



Eritematöz Skuamöz Hastalıkların Teşhisinde Makine Öğrenme Algoritmaları Performanslarının Değerlendirilmesi

Gürkan Bilgin¹ , Ahmet Çifçi^{2*} 

^{1,2} Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Burdur, Türkiye

gbilgin@mehmetakif.edu.tr, acifci@mehmetakif.edu.tr

Öz

Eritematöz skuamöz hastalıkların ayırıcı tanısı dermatolojide önemli problemlerden biridir. Hepsinin birbirleri arasında, çok az farklı eritem ve ölçeklenmenin klinik özelliklerini paylaşmaktadırlar. Bu gruba dâhil olan hastalıklar; sedef hastalığı, seboreik dermatit, liken planus, gül hastalığı (pityriasis rosea), kronik dermatit ve pityriasis rubra pilaris olarak sınıflandırılabilir. Tanı için genellikle biyopsi gereklidir ancak ne yazık ki bu hastalıklar pek çok histopatolojik özelliği de paylaşmaktadır. Diğer taraftan, son yıllarda özellikle bilgisayar teknolojisindeki gelişmeler ve yapay zekâ teknolojileri, biyomedikal alanda kendine geniş bir uygulama alanı bulmuştur. Tıbbi cihazlarda bilgisayar teknolojilerinin kullanılmasıyla daha hassas, daha hızlı, insandan kaynaklanan hataları minimize eden cihazlar geliştirilmektedir. Dolayısıyla, bu çalışmada, makine öğrenme algoritmaları deri hastalıklarının sınıflandırılması ve tahmininde ne kadar etkili olmaktadır onun araştırılması yapılmıştır. Bu çalışmada, 366 hastaya ait 33 nitelikten oluşan deri doku örnekleri, Destek Vektör Makineleri (Support Vector Machines - SVM), Topluluk Öğrenme Algoritmaları (Ensemble Learning Algorithms - ELA), Karar Ağaçları (Decision Trees - DT) ve k-En Yakın Komşuluk (k-Nearest Neighborhood - k-NN) ile sınıflandırılmış ve en yüksek doğruluk değerleri kaydedilmiştir. Buna göre deri hastalıklarının ayrıştırılması ve sınıflandırılması ile ilgili etkiler araştırılmıştır. SVM ile bu veri setinde, önceki tüm çalışmalardan daha yüksek olan %99.73'lük bir doğruluk elde edilmiştir.

Anahtar kelimeler: Deri Hastalıkları, Destek Vektör Makinesi, Topluluk Öğrenme Algoritmaları, Karar Ağaçları, k-En Yakın Komşuluk.

Evaluation of Machine Learning Algorithms Performance in Diagnosis of Erythematous Squamous Diseases

Abstract

Differential diagnosis of erythematous squamous diseases is one of the important problems in dermatology. They all share the clinical picture of erythema and scaling among each other, with little difference. The diseases included in this group can be classified as psoriasis, seborrheic dermatitis, lichen planus, pityriasis rosea, chronic dermatitis and pityriasis rubra pilaris. Biopsy for diagnosis, but unfortunately these diseases also share many histopathological features. Technologies related to some other technologies have found wide application in the biomedical field. With the use of computer technologies in medical devices, more sensitive, faster, faster, cutting devices are developed. Therefore, it has been investigated how effective machine learning algorithms are in classifying and predicting skin diseases. In this study, skin tissue samples consisting of 33 attributes belonging to 366 patients, Support Vector Machines (SVM), Ensemble Learning Algorithms (ELA), Decision Trees (DT), k-Nearest Neighborhood (k-NN) were classified with algorithms and the highest knowledge information was recorded. Accordingly, the effects related to the separation and classification of skin diseases have been investigated. SVM has achieved an accuracy of 99.73% which is higher than all the previous studies on this dataset.

Keywords: Skin Diseases, Support Vector Machine, Ensemble Learning Algorithms, Decision Trees, k-Nearest Neighborhood.

* Sorumlu yazar.
E-posta adresi: acifci@mehmetakif.edu.tr

Alındı : 23 Mart 2021
Revizyon : 22 Haziran 2021
Kabul : 16 Eylül 2021

1. Giriş (Introduction)

Deri, en büyük immünolojik organlardan biridir ve hem dış hem de iç faktörlerin yanı sıra doğuştan gelen ve uyarlanabilir immün yanıtlardan etkilenir (Fonacier vd., 2010). Ayrıca deri, canlıyı ultraviyole ışınlarından, mikrobiyal, kimyasal ve fiziksel saldırılardan koruyan bir bariyerdir (Lee vd., 2006). Anatomileri ve işlevleri açısından önemli ölçüde farklılık gösteren epidermis, dermis ve hipodermis adı verilen üç katmandan oluşur. Epidermis, gözle görülebilen ve çoğunlukla keratinositlerden oluşan dış tabakadır. Dermis, derinin epidermis ile deri altı doku arasında bulunan kıl kökleri, yağ bezleri ve ter bezleri ihtiva eden katmandır. Yapısal bileşenleri kollajen, elastin ve hyaluronik asittir (Tabassum ve Hamdani, 2014; Dumas ve Ntambi, 2018; Yousef vd., 2021).

Deri hastalıkları, yenidoğanlardan yaşlılara kadar her yaşı etkileyen ve sıkça ortaya çıkan bir sağlık sorunu olup, çeşitli şekillerde zararlara neden olur. Deri hastalıklarının çoğu da benzer bazı semptomlar göstermektedir. Bu yüzden aralarındaki farkları bilmek önemlidir. Eritematöz skuamöz hastalıkların ayırıcı tanısı dermatolojide önemli problemlerden biridir. Hepsi birbirleri arasında, çok az farkla eritem ve ölçeklenmenin klinik özelliklerini paylaşmaktadırlar. Bu gruptaki hastalıklar; sedef hastalığı, seboreik dermatit, liken planus, pityriasis rosea, kronik dermatit ve pityriasis rubra pilaris'dir (Güvenir vd., 1998).

Sedef hastalığı kalıcı, bulaşıcı olmayan ve iltihaplı bir hastalıktır. Sedef hastalığı olan hastalar, hastalığa genetik bir yatkınlığa sahiptir. Lezyonlar tipik olarak kafa derisi, gövde, dirsekler ve dizlerde görülür (Lyons ve Ousley, 2014). Sebore olarak da adlandırılan seboreik dermatit uzun süren bir deri hastalığıdır. Kırmızı, pürüzlü, yağlı, tahriş olmuş deri semptomları arasındadır (Borda ve Wikramanayake, 2015). Liken planus deri, mukoza zarı ve tırnakları etkileyen idiyopatik papüloskuamöz bir deri hastalığıdır. Kesin insidansı ve yaygınlığı bilinmemektedir. Genellikle orta yaşlı bireyleri etkilemektedir (Gurusamy ve Selvaraj, 2016). Pityriasis rosea veya gül hastalığı sağlıklı çocuklarda ve yetişkinlerde sıklıkla görülen, genellikle 1-2 ay süren iyi huylu akut papüler döküntüdür (Lyons ve Ousley, 2014). Kronik dermatit deride tahriş ve kızarıklık ile kendini gösteren, derinin kötüleşmesine neden olan bir deri iltihabıdır (Nedorost, 2012). Pityriasis rubra pilaris idiyopatik, papüloskuamöz inflamatuvar bir deri hastalığıdır. Turuncu-kırmızı pullu plaklar içine birleşmiş hiperkeratotik foliküler papüller, koruyucu adalar ve palmoplantar keratoderma ile karakterizedir (Wang vd., 2018).

Eritematöz skuamöz hastalıkları doğru teşhis etmek için çeşitli teknikler kullanılarak birçok çalışma yapılmıştır. Güvenir ve ark. (1998), eritematöz skuamöz hastalıklarının ayırıcı tanısı ile ilgili ilk çalışmayı yapmışlardır. Oylama özelliği aralıkları (Voting Feature Intervals - VFI5) adlı yeni bir

sınıflandırma algoritması geliştirmişler ve eritematöz skuamöz hastalıkları veri seti için doğruluk oranını %99.2 olarak bulmuşlardır. Fidelis ve ark. (2000), genetik algoritma kullanarak veri seti için doğruluk oranını %95 olarak elde etmişlerdir. Karabatak ve İnce (2009), eritematöz skuamöz hastalıklarının teşhisi için birliktelik kuralları ve sinir ağları tabanlı yeni bir özellik seçme yöntemi sunmuşlardır. Önerdikleri yöntemin doğru sınıflandırma oranı %98.61'dir. Xie ve Wang (2011), SVM tabanlı ardışık ileri yönde seçim algoritması kullanmışlar ve 21 özelliğinden oluşan azaltılmış veri seti için %98.61 sınıflandırma doğruluğu elde etmişlerdir. Çifci ve ark. (2014), sedef ve liken planus deri hastalıkları olmak üzere iki grup üzerinde çok katmanlı yapay sinir ağı oluşturmuşlar ve ağı korelasyon katsayısını 0.98 olarak bulmuşlardır. Parikh ve Shah (2017), sınıflandırıcı olarak SVM ile sarmal yöntemini kullanarak, 34 özelliğinden oluşan orijinal veri setinin alt kümesinin 20 özelliği için %97.27 doğruluk elde etmişlerdir. Elsayad ve ark. (2018), hem klinik hem de histopatolojik özellikleri kullanarak eritematöz skuamöz hastalıklarının teşhisi için Ki-Kare Otomatik Etkileşim Algılama (Chi-Squared Automatic Interaction Detection - CHAID) karar ağaçlarının ve bunların torbalanmış (Bagging) ve artırılmış (Boosting) topluluklarının uygulamasının deneysel sonuçlarını sunmuşlardır. Modelin doğruluk oranını %93.81 olarak elde etmişlerdir. Idoko ve ark. (2018), eritematöz skuamöz hastalıklarının ayırıcı tanısı için bulanık sinir ağı (Fuzzy Neural Network - FNN) tanımlama sistemi tasarlamış ve performansını sınıflandırma ve regresyon ağacı (Classification and Regression Tree - CART), birliktelik kuralları ve bulanık c-ortalama kümeleme (Association Rules and Fuzzy c-Means Clustering - ARFCMC), uyarlamalı sinirsel bulanık çıkarım sistemi (Adaptive Neuro-Fuzzy Inference System - ANFIS), ve topluluk sınıflandırıcılar (Ensemble of Classifiers - AEC) ile karşılaştırmışlardır. Chaurasia ve Pal (2020), lojistik regresyon (logistic regression - LR), lineer diskriminant analizi (linear discriminant analysis - LDA), k-NN, SVM, CART ve Gaussian Naïve Bayes (NB) gibi doğrusal ve doğrusal olmayan algoritmaları dermatoloji veri setine uygulamışlardır. LR ile %97.94 doğruluk oranına ulaşmışlardır. Verma ve ark. (2020), pasif agresif sınıflandırıcı (Passive Aggressive Classifier - PAC), LDA, radius komşular sınıflandırıcı (Radius Neighbors Classifier - RNC), Bernoulli Naïve Bayes (Bernoulli Naïve Bayesian - BNB), NB ve ekstra ağaç sınıflandırıcı (Extra Tree Classifier - ETC) gibi altı makine öğrenimi sınıflandırma tekniğini deri hastalıklarının tahminini sınıflandırmak için kullanmışlar ve doğruluğu artırmak için torbalama, AdaBoost ve gradyan artırma sınıflandırıcıları olmak üzere üç topluluk tekniği uygulamışlardır. RNC'de uygulanan gradyan artırma topluluğu yöntemi ile %99.68'lik doğruluk elde etmişlerdir. Rashid ve ark. (2020), öznitelik seçimi için işbirlikçi birlikte evrim algoritmasının etkisini, yaygın olarak kullanılan altı farklı makine öğrenimi sınıflandırma algoritması, yani


NB, SVM, k-NN, J48, rastgele orman (Random Forest - RF) ve LR üzerinde analiz etmişlerdir. NB ve RF algoritmalarında %97.54 başarı oranına ulaşmışlardır. Putatunda (2020), dermatoloji veri setine hem yeni bir hibrit derin öğrenme yaklaşımı olan Derm2Vec'i hem de derin sinir ağlarını diğer geleneksel makine öğrenme (MÖ) yöntemleriyle birlikte uygulamıştır. Derm2Vec, derin sinir ağları ve ekstrem gradyan artırma algoritmasının ortalama doğruluk skorunu sırasıyla %96.92, %96.65 ve %95.80 olarak bulmuştur. Shastri ve ark. (2021), eritematöz skuamöz hastalıklarının analizi ve tahmini için gradyan topluluk öğrenme yaklaşımı olan GBoost'u kullanmışlardır. Sonuç olarak %99.45 gibi yüksek bir tahmin başarısına ulaşmışlardır.

Bu çalışmanın ana odak noktası sedef hastalığı, seboreik dermatit, liken planus, pityriasis rosea, kronik dermatit ve pityriasis rubra pilaris gibi farklı eritematöz skuamöz hastalık sınıflarını içeren dermatoloji veri setidir. Hekimler tarafından tanısı konulmaya çalışılan bu hastalıkların tespit edilmesi ve birbirleri arasında ayrıştırılmasının yapılabilmesi için, dermatoloji veri setine dört farklı MÖ yöntemi uygulanarak en yüksek oranda doğru sınıflandırmanın elde edilmesi hedeflenmiştir. Ayrıca yöntemlerin performans karşılaştırmaları yapılmıştır. Çalışmada, MÖ metotları olarak SVM, ELA, DT ve k-NN metotları kullanılmıştır.

Çalışmanın bu bölümünde konu hakkında daha önce gerçekleştirilmiş benzer çalışmalar özet olarak verilmiş, ayrıca çalışmanın hedefleri ve motivasyonundan bahsedilmiştir. İkinci bölümde ise veri setinin içeriği hakkında bilgiler sunulmuş ve önerilen sınıflandırma yöntemleri açıklanmıştır. Üçüncü bölümde analizlerde kullanılan yöntemlerin performansları tartışılmış ve önceki çalışmalar ile kıyasları yapılmıştır. Dördüncü bölümde ise bu çalışmanın sonuçları verilmiştir.

2. Materyal ve Yöntem (Material and Method)

Çalışmada bahsi geçen sınıflandırma sisteminin genel blok şeması Şekil 1'de gösterilmiştir. Bloklara bakacak olursak eritematöz skuamöz hastalıklara sahip hastalardan oluşturulan veri seti, tasarlanan bir bilgisayar arayüzüne hekim tarafından girilecektir. Sistem arayüze sunulan veri setini sayısal değerlere dönüştürüp MÖ metodu girişlerine uygun hale getirecektir. Sınıflandırma için veri seti sırasıyla SVM, ELA, DT ve k-NN metotları ile eğitilecek ve test verileri kullanılarak her bir algoritmanın performansı incelenecektir. Hastalık tahmin performanslarının değerlendirilmesi için çapraz doğrulama, duyarlılık ve özgüllük değerleri kullanılacaktır.



Şekil 1. Çalışmanın genel blok şeması (General block diagram of the study)

2.1. Veri Tabanı (Database)

Çalışmada kullanılan veri seti UCI (University of California, Irvine) makine öğrenme veri tabanından alınmıştır (Dua ve Graff, 2019). Gerçek veri tabanı, 33'ü doğrusal değerli ve biri nominal olan 34 öznelik içermektedir. Çalışmada sadece 33 özellik dikkate alınmıştır. Hastanın yaşı olan son özellik çalışmaya dâhil edilmemiştir. Bu 34 niteliğin, 12 tanesi klinik nitelikleri, geri kalan 22 nitelik ise histopatolojik nitelikleri oluşturmaktadır. Bu niteliklerin açıklamaları Tablo 1'de verilmiştir.

