R, Devaraj D. 2020. A novel feature selection method using whale optimization algorithm and genetic operators for intrusion detection system in wireless mesh network. *IEEE Access*, 8: 56847-56854. <https://doi.org/10.1109/ACCESS.2020.2978035>.
- Wang JS, Li SX. 2019. An improved grey wolf optimizer based on differential evolution and elimination mechanism. *Sci Rep*, 9(1): 1-21. <https://doi.org/10.1038/s41598-019-43546-3>.
- Zhang Y, Liu R, Wang X, Chen H, Li C. 2021. Boosted binary Harris hawks optimizer and feature selection. *Eng Comput*, 37(4): 3741-3770. <https://doi.org/10.1007/s00366-020-01028-5>.