

# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### A New Artificial Intelligence Supported Approach to Diagnosis and Prediction of Psoriasis

Mehmet Akif Bülbül<sup>\*a</sup>

Submitted: 23.03.2024 Revised: 06.04.2024 Accepted: 26.04.2024 doi:10.30855/gmbd.0705A06

#### ABSTRACT

**Keywords:** Firefly optimization algorithm, stacked auto-encoder, softmax classifier, decision support system

<sup>a\*</sup> Kayseri University,  
Faculty of Engineering, Architecture and  
Design,  
Dept. of Software Engineering  
38280 - Kayseri, Türkiye  
Orcid: 0000-0003-4165-0512  
e mail: makifbulbul@kayseri.edu.tr

<sup>\*</sup>Corresponding author:  
makifbulbul@kayseri.edu.tr

Early diagnosis and prediction of psoriasis is crucial to control disease progression, alleviate symptoms and reduce the risk of complications. Diagnosis in the early stages helps to determine the appropriate treatment plan and improve the patient's quality of life. The aim of this study is to enable early diagnosis of psoriasis. For this purpose, a hybrid architecture was created using a stacked auto-encoder, softmax classifier and Firefly Optimization Algorithm. With the created architecture, the architectural parameters of the stacked autocoder and softmax classifier hybrid structure aimed to be created for psoriasis diagnosis and all hyperparameters within the architecture were optimized. The model was implemented on the "Dermatology" dataset in the UCI data warehouse. In addition, machine learning methods such as K-Nearest Neighbor algorithm, Support Vector Machine and Decision Trees, which are frequently used in the literature, were also applied on the same dataset. The findings obtained from the experimental studies are presented in a controversial manner. The findings show that the proposed hybrid architecture achieves better results than other machine learning methods. At the same time, the model optimized and presented with the hybrid architecture can be used as an alternative method in patient decision support systems.

### Sedef Hastalığının Tanı ve Tahmininde Yapay Zekâ Destekli Yeni Bir Yaklaşım

#### ÖZ

Sedef hastalığının erken tanı ve tahmini, hastalığın ilerlemesini kontrol altına almak, semptomları hafifletmek ve komplikasyon riskini azaltmak açısından son derece önemlidir. Erken aşamalarda tanı konulması, uygun tedavi planının belirlenmesine ve hastanın yaşam kalitesini artırmaya yardımcı olur. Bu çalışmanın amacı, sedef hastalığının erkenden teşhis edilebilmesini sağlamaktır. Bu amaç doğrultusunda yığılmış oto-kodlayıcı, softmax sınıflandırıcı ve Ateş Böceği Optimizasyon Algoritması kullanılarak hibrit bir mimari oluşturulmuştur. Oluşturulan mimari ile sedef hastalığı teşhisi için oluşturulması hedeflenen yığılmış oto-kodlayıcı ve softmax sınıflandırıcı hibrit yapısının mimari parametreleri ile mimari içerisinde bulunan bütün hiperparametreler optimize edilmiştir. Model UCI veri deposunda bulunan "Dermatoloji" veri seti üzerinde uygulanmıştır. Bunun yanında aynı veri seti üzerinde literatürde sıkça kullanılan makine öğrenme yöntemleri olan K-En yakın komşu algoritması, Destek Vektör Makinası ve Karar Ağaçları metotları da uygulanmıştır. Deneysel çalışmalardan elde edilen bulgular tartışmalı bir şekilde sunulmuştur. Elde edilen bulgular önerilen hibrit mimarinin diğer makine öğrenme yöntemlerine göre daha başarılı sonuçlar elde ettiğini göstermiştir. Aynı zamanda hibrit mimari ile optimize edilen ve sunulan model hasta karar destek sistemlerinde alternatif bir yöntem olarak da kullanılabilir.

**Anahtar Kelimeler:** Ateş böceği optimizasyon algoritması, yığılmış oto-kodlayıcı, softmax sınıflandırıcı, karar destek sistemi

## 1. Giriş (Introduction)

Sedef hastalığı, kronik inflamatuvar bir deri hastalığı olup milyonlarca kişiyi etkilemektedir [1]. Sedef hastalığı kardiyometabolik hastalıklar ve depresyon gibi bir dizi eşlik eden hastalıklarla da ilişkilidir [2]. Sedef hastalığının çeşitli komplikasyonları yüksektir. Aynı zamanda ölüm için bağımsız bir risk faktörünü temsil ettiği ve patolojisini karmaşıktırdığı ortaya konulmuştur [3]. Bu sebeple hastalığın erken tanı ve teşhisi büyük önem arz etmektedir.

Gelişen yeni nesil teknolojiler ile birlikte gün geçtikçe yaygınlaşan yapay zekâ yöntemlerinin kullanımı tıp alanında da artmaktadır [4,5]. Literatürde deri hastalıklarıyla ilgili yapılan çalışmalara bakıldığında Raj ve arkadaşları [6], 2D RGB görüntülerden sedef hastalığı alanının ve şiddetinin objektif tahmini için birçok geleneksel ve makine öğrenimi tabanlı çalışma önermişlerdir. Yapılan çalışmada yerel özellik ayıklama için hafif bir ağ benimsenmiş ve bu ağı genel özellikleri öğrenmek için bir vizyon transformatörü ile entegre ederek hibrit bir model oluşturulmuştur. 212 sedef hastasının farklı vücut bölgelerinden 1018 fotoğraf görüntüsü üzerinde yapılan deneysel çalışmalarda başarılı sonuçlar elde edilmiştir.

Rashid ve arkadaşları [7], sedef hastalığının tiplerinin otomatik tespiti ve sınıflandırılması üzerine bir çalışma gerçekleştirmiştir. Gerçekleştirilen çalışmada derin sinir ağları kullanılmıştır. GoogLeNet, InceptionV3 ve VGG-19 gibi önceden eğitilmiş makine öğrenme modellerinin de kullanıldığı çalışmada elde edilen bulgular önerilen yöntem ile elde edilen bulgularla karşılaştırmalı bir şekilde sunulmuştur. Önerilen derin sinir ağı ile elde edilen sonuçlar çalışmada kullanılan diğer makine öğrenme yöntemlerine göre daha başarılı sonuçlar ortaya koymuştur.

Shrivastava ve arkadaşları [8], yapmış oldukları bir çalışmada sedef hastalığının sınıflandırılmasında makine öğrenimi yöntemleri kullanmışlardır. Çalışmada 848 adet görüntüden oluşan veri seti üzerinde sağlıklı, hafif, orta, şiddetli ve çok şiddetli olmak üzere beş şiddet derecesine sahip çok sınıflı bir sınıflandırma gerçekleştirilmiştir. Destek Vektör Makineleri (DVM), Karar Ağacı (KA), Temel Bileşen Analizi ve Fisher Diskriminant Oranı kullanılan çalışmada Fisher Diskriminant Oranı ve DVM ile başarılı sonuçlar elde edilmiştir.

Vishwakarma ve arkadaşları [9], yapmış oldukları bir çalışmada sedef hastalığının tespiti için evrişimli sinir ağı ile görüntü transformatörü kodlayıcıyı birleştirmişlerdir. Çalışmada sunulan model içerisinde bulunan hiperparametreler Tavşan Optimizasyon Algoritması ile optimize edilmiştir. Önerilen model ile sedef hastalığının tespitinde başarılı sonuçlar elde edilmiştir.

Dash ve arkadaşları [10], otomatik sedef hastalığı cilt lezyonu segmentasyonu gerçekleştirmek için modifiye edilmiş U-Net tabanlı tam evrişimli ağ kullanmışlardır. 29 katmanlı derin tamamen evrişimli bir ağdan oluşan model 1026 sedef hastasından toplanan 5241 sedef lezyonu görüntüsü üzerinde test edilmiştir. Yapılan deneysel çalışmalar sonucunda yüksek başarı metrikleri elde edilmiştir.

Juang ve Wu [11], yapmış oldukları çalışmada sedef hastalığını tanımlamak için k-ortalama kümeleme yöntemi kullanmışlardır. Çalışmada görüntüler üzerine sırasıyla k-ortalama kümeleme, gri seviye, medyan filtreleme, ikili görüntüleme, sobel kenar süreci ve morfolojik rekonstrüksiyon uygulanmıştır. Elde edilen bulgular sedef hastalığının boyutunu ve bölgesini tam olarak ayırt etmek için sunulan yöntemin başarılı sonuçlar ürettiğini göstermektedir.

Yapay zekâ yöntemlerinin yüksek başarı oranları elde etmesi, erken tanı ve teşhis ile hastaların tedavi süreçlerini hızlandırması bu alandaki trendi oldukça artırmaktadır. Erken tanı ve tedavi hastalıkların yol açmış olduğu olumsuz etkileri azaltmada oldukça önemlidir. Literatürde yapılan çalışmalarda farklı makine öğrenimi yöntemleri kullanılmaktadır. Kullanılan yöntemlerde sunulan modeller içerisinde birçok hiperparametre bulunmaktadır. Modeller içerisindeki bu hiperparametrelerdeki değişiklik modelin


performansını doğrudan etkilemektedir [12,13]. Probleme özgü hiperparametre belirlemek modelin performans açısından büyük önem arz etmektedir [14].

Bu çalışmada, sedef hastalığının tanı ve teşhisi için hibrit bir mimari önerilmektedir. Mimari içerisinde yığılmış oto-kodlayıcı, softmax sınıflandırıcı ve Ateş Böceği Optimizasyon Algoritması kullanılmıştır. Oluşturulan hibrit mimari UCI veri deposunda halka açık bulunan “Dermatoloji” veri seti üzerinde uygulanmıştır. Çalışmada aynı zamanda literatürde sıkça kullanılan makine öğrenmesi yöntemlerinden DVM, KA ve K-en Yakın Komşu metotları da aynı veri seti üzerinde çalıştırılmıştır. Yapılan deneysel çalışmalar sonucu elde edilen bulgular tartışmalı bir şekilde sunulmuştur.

## 2. Materyal ve Metot (Material and Method)

### 2.1. Destek Vektör Makineleri (Support vector machines)


DVM, özellikle sınıflandırma ve regresyon problemlerinde kullanılan güçlü bir makine öğrenimi algoritmasıdır [15]. Temel amacı, veri noktalarını sınıflar arasında bir karar sınırıyla ayırmaktır. DVM, veri noktalarını çok boyutlu uzayda temsil eder ve bu uzayda en uygun ayrımı yapacak hiper düzlemleri bulur. Bu hiper düzlem, sınıflar arasındaki marjinal boşluğu maksimize eder, yani her iki sınıfa ait veri noktalarını en iyi şekilde ayırmaya çalışır [16]. Örnek bir SVM yapısı Şekil 1’de gösterilmektedir.



Şekil 1. DVM yapısı (SVM structure)

### 2.2. K-En yakın Komşu Algoritması (K-Nearest Neighbor Algorithm)


K-En Yakın Komşu (K Nearest Neighbour, KNN), basit ancak güçlü bir makine öğrenimi algoritmasıdır [17]. Temel prensibi, bir veri noktasını sınıflandırmak veya tahmin etmek için en yakın komşularının etiketlerini kullanmaktır. KNN, belirli bir veri noktasının etiketini belirlemek için, o noktaya en yakın olan k komşusunun etiketlerini dikkate alır ve bu komşuların çoğunluğuna göre karar verir [18]. Algoritma, veri noktalarının uzaklık ölçüsüne dayanır ve genellikle Öklid mesafesi kullanılır, ancak farklı uzaklık ölçüleri de tercih edilebilir. Örnek bir KNN yapısı Şekil 2’de gösterilmektedir.



Şekil 2. KNN yapısı (KNN structure)

### 2.3. Karar Ağaçları (Decision trees)

KA, karmaşık veri kümelerini basit karar yapısıyla temsil eden etkili bir makine öğrenimi yöntemidir [19]. Bu yöntem, veri özelliklerini dikkate alarak sıralı kararlarla sınıflandırma veya tahmin işlemi gerçekleştirir. Her bir düğüm, veri özelliklerine göre bölünmüş veri kümesini temsil eder. Ağaç yapısı, veri kümesini en iyi şekilde bölerek homojen alt gruplar oluşturmayı amaçlar [20]. Karar ağaçları, kolay anlaşılabilir bir yapıya sahiptir ve genellikle diğer makine öğrenimi yöntemleriyle birleştirilerek daha karmaşık modeller oluşturmak için de kullanılır. Örnek bir KA yapısı Şekil 3'de gösterilmektedir.



Şekil 3. KA yapısı (KA structure)

### 2.4. Ateş Böceği Optimizasyon Algoritması (Firefly Optimization Algorithm)

Ateş Böceği Algoritması (ABA), ateş böceklerinin iletişim ve çiftleşme davranışlarından esinlenerek tasarlanmıştır [21]. Temel prensibi, daha parlak olan böceklerin diğerlerini çekme eğilimi göstermesine dayanır. Algoritma, bir optimizasyon problemi için çözümleri ateş böcekleri olarak kabul eder ve bu çözümlerin parlaklık derecelerine göre hareket etmelerini sağlar. Daha parlak çözümler, daha iyi çözümler olduğu kabul edilir ve bu nedenle diğer çözümleri kendine doğru çekerler [22]. Ateş böceği algoritması, doğal paralelizm ve hızlı yakınsama özellikleri sayesinde birçok optimizasyon problemi için etkili bir çözüm sunar. ABA adımları şu şekildedir:

1. **Başlangıç Popülasyonu Oluşturma** : Başlangıçta rastgele bir ateş böceği popülasyonu oluşturulur. Her bir ateş böceği, problemin boyutuna uygun rastgele bir konumda yer alır.
2. **Aydınlatma Değerlerinin Hesaplanması** : Her bir ateş böceğinin parlaklık değeri, uygunluk fonksiyonu kullanılarak hesaplanır. Bu, problem bağlamına ve çözümün kalitesine bağlıdır. Daha parlak ateş böcekleri, daha iyi çözümlere işaret eder.

3. **Yenileme ve Hareket Etme** : Her bir ateş böceği, çevresindeki diğer ateş böceklerini çekecek şekilde hareket eder. Bu hareket, iki faktör arasındaki çekim kuvveti ve rastgele bir yön belirlenmesiyle gerçekleşir. Daha parlak olan ateş böcekleri, daha az parlak olanları kendilerine doğru çeker.
4. **Ateş Böceği Popülasyonunun Güncellenmesi** : Her bir ateş böceği, yeni pozisyonuna göre güncellenir. Eğer yeni konum, önceki konumdan daha iyi bir çözüm sunuyorsa, ateş böceği bu yeni konumu kabul eder.
5. **Sonlandırma Koşulunun Kontrol Edilmesi** : Belirlenen sonlandırma koşullarının sağlanıp sağlanmadığı kontrol edilir. Eğer koşullar sağlanırsa, algoritma sonlanır; aksi halde 2. Adıma dönlür.
6. **En İyi Çözümün Bulunması** : Algoritma sonlandığında, en iyi çözüm bulunur ve geri döndürülür.

ABA çözüm uzayı içerisinde oluşturulan rastgele ateş böcekleri en parlak ateş böceğine yönelim halindedirler. Bu parlaklık ateşböceklerinin arasındaki mesafeye göre değişmektedir. Ters kare yasasına göre hesaplanan ışık şiddeti Eşitlik 1' e göre belirlenir [23].

$$l(r) = l_s/r^2 \quad (1)$$

Eşitlikte  $l(r)$  ışık şiddetini,  $l_s$  ışık kaynak şiddetini ve  $r$  ise uzaklığı temsil etmektedir. Bir ortamda ışık yayılırken emilime uğrar. Emilim katsayısı( $\gamma$ ) hesaba katıldığında Eşitlik 2 elde edilir.

$$l(r) = l_0/e^{-\gamma r^2} \quad (2)$$

Burada  $l_0$  değeri başlangıç ışık şiddetini temsil etmektedir. Bir ateş böceğinin çekiciliği diğer ateşböceklerinin gördüğü ışık yoğunluğuyla orantılıdır. Bir ateş böceğinin çekiciliği Eşitlik 3' de sunulduğu gibi hesaplanmaktadır.

$$B(r) = B_0/e^{-\gamma r^2} \quad (3)$$

Burada  $B(r)$  ateş böceğinin çekiciliğini temsil etmektedir.  $B_0$ ,  $r = 0$  değerindeki çekicilik değerini temsil etmektedir.

Ateş böceklerinin arasındaki mesafe ise Eşitlik 4' de sunulduğu gibi hesaplanmaktadır.

$$r_{ij} = \left| |X_i - X_j| \right| = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (4)$$


Burada  $i$  ve  $j$  farklı ateş böceklerini  $X_i$  ve  $X_j$  ateş böceklerinin konumlarını  $r_{ij}$  ise bu konumdaki ateş böceklerinin arasındaki mesafeyi temsil etmektedir. Burada  $j$ . ateş böceğinin diğer ateş böceğine göre daha parlak olduğunu varsayırsa  $i$  ateş böceğinin konumu Eşitlik 5' de sunulduğu gibi güncellenmektedir.

$$X_i = X_i + B_0 e^{-\gamma r_{ij}^2} (X_j - X_i) + \alpha (rand - \frac{1}{2}) \quad (5)$$

Buarada  $\alpha$  [0 1] arasında bir katsayıyı,  $rand$  [0 1] arasında rastgele bir değeri temsil etmektedir.

## 2.5. Yığılmış Oto-Kodlayıcı (Stacked Auto-Encoder)

Yığılmış oto-kodlayıcılar (YOK), derin öğrenme literatüründe önemli bir yer tutan yapay sinir ağı modellerinden biridir [24]. Bu model, genellikle girdi verisinin temsili için hiyerarşik bir özellik çıkarımı sağlamak amacıyla kullanılır. Her biri ayrı ayrı eğitilen ve ardından birleştirilen bir dizi oto-kodlayıcıdan oluşur. Oto-kodlayıcılar, veriyi daha düşük boyutlu bir uzayda temsil etmek için öğrenilen bir kodlama işlemi gerçekleştirir ve ardından bu temsilin orijinal veriyi yeniden oluşturmasını hedefler [25]. Basit bir oto-kodlayıcı mimarisi Şekil 4' de gösterilmektedir.



Şekil 4. Oto-kodlayıcı yapısı (Auto-Encoder structure)

Oto-kodlayıcı sinir ağı, temelde iki bölümden oluşur: Bir kodlayıcı ve bir kod çözücü. Giriş verilerini kodlayıcı kullanarak özelliklere dönüştürür, ardından bu özellikleri kod çözücü aracılığıyla başlangıç verilerine geri dönüştürerek giriş verilerini yeniden oluşturur [26].

Birden fazla oto-kodlayıcısının birbirlerine bağlanması ile yığılmış oto-kodlayıcı mimarisi oluşmaktadır. Basit bir yığılmış oto kodlayıcı mimarisi Şekil 5’de gösterilmektedir.



Şekil 5. Yığılmış oto-kodlayıcı yapısı (Stacked auto-encoder structure)

YOK, her biri bir öncekinden türetilmiş daha yüksek seviye özelliklerin öğrenilmesini sağlar. Bu model, genellikle büyük boyutlu ve karmaşık veri kümeleri üzerinde etkili sonuçlar verirken, özellik çıkarımı, boyut azaltma ve sınıflandırma işlemlerinde yaygın bir şekilde kullanılmaktadır [27,28].

Bir yığılmış oto-kodlayıcı yapısında birçok hiperparametre barındırmaktadır. Bu hiperparametreler kurulan ağın performansını doğrudan etkilemektedir. Oluşturulan bir mimaride yüksek başarı bu parametrelerin probleme özgü optimize edilmesi ile elde edilebilir.

## 2.6. Veri seti (Dataset)

Sedef hastalığının tanı ve teşhisi için ilk olarak Übeyli ve Güler tarafından kullanılan ve UCI’ de halka açık bir şekilde bulunan “Dermatoloji” veri seti kullanılmıştır [29]. Kullanılan bu veri seti içerisinde 33 adet öznitelik bulunmaktadır. Bu özniteliklerden 12 tanesi klinik öznitelik içerirken 21 adet öznitelik ise histopatolojik özelliklerdir. Veri setinde bulunan öznitelikler Tablo 1’de gösterilmektedir.

Tablo 2. Dermatoloji veri setinde bulunan öznitelikler (Attributes found in the dermatology dataset)

Öznitelik Türü	Öznitelik	Öznitelik Türü	Öznitelik
Klinik	Eritem	Histopatolojik	Akantoz
Klinik	Pullanma	Histopatolojik	Hiperkeratoz
Klinik	Kesin Sınırlar	Histopatolojik	Parakeratoz
Klinik	Kaşıntı	Histopatolojik	Rete Sırtlarının Çomaklaşması
Klinik	Koebner Fenomeni	Histopatolojik	Rete Sırtlarının Uzaması
Klinik	Poligonal Papüller	Histopatolojik	Suprapapiller Epidermisin İncelmesi
Klinik	Foliküler Papüller	Histopatolojik	Spongiform Püstül
Klinik	Oral Mukozal Tutulum	Histopatolojik	Munro Mikroabse
Klinik	Diz Ve Dirsek Tutulumu	Histopatolojik	Fokal Hipergranüloz
Klinik	Kafa Derisi Tutulumu	Histopatolojik	Granüler Tabakanın Kaybolması
Klinik	Aile Öyküsü	Histopatolojik	Vakuolizasyon Ve Bazal Tabakanın Hasarı
Klinik	Yaş	Histopatolojik	Spongioz, Retelerin Testere Dışı Görünümü
Histopatolojik	Melanin İnkontinansı	Histopatolojik	Foliküler Boynuz Tıkaçı
Histopatolojik	İnfiltratta Eozinofiller	Histopatolojik	Perifoliküler Parakeratoz
Histopatolojik	Pnl İnfiltratı	Histopatolojik	İnflamatuvar Monolükleer İnfiltrat
Histopatolojik	Papiller Dermiste Fibrozis	Histopatolojik	Bant Benzeri İnfiltrat
Histopatolojik	Ekzozitoz		

Veri seti içerisinde Tablo 1’ de sunulan özniteliklere sahip 366 adet veri bulunmaktadır. Veri seti içerisinde farklı dermatolojik hastalıklara ait sınıflandırmalar yapılmıştır. Bu çalışmada sadece sedef hastalığına sahip olan kişi sayısı 111’dir. Veri seti %70 eğitim ve %30 test olmak üzere 2 bölüme ayrılmıştır. Çalışmada kullanılan farklı makine öğrenme yöntemleri eğitim veri seti ile eğitilecek sonrasında başarıları test veri seti ile değerlendirilecektir.

## 2.7. Değerlendirme kriterleri (Evaluation criteria)

Sedef hastalığı tanı ve teşhisinde kullanılan makine öğrenme yöntemlerinin başarılarını ölçmek için literatürde sıkça kullanılan doğruluk, duyarlılık ve kesinlik ölçütleri kullanılacaktır [30, 31]. Bu değerlendirme ölçütlerinin hesaplanabilmesi için öncelikle tahmin modelinin karışıklık matrisi oluşturulmalıdır. İki sınıfa ait bir karışıklık matrisi Şekil 6’de gösterilmektedir.

		Tahmin	
		DN	YN
Gerçek	DN	DN	YN
	YN	YP	DP

Şekil 6. Karışıklık matrisi (Confusion matrix)

Şekil 6’ de DN gerçek negatifi, YN yanlış negatifi, YP yanlış pozitif ve DP doğru pozitif temsil etmektedir. Şekil 6’ de sunulan karışıklık matrisi ile doğruluk, duyarlılık ve kesinlik ölçütleri Eşitlik 6-8’ de sunulduğu gibi hesaplanmaktadır [32].

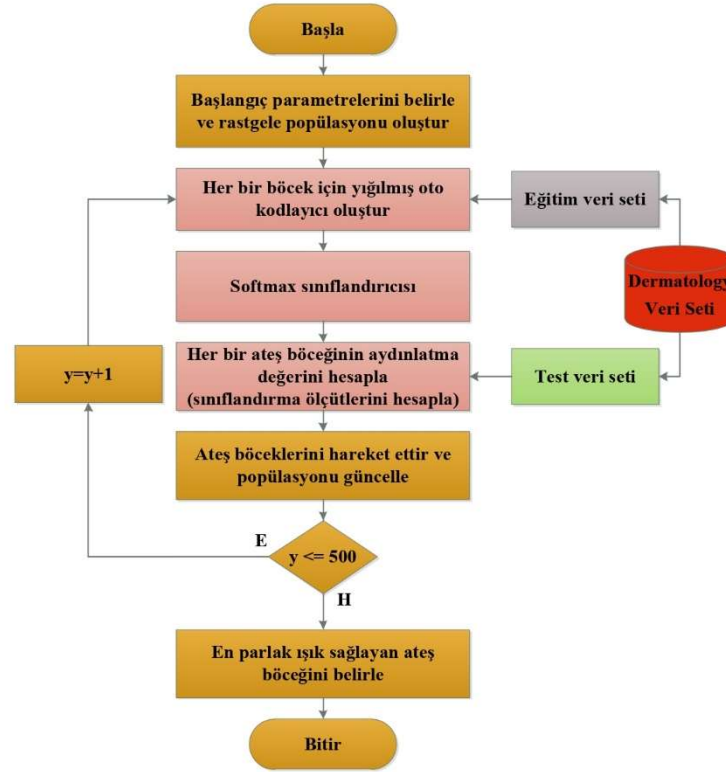
$$Doğruluk = \frac{DN+DP}{DN+DP+YN+YP} \quad (6)$$

$$Duyarlılık = \frac{DP}{DP+YN} \quad (7)$$

$$Kesinlik = \frac{DP}{DP+YP} \quad (8)$$

### 3. Önerilen Yöntem (Proposed Model)

Çalışmanın bu bölümünde, sedef hastalığının doğru bir şekilde tanı ve teşhisinin belirlenebilmesi için yığılmış oto-kodlayıcı, softmax sınıflandırıcı ve Ateş Böceği Algoritması ile optimizasyon temelli bir derin öğrenme ağı oluşturulmuştur. Oluşturulan yapının akış diyagramı Şekil 7’de gösterilmektedir.



Şekil 7. Önerilen model diyagramı (Proposed model diagram)

Şekil 7’de sunulan mimari kodlama kolaylığı ve çok boyutlu problemlerin çözümünde sunmuş olduğu avantajlardan dolayı MATLAB platformunda gerçekleştirilmiştir [12]. Mimaride öncelikle bütün hiperparametreleri optimize edecek olan Ateş Böceği Algoritması’ nın başlangıç parametreleri belirlenmiştir. Bu parametreler deneysel çalışmalar sonucu elde edilmiş olup Tablo 2’de gösterilmektedir.

Tablo 2. ABA parametreleri ve değerleri (ABA parameters and values)

Parametreler	Değerleri
Popülasyon sayısı	40
$B_0$	1
$\gamma$	1
$\alpha$	0,2
Yineleme sayısı	500

Şekil 7’de sunulduğu üzere ilk adım olarak bir başlangıç popülasyonu oluşturulacaktır. Popülasyondaki her bir ateşböceği kendi içerisinde birbirlerinde farklı oto-kodlayıcı+softmax ya da yığılmış oto-kodlayıcı+softmax yapısı oluşturmaktadır. Her bir ateşböceği konumu oluşturulan yapılarıdaki hiperparametreleri bünyesinde barındırmaktadır. Bu hiperparametreler Tablo 3’de gösterilmektedir.



Tablo 3. Hibrit mimaride bulunan hiperparametreler (Hyperparameters in hybrid architecture)

Hiperparametreler	Temsili
Kodlayıcı ve çözücü sayısı	AEnDeSa
Kodlayıcı ve çözücü bölümlerinde bulunan katman sayıları	AGKS
Kodlayıcı katmanlarında kullanılan aktivasyon fonksiyonu	EAF
Çözücü katmanlarında kullanılan aktivasyon fonksiyonu	DAF
Aşırı sığmayı önlemek ve modellerin genelleme yeteneğini geliştirmek için kullanılan Ağırlık Düzenleme Katsayısı	WRK
Geri yayılıma yardımcı olan ve seyrelmede kullanılan seyreklik oranı katsayısı	SRK
Geri yayılıma yardımcı olan ve seyrelmede kullanılan Seyreklik Düzenleme Katsayısı	SPK
Oto-kodlayıcı veya yığılmış oto-kodlayıcıda bulunan Lscaledata değerleri	LD

Şekil 7’de sunulduğu gibi oluşturulan ateş böcekleri çözüm uzayı içerisine rastgele dağıtılmaktadır. Her bir ateş böceği oluşturulurken Tablo 3’de verilen AEnDeSa değeri Eşitlik 9’de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_i \text{EnDeSa}_j(x) = \begin{cases} 1, & x < 1 \\ x, & 1 \leq x \leq 4 \\ 4, & x > 4 \end{cases} \quad (9)$$

Burada  $A_i \text{EnDeSa}_j(x)$ , i. ateş böceğinin j. yinelemedeki AEnDeSa değerini temsil etmektedir.

Her bir ateş böceği için AGKS değeri Eşitlik 10’ de sunulan sınırlama fonksiyonun göre rastgele belirlenmektedir.

$$A_i \text{GKS}_j(x) = \begin{cases} 10, & x < 10 \\ x, & 10 \leq x \leq 100 \\ 100, & x > 100 \end{cases} \quad (10)$$

Burada  $A_i \text{GKS}_j(x)$ , i. ateş böceğinin j. yinelemedeki AGKS değerini temsil etmektedir.

Her bir ateş böceği için EAF değeri Eşitlik 11’ de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_i \text{EAF}_j(x) = \begin{cases} 1, & x < 1 \\ x, & 1 \leq x \leq 2 \\ 2, & x > 2 \end{cases} \quad (11)$$

Burada  $A_i \text{EAF}_j(x)$ , i. ateşböceğinin j. yinelemedeki EAF değerini temsil etmektedir. Rastgele olarak belirlenen  $A_i \text{EAF}_j(x)$  değerine karşılık gelen aktivasyon fonksiyonları Tablo 4’ de gösterilmektedir.

Tablo 4. EAF değerlerine karşılık gelen aktivasyon fonksiyonları (Activation functions corresponding to EAF values)

EAF Değerleri	Aktivasyon Fonksiyonu
1	logsig
2	satlin

Her bir ateş böceği için DAF değeri Eşitlik 12’de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_i \text{DAF}_j(x) = \begin{cases} 1, & x < 1 \\ x, & 1 \leq x \leq 3 \\ 3, & x > 3 \end{cases} \quad (12)$$

Burada  $A_i \text{DAF}_j(x)$ , i. ateşböceğinin j. yinelemedeki ADAF değerini temsil etmektedir. Rastgele olarak belirlenen  $A_i \text{DAF}_j(x)$  değerine karşılık gelen aktivasyon fonksiyonları Tablo 5’ de gösterilmektedir.

Tablo 5: ADAF değerlerine karşılık gelen aktivasyon fonksiyonları (Activation functions corresponding to ADAF values)

DeAf Değerleri	Aktivasyon Fonksiyonu
1	logsig
2	satlin
3	purelin

Her bir ateşböceği için WRK değeri Eşitlik 13' de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_iWRK_j(x) = \begin{cases} 0,001, & x < 0,001 \\ x, & 0,001 \leq x \leq 0,01 \\ 0,01, & x > 0,01 \end{cases} \quad (13)$$

Burada  $A_iWRK_j(x)$ , i. ateşböceğinin j. yinelemedeki WRK değerini temsil etmektedir.