Tablo 1. Özneliklerin açıklaması (Description of attributes)

Nitelik no	Nitelik açıklaması	Değerler
Klinik nitelikler		
1	Cilt kızarıklığı	0-3
2	Ciltte pullanma	0-3
3	Kesin sınırlar	0-3
4	Kaşıntı	0-3
5	Koebner fenomeni	0-3
6	Çokgen papüller	0-3
7	Foliküler papüller	0-3
8	Oral mukozal tutulum	0-3
9	Diz ve dirsek tutulumu	0-3
10	Kafatası derisi tutulumu	0-3
11	Aile öyküsü	0-1
34	Yaş	Doğrusal
Histopatolojik nitelikler		
12	Melanin tutamama	0-3
13	Sızıntıdaki eozinofiller	0-3
14	PNL sızması	0-3
15	Kabarıklı derinin dejenerasyonu	0-3
16	Eksositoz	0-3
17	Akantoz	0-3
18	Hiperkeratoz	0-3
19	Parakeratoz	0-3
20	Rete çıkıntılarının Çomaklaşması	0-3
21	Rete çıkıntılarının uzaması	0-3
22	Yüksek kabarcıklı üstderinin incelmesi	0-3
23	Sponjiyöz çıbanı	0-3
24	Munro mikroapsesi	0-3
25	Fokal hipergranüloz	0-3
26	Pürüzlü katmanın yok olması	0-3
27	Temel katmanın kofullaşması ve zedelenmesi	0-3
28	Sponjiyoz	0-3
29	Retenin testere dişi görünümünde olması	0-3
30	Foliküler boynuz tıkaçı	0-3
31	Perifoliküler parakeratoz	0-3
32	İltihaplı mononükleer sızması	0-3
33	Bant şeklinde sızma	0-3

Tablo 1'de gösterilen aile öyküsü niteliği bu hastalıklardan herhangi biri ailede gözlenmişse 1, aksi halde 0 değerine sahiptir. Diğer klinik ve histopatolojik niteliklere 0 ile 3 aralığında bir değer verilir. Burada 0

özelliğın mevcut olmadığını, 3 mümkün olan en büyük değeri ve 1 ile 2 ise göreceli ara değeri gösterir.

Dermatoloji veri seti altı türden 366 örnek içeren eritematöz skuamöz hastalıklarla ilgilidir: Sedef hastalığı (112 hasta), seboreik dermatit (61 hasta), liken planus (72 hasta), pityriasis rosea (49 hasta), kronik dermatit (52 hasta) ve pityriasis rubra pilaris (20 hasta). Bu hastalıklara ilişkin görseller Şekil 2’de verilmiştir.



Şekil 2. Eritematöz skuamöz hastalıklar (Lyons ve Ousley, 2014) (Erythematous squamous diseases) (a) Sedef hastalığı, (b) Liken planus, (c) Kronik dermatit, (d) Seboreik dermatit, (e) Pityriasis rosea, (f) Pityriasis rubra pilaris

2.2. Önerilen Yöntemler (Proposed Methods)

Çalışmada, hastalardan elde edilen klinik ve histopatolojik niteliklerden oluşturulmuş veri seti SVM, ELA, DT ve k-NN metotları gibi farklı MÖ algoritmalarına sırasıyla uygulanmıştır. MÖ sistemine verilerin uyarlanmasını temsil eden şematik çizim Şekil 3’te gösterilmiştir.



Şekil 3. MÖ metotlarının sisteme uygulanmasının şematik gösterimi (Schematic representation of the application of ML methods to the system)

2.2.1. Destek Vektör Makinaları (Support Vector Machines)

SVM, çok fazla verilerin bulunduğu sınıflandırma problemlerinde fazla kullanılan bir ayırım metodudur.

Bu ayırım işlemini bir kümenin tüm veri noktalarını başka bir kümenin tüm noktalarından ayırt eden en uygun hiper düzlemi belirleyerek gerçekleştirmektedir. En uygun hiper düzlemin seçilmesi için marjın kavramının en büyük olması gerekmektedir. Marjın bölgesi, içerisinde herhangi bir veri noktası bulundurmayan ve hiper düzleme paralel olan maksimum genişlik anlamına gelmektedir. Hiper düzleme en yakın verilerden geçen noktalar destek vektörleri olarak isimlendirilir. SVM’de, ikili sınıflandırma fonksiyonlarının karar kuralı denklem 1’deki şekilde ifade edilebilmektedir (Abakar ve Yu, 2014; Subasi ve Gursoy, 2010; Mohammed vd., 2016; Huang vd., 2018).

$$f(z) = \text{sign}\left[\sum_{j=1}^n a_j y_j x_j z + b\right] \quad (1)$$

Denklem (1) 'de, x_j destek vektörlerini, a_j optimum Lagrange çarpanlarını, y_j ikili sınıf etiketlerini ifade eder. Parametre b ise fonksiyonun bias parametresi olarak bilinir. Bu çalışmada ise SVM ikili sınıflandırıcılar ile oluşturulan çok sınıflı hata düzeltme çıktı kodları (HDÇK) modeli kullanılmıştır. Bu modelde SVM ikili sınıflandırıcıları birebir kodlama tasarımı ile gerçekleştirilmiştir. HDÇK modeli üç veya daha fazla sınıf ile sınıflandırma sorununu bir dizi ikili sınıflandırma problemine indirger. HDÇK modeli diğer çoklu sınıflandırma problemleri ile karşılaştırıldığında sınıflandırma doğruluğunu iyileştirebilmektedir (Fürnkranz, 2002).

2.2.2. Topluluk Öğrenme Algoritmaları (Ensemble Learning Algorithms)

ELA, eğitim verileri ile birden fazla temel modelin tahmin sonuçlarını birleştirme yoluyla karar vermeyi amaçlar (Zhou, 2012). Buradaki amaç tek bir modele göre daha güçlü ve genellenebilir sonuçlar elde etmektir. Tahmin sonuçlarının bir araya getirilerek sonuç üretilmesi için çeşitli yöntemler mevcuttur. Çalışmada ELA’nın farklı metodları test edilmiş ve en yüksek doğruluğu AdaBoostM2 metodu ile sağlanmıştır. AdaBoost algoritması Boosting algoritmasının daha genel bir versiyonudur (Freund ve Schapire, 1996).

2.2.3. Karar Ağaçları (Decision Trees)

DT makine öğrenme metodları içerisinde insan düşünme mantığına en yakın yapılardan biridir. DT mantık olarak bulunulan durumun bilgi kazancını maksimum yapabilmek için rastgelelik değerini minimize edecek seçimler yapmaya çalışır. Bunu sağlamak için her düğümde hata fonksiyonun tekrardan hesaplar ve minimum hataya sahip durumu seçer. Herhangi bir ağaca benzer DT yapısı temel olarak üç parçadan oluşur. Bunlar yapraklar, dallar ve düğümlerdir. Bu yapıda, kullanılan özellikler düğümler ile temsil edilmektedir. Yapraklar ile dallar ise, ağaç

yapısının kalan diğer bileşenlerini oluşturmaktadır. DT çalışma prensibi, eldeki veriyi küçük parçalara ayırarak en kısa sürede sonucu elde etmek üzerinedir. DT’de, her bir düğüm bir sınıfı belirtmekte veya düğümdeki test verilerini oluşturan olası çıktılara göre numune alanını ayırarak bir test bölümü oluşturmaktadır. Ayrılan alt kümelerin her biri, yeni bir alt ağaç ile çözümlenerek yeni bir alt sınıflandırma problemi ortaya çıkaracaktır. Yapraklar olarak adlandırılan düğümler, sonuç düğümünün sınıfını içerir. Yaprak düğümü olmayan noktalar ise karar düğümleri olarak tanımlanır.