Her bir ateşböceği için SRK değeri Eşitlik 14' de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_iSRK_j(x) = \begin{cases} 1, & x < 1 \\ x, & 1 \leq x \leq 5 \\ 5, & x > 5 \end{cases} \quad (14)$$

Burada  $A_iSRK_j(x)$ , i. ateşböceğinin j. yinelemedeki SRK değerini temsil etmektedir.

Her bir ateşböceği için SPK değeri Eşitlik 15' de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_iSPK_j(x) = \begin{cases} 0, & x < 0 \\ x, & 0 \leq x \leq 1 \\ 1, & x > 1 \end{cases} \quad (15)$$

Burada  $A_iSPK_j(x)$ , i. ateşböceğinin j. yinelemedeki SPK değerini temsil etmektedir.

Her bir ateşböceği için LD değeri Eşitlik 16' de sunulan sınırlama fonksiyonuna göre rastgele belirlenmektedir.

$$A_iLD_j(x) = \begin{cases} 1, & x < 1 \\ x, & 1 \leq x \leq 2 \\ 2, & x > 2 \end{cases} \quad (16)$$

Burada  $A_iLD_j(x)$ , i. ateşböceğinin j. yinelemedeki LD değerini temsil etmektedir. Belirlenen LD değerine karşılık gelen değer Tablo 6' de gösterilmektedir.

Tablo 6. LD değerinin mimarideki karşılığı (The equivalent of LD value in architecture)

LD Değerleri	Değeri
1	True
2	False

Rastgele oluşturulan popülasyonun ardından bir sonraki adımda her bir ateş böceğinin yaymış olduğu ışığın parlaklığı hesaplanmaktadır. Her bir ateş böceğinin yaymış olduğu ışığın parlaklığı Eşitlik 17' de sunulan formül ile belirlenmektedir.

$$f(A_{ij}) = A(\text{Doğruluk}, \text{Kesinlik}, \text{Duyarlılık}) \quad (17)$$

Formülde  $f(A_{ij})$ , i. ateş böceğinin j. yinelemedeki parlaklık miktarını temsil etmektedir.

Bir sonraki adımda Eşitlik 17 ile belirlenen en parlak ışığa sahip ola ateş böceğine yönelim Eşitlik 5' de


sunulduğu gibi belirlenerek ateş böceklerinin konumları güncellenmektedir.

Tablo 2’de sunulan yineleme sayısı kadar tekrarlanan hibrit mimaride en parlak ışığa sahip ateşböceği Eşitlik 17’de sunulan formül ile belirlenmiş ve bünyesinde bulunan parametreler Tablo 7’de gösterilmektedir.

Tablo 7: En parlak ışık yayan ateşböceği parametreleri (arameters of the brightest light-emitting firefly)

Parametreler	Değerleri
AEnDeSa	1
AGKS	64
EAF	2 (satlin)
DAF	2 (satlin)
WRK	0,006
SRK	4,2770
SPK	0.03
LD	1 (true)

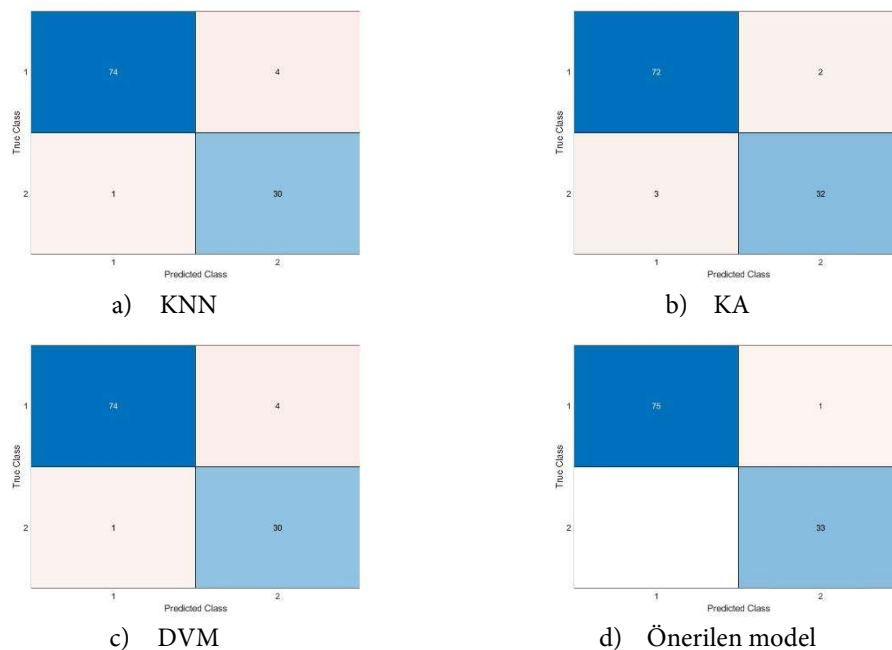
Tablo 7’de sunulan hiperparametrelere sahip en parlak ışık yayan ateş böceği parametreleri ile kurulan otokodlayıcı ve softmax sınıflandırıcı ile elde edilen hibrit mimari Şekil 8’de gösterilmektedir.



Şekil 8. Elde edilen mimari yapısı (The resulting architectural structure)


### 3. Deneysel Sonuçlar ve Tartışma (Experimental Results and Discussion)

Sedef hastalığının tanı ve teşhisinde kullanılan hibrit mimari ile birlikte literatürde sınıflandırma problemlerinde sıklıkla kullanılan KA, KNN ve DVM yöntemleri de çalışmada kullanılmıştır. Öğrenme veri seti üzerinde çalıştırılan modellerin test veri seti üzerindeki tahminleri ile oluşturulan karışıklık matrisleri Şekil 9’da gösterilmektedir.



Şekil 9. Çalışmada kullanılan modellerin karışıklık matrisleri (Confusion matrices of the models used in the study)

Şekil 9'da sunulan karışıklık matrislerine göre sunulan hibrit mimari ile elde edilen modelin tahmin doğruluğu diğer makine öğrenme yöntemlerine göre daha yüksektir. Çalışmada kullanılan makine öğrenimi yöntemlerinin ROC eğrileri Şekil 10'da gösterilmektedir.



Şekil 10. Makine öğrenme yöntemleri ROC eğrileri (Machine learning methods ROC curves)

ROC eğrisi makine öğrenme yöntemlerinin başarılarının ölçümünde sıklıkla kullanılmaktadır [33]. ROC eğrisi altında kalan alana AUC denilmektedir. Bir ROC eğrisinde AUC alanı ne kadar büyükse modelin performansı da o kadar yüksektir [4]. Şekil 10'da verilen ROC eğrilerine bakıldığında önerilen modelin performansı diğer makine öğrenme yöntemlerine göre daha başarılıdır.

Çalışmada sedef hastalığının tanı ve teşhisinde kullanılan makine öğrenme yöntemlerinin Eşitlik 6-8'de verilen değerlendirme ölçütlerine göre başarıları hesaplanmış ve bu sonuçlar Tablo 8'de sunulmuştur.

Tablo 8. Çalışmada kullanılan makine öğrenme yöntemlerinin performansları (The performance of the machine learning methods used in the study)

Modeller	Kesinlik	Duyarlılık	Doğruluk(%)
KNN	0,96	0,88	0,95
KA	0,91	0,94	0,95
DVM	0,96	0,88	0,95
Önerilen Model	<b>1</b>	<b>0,97</b>	<b>0,99</b>

Tablo 8'de sunulan değerlendirme ölçütlerine göre sunulan hibrit modelin diğer makine öğrenme yöntemlerine göre daha başarılı sonuçlar elde ettiği görülmektedir.

### 3. Sonuç (Conclusion)

Sedef hastalığının erken tanı ve teşhisi, hastalığın etkilerini hafifletmek ve yaşam kalitesini artırmak için kritik

bir öneme sahiptir. Sedef, kronik bir inflamatuvar cilt hastalığıdır ve erken teşhis edilmediğinde, semptomlar zamanla kötüleşebilir ve ciddi komplikasyonlara yol açabilir. Erken tanı, uygun tedaviye başlama ve hastalığın ilerlemesini kontrol altına alma şansını artırır. Ayrıca, sedef hastalığının erken tanınması, hastalığın diğer sistemik sağlık sorunlarıyla ilişkilendirilen risklerini azaltabilir. Bu çalışmada sedef hastalığının tanı ve teşhisi için hibrit bir mimari ile elde edilen bir model önerilmiştir. Oluşturulan mimaride yığılmış oto-kodlayıcı, softmax sınıflandırıcı ve Ateş Böceği Algoritması kullanılmıştır. Yığılmış oto-kodlayıcı ve softmax sınıflandırıcı ile hibritleştirilmiş mimarinin model ve hiperparametre optimizasyonu Ateş Böceği Algoritması ile sağlanmıştır. Model UCI veri deposunda bulunan "Dermatoloji" veri seti üzerinde uygulanmıştır. Çalışmada aynı veri seti üzerinde farklı makine öğrenme yöntemleri de çalıştırılmıştır. Deneysel çalışmalardan elde edilen bulgular önerilen yöntemin diğer makine öğrenme yöntemlerine göre daha başarılı sonuçlar elde ettiğini göstermiştir.

Sunulan model mimari yapıda kullanılan ve mimari içerisindeki hiperparametreleri optimize ederken aynı zamanda bunlara ulaşım imkânı da sağlamaktadır. Sunulan yöntem hasta karar destek sistemlerinde alternatif bir yöntem olarak kullanılabilir.

İleriki çalışmalarda sunulan mimari ve bu mimariye ait parametreler ile mobil uygulamalar geliştirilebilir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] A. Günaydin, "Kurkumin Etken Maddesinin Etkileri ve Kalite Kontrol Çalışmaları Effects and Quality Control Studies of Curcumin," *Dünya Sağlık ve Tabiat Bilimleri Dergisi*, vol. 6(1), pp. 14-21, 2023.
- [2] A. W. Armstrong and C. Read, "Pathophysiology, Clinical Presentation, and Treatment of Psoriasis: A Review," *JAMA - Journal of the American Medical Association*, vol. 323(19), pp. 1945-1960, 2020. doi:10.1001/jama.2020.4006
- [3] F. Yamazaki, "Psoriasis: Comorbidities," *Journal of Dermatology*, vol. 48(6), pp. 732-740, 2021. doi:10.1111/1346-8138.15840
- [4] M. A. Bülbül, "Optimization of artificial neural network structure and hyperparameters in hybrid model by genetic algorithm: iOS-android application for breast cancer diagnosis/prediction", *Journal of Supercomputing*, vol. 80(4), pp. 4533-4553, 2024. doi:10.1007/s11227-023-05635-z
- [5] I. Pacal and S. Kılıncarslan, "Deep learning-based approaches for robust classification of cervical cancer," *Neural Comput. Appl.*, vol. 35(25), pp. 18813-18828, 2023. doi:10.1007/s00521-023-08757-w
- [6] R. Raj, N. D. Londhe, and R. S. Sonawane, "Objective scoring of psoriasis area and severity index in 2D RGB images using deep learning," *Multimed. Tools Appl.*, pp. 1-27, 2024. doi:10.1007/s11042-024-18138-7
- [7] M. S. Rashid, G. Gilanie, S. Naveed, S. Cheema, and M. Sajid, "Automated detection and classification of psoriasis types using deep neural networks from dermatology images," *Signal, Image Video Process.*, vol. 18(1), pp. 163-172, 2024. doi:10.1007/s11760-023-02722-9
- [8] V. K. Shrivastava, N. D. Londhe, R. S. Sonawane, and J. S. Suri, "A novel approach to multiclass psoriasis disease risk stratification: Machine learning paradigm," *Biomed. Signal Process. Control*, vol. 28, pp. 27-40, 2016. doi:10.1016/j.bspc.2016.04.001
- [9] G. Vishwakarma, A. K. Nandanwar, and G. S. Thakur, "Optimized vision transformer encoder with cnn for automatic psoriasis disease detection," *Multimed. Tools Appl.*, pp. 1-20, 2023. doi:10.1007/s11042-023-16871-z
- [10] M. Dash, N. D. Londhe, S. Ghosh, A. Semwal, and R. S. Sonawane, "PsLSNet: Automated psoriasis skin lesion segmentation using modified U-Net-based fully convolutional network," *Biomed. Signal Process. Control*, vol. 52, pp. 226-237, 2019. doi:10.1016/j.bspc.2019.04.002
- [11] L. H. Juang and M. N. Wu, "Psoriasis image identification using k-means clustering with morphological processing," *Meas. J. Int. Meas. Confed.*, vol. 44(5), pp. 895-905, 2011. doi:10.1016/j.measurement.2011.02.006