2.2.4. k-En Yakın Komşuluk Metodu (k- Nearest Neighborhood Method)

k-NN algoritması, kullanım kolaylığına sahip ve kolay anlaşılır temel makine öğrenimi algoritmaları arasında popülerdir. Metodun isminde de var olan “k” değeri, sınıflandırma yapabilmek için veri kümesindeki sonuçlardan kendisine en yakın seçilecek komşu sayısı olarak belirlenir. En yakın özellikleri belirleyebilmek için veri noktaları arasındaki uzaklığın belirlenmesi gereklidir. Bunun için farklı yöntemler vardır. Mesafe Chebyshev, Euclid, Hamming, Manhattan veya Minkowski yöntemleriyle ölçülebilmektedir.

3. Deneysel Sonuçlar (Experimental Results)

Yapılan çalışma süresince, hastalardan elde edilen veriler SVM, ELA, DT ve k-NN algoritma girişlerine uygulanmış ve doğruluk başarıları rapor edilmiştir. Doğrulukların birbirleri ile karşılaştırılması çapraz doğruluk yöntemleri ile test edilmiştir. Buna göre, doğrulama işlemi 3, 5 ve 10 kat çapraz doğrulama (KÇD) işlemleri gerçekleştirilmiştir. Her bir doğrulama işleminde doğruluk değerleri hem tüm veri tabanı ve hem de test verileri için hesaplanması yapılmıştır. Çalışmada hesaplanan doğruluk değeri aşağıda verilen denklem 2 ile hesaplanmaktadır:

$$\text{Doğruluk}(\%) = \frac{DT}{DT+YT} \times 100 \quad (2)$$

Bu formülde, DT parametresi, doğru tahmin edilen değer sayısını gösterirken, YT parametresi ise yanlış tahmin edilen değer sayısını göstermektedir. Algoritmalar arasında en yüksek doğruluk değerini sağlayan makine öğrenme algoritması en uygun sınıflandırma metodu olarak belirlenmiştir. Daha sonra ise en yüksek doğruluk değerini sağlayan algoritma çıkışında elde edilen sınıflar karmaşıklık matrisi ile gösterilmiştir. Çalışmada, çoklu sınıflandırma işlemi olduğu için hassasiyet ve duyarlılık analizleri yerine karmaşıklık matrisi gösterimi yer almaktadır.

Çalışmada Bayesian optimizasyon algoritması kullanılmış ve deneyler sonucunda maksimum karar bölme sayısı 20, minimum yaprak düğüm gözlem sayısı ise 1 seçilmiştir. Yine Bayesian optimizasyon

algoritması kullanarak en başarılı yöntem Minkowski olarak belirlenmiştir. Moçkus (Moçkus, 1974) tarafından geliştirilmiş Bayesian optimizasyonu, makine öğrenmesi alanında etkili bir tekniktir ve değerlendirilmesi pahalı bir amaç fonksiyonu için en iyi seçimdir. Bayesian optimizasyon algoritması, x için bir skaler amaç fonksiyonu olan $f(x)$ 'i minimize etmeyi amaçlayan bir kara kutu tekniğidir. Fonksiyonun deterministik veya stokastik olmasına bağlı olarak, çıkış aynı x girişi için farklı olacaktır. Bayesian optimizasyon algoritmasında genellikle Gauss süreci (Gauss Process), olasılık modeli olarak seçilir (Rasmussen, 2003). Minimizasyon süreci üç ana bileşenden oluşur: $f(x)$ amaç fonksiyonu için bir Gauss süreç modeli, amaç fonksiyonunun her yeni değerlendirmesinden sonra Gauss modelini değiştiren bir Bayesian güncelleme süreci ve bir $a(x)$ kazanım fonksiyonu. Bu kazanım fonksiyonu, bir sonraki değerlendirme noktasını belirlemek için maksimize edilir. Bu fonksiyonun rolü, amaç fonksiyonunda beklenen gelişmeyi ölçerken, onu artıracak değerleri atmaktır (Brochu, 2010).

Analizlerde kullanılan makine öğrenme algoritmalarının performanslarının karşılaştırıldığı doğruluk değerleri Tablo 2’de gösterilmektedir.