- [12] M. A. Bülbül and C. Öztürk, "Optimization, Modeling and Implementation of Plant Water Consumption Control Using Genetic Algorithm and Artificial Neural Network in a Hybrid Structure," *Arab. J. Sci. Eng.*, vol. 47(2), pp. 2329-2343, 2022. doi:10.1007/s13369-021-06168-4
- [13] M. A. Bülbül, E. Harirchian, M. F. Işık, S. E. Aghakouchaki Hosseini, and E. Işık, "A Hybrid ANN-GA Model for an Automated Rapid Vulnerability Assessment of Existing RC Buildings," *Appl. Sci.*, vol. 12, no. 10, 2022. doi:10.3390/app12105138
- [14] F. Konak, M. A. Bülbül, and D. Türkoğlu, "Feature Selection and Hyperparameters Optimization Employing a Hybrid Model Based on Genetic Algorithm and Artificial Neural Network: Forecasting Dividend Payout Ratio," *Comput. Econ.*, vol. 63, pp. 1673-1693, 2024. doi:10.1007/s10614-023-10530-z
- [15] I. Nurhidayat, B. Pimpunchat, and W. Klomsungcharoen, "More accurate simulation for insurance data based on a modified SVM polynomial method," *J. Intell. Fuzzy Syst.*, vol. 44(6), pp. 9129-9141, 2023. doi: 10.3233/JIFS-222879
- [16] J. Li, J. Shi, Z. Liu, and C. Feng, "A parallel and balanced SVM algorithm on spark for data-intensive computing," *Intell. Data Anal.*, vol. 27(4), pp. 1065-1086, 2023. doi:10.3233/IDA-226774
- [17] G. Sandhu, A. Singh, P. S. Lamba, D. Virmani, and G. Chaudhary, "Modified Euclidean-Canberra blend distance metric for kNN classifier," *Intell. Decis. Technol.*, vol. 17(2), pp. 527-541, 2023. doi:10.3233/idt-220223
- [18] M. A. Bülbül, "Kuru Fasulye Tohumlarının Çok Sınıflı Sınıflandırılması İçin Hibrit Bir Yaklaşım," *İğdır Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 13(1), pp. 33-43, 2023. doi:10.21597/jist.1185949
- [19] I. Roshanski, M. Kalech, and L. Rokach, "Automatic Feature Engineering for Learning Compact Decision Trees," *Expert Syst. Appl.*, vol. 229, pp. 120470, 2023. doi:10.1016/j.eswa.2023.120470
- [20] G. Nanfack, P. Temple, and B. Frénay, "Learning Customised Decision Trees for Domain-knowledge Constraints," *Pattern Recognit.*, vol. 142, pp. 109610, 2023. doi:10.1016/j.patcog.2023.109610
- [21] Z. Cheng, H. Song, D. Zheng, M. Zhou, and K. Sun, "Hybrid firefly algorithm with a new mechanism of gender distinguishing for global optimization," *Expert Syst. Appl.*, vol. 224, pp. 120027, 2023. doi:10.1016/j.eswa.2023.120027
- [22] T. Theppakorn and P. Pongcharoen, "Modified and hybridised bi-objective firefly algorithms for university course scheduling," *Soft Comput.*, vol. 27(14), pp. 9735-9772, 2023. doi:10.1007/s00500-022-07810-5
- [23] M. Akdağ and M. Çelebi, "Ateş Böceği Algoritması ile Yağlı Tip Transformatörün Ağırlık Optimizasyonu," *DÜMF Mühendislik Derg.*, vol. 2, pp. 169-180, 2022. doi:10.24012/dumf.1075008
- [24] J. Yang and L. Wang, "Nonlocal, local and global preserving stacked autoencoder based fault detection method for nonlinear process monitoring," *Chemom. Intell. Lab. Syst.*, vol. 235, pp. 104758, 2023. doi:10.1016/j.chemolab.2023.104758
- [25] R. R. Jagat, D. S. Sisodia, and P. Singh, "Web-S4AE: a semi-supervised stacked sparse autoencoder model for web robot detection," *Neural Comput. Appl.*, vol. 35(24), pp. 17883-17898, 2023. doi:10.1007/s00521-023-08668-w
- [26] K. Adem, S. Kiliçarslan, and O. Cömert, "Classification and diagnosis of cervical cancer with stacked autoencoder and softmax classification," *Expert Syst. Appl.*, vol. 115, pp. 557-564, 2019. doi:10.1016/j.eswa.2018.08.050
- [27] K. E. M and Deje, "Stacked autoencoder with novel integrated activation functions for the diagnosis of autism spectrum disorder," *Neural Comput. Appl.*, 2023. doi:10.1007/s00521-023-08565-2
- [28] W. Zeng *et al.*, "Wear indicator construction for rolling bearings based on an enhanced and unsupervised stacked auto-encoder," *Soft Comput.*, pp. 1-14, 2023. doi:10.1007/s00500-023-09068-x
- [29] E. D. Übeyli and I. Güler, "Automatic detection of erythematous-squamous diseases using adaptive neuro-fuzzy inference systems," *Comput. Biol. Med.*, vol. 35(5), pp. 421-433, 2005. doi:10.1016/j.combiomed.2004.03.003
- [30] M. Jiang *et al.*, "Personalized and adaptive neural networks for pain detection from multi-modal physiological features," *Expert Syst. Appl.*, vol. 235, pp. 121082, 2024. doi:10.1016/j.eswa.2023.121082
- [31] U. Prasad, S. Chakravarty, and G. Mahto, "Lung cancer detection and classification using deep neural network based on hybrid metaheuristic algorithm," *Soft Comput.*, pp. 1-224, 2023. doi:10.1007/s00500-023-08845-y
- [32] P. Sengodan, K. Srinivasan, R. Pichamuthu, and S. Matheswaran, "Early detection and classification of malignant lung nodules from CT images: An optimal ensemble learning," *Expert Syst. Appl.*, vol. 229, pp. 120361, 2023. doi:10.1016/j.eswa.2023.120361

[33] A. M. Carrington *et al.*, “Deep ROC Analysis and AUC as Balanced Average Accuracy, for Improved Classifier Selection, Audit and Explanation,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 45(1), pp. 329-341 2023. doi:10.1109/TPAMI.2022.3145392

---

This is an open access article under the CC-BY license