Tablo 2. Metotların ortalama k-kat çapraz doğrulama karşılaştırmaları (Mean k-fold cross validation comparisons of methods)

KÇD	Metot	Doğruluk (%)	
		Test Verileri (%)	Tüm Veri (%)
3-KÇD	SVM	99,73	99,73
	ELA	96,72	98,91
	DT	95,08	97,36
	k-NN	96,99	98,99
5-KÇD	SVM	99,73	99,73
	ELA	95,91	99,18
	DT	94,27	97,38
	k-NN	96,17	99,24
10-KÇD	SVM	99,73	99,73
	ELA	96,73	99,67
	DT	94,81	97,62
	k-NN	96,70	99,67

Tablo 2’de gösterilen sonuçlara göre, SVM algoritmasının en etkili metot olduğu açıkça görülmektedir. Tabloda, çapraz doğrulama işlemleri 3, 5 ve 10-KÇD uygulanarak elde edilen sonuçlar gösterilmiştir. Diğer taraftan doğruluk değerleri karşılaştırıldığında gerek test verileri yönünden ve gerekse tüm veriler yönünden, en yüksek tahmin doğruluk değerinin her KÇD bölümünde SVM metodunun üstün ve doğruluk yüzdesinin %99.73 şeklinde olduğu açıktır. Böylelikle, çalışmada gerçekleştirilen optimizasyon teknikleri ve deneysel

çalışmalar, eritematöz skuamöz hastalıkların ayırıcı tanısında SVM yönteminin çok etkili olduğu ve klinik uygulamalarda tanı ve teşhise yardımcı bir yöntem olarak kullanılabileceğini ortaya sermektedir. Bununla beraber, DT metodunun ise bu tür sınıflandırma için diğer metotlardan çok daha yetersiz kaldığı ortaya çıkmaktadır.

Bu çalışmada elde edilen sonuçlar literatürde gerçekleştirilmiş olan diğer çalışmalar ile karşılaştırıldığında, SVM yönteminin hayli başarılı bir yöntem olduğu burada da ortaya çıkmaktadır. SVM sonucunda elde edilen karmaşıklık matrisi Tablo 3'te gösterilmektedir. Bu tabloya göre Sedef hastalığı sınıf 1'i, seboreik dermatit sınıf 2'yi, liken planus sınıf 3'ü, pityriasis rosea sınıf 4'ü, kronik dermatit sınıf 5'i ve pityriasis rubra pilaris sınıf 6'yı göstermektedir. Zaten doğruluk çok yüksek olmakla birlikte algoritma sadece seboreik dermatit hastalığından bir tanesini pityriasis rosea olarak değerlendirmiştir ve bu da doğruluğun çok yüksek olduğunu göstermektedir.

Tablo 3. SVM ile elde edilmiş karmaşıklık matrisi (Confusion matrix obtained by SVM)

Eritematöz skuamöz hastalıklarının Sınıflandırılması						
True Class	1	2	3	4	5	6
1	112					
2		60		1		
3			72			
4				49		
5					52	
6						20
	1	2	3	4	5	6

Dermatoloji veri seti için sonuçların diğer yayınlanmış yöntemlerle karşılaştırılması Tablo 4'te verilmiştir.

Tablo 4. Dermatoloji veri seti için sınıflandırma yöntemlerinin karşılaştırılması (Comparison of classification methods on the dermatology dataset)

Çalışma	Yöntem	Doğruluk (%)
Guvenir ve ark. (1998)	VFI5	99.2
Fidelis ve ark. (2000)	Genetik Algoritma	95
Karabatak ve İnce (2009)	Birlikte Kuralları + Sinir Ağları	98.61
Xie ve Wang (2011)	SVM	98.61
Çifci ve ark. (2014)	Çok Katmanlı Yapay Sinir Ağı	98
Parikh ve Shah (2017)	SVM	97.27
Elsayad ve ark. (2018)	CHAID + Bagging ve Boosting	93.81
	CART	94.84
Idoko ve ark. (2018)	ARFCMC	75.96
	ANFIS	95.50

	AEC	97.32
	FNN	98.37
	LR	97.94
	LDA	96.22
Chaurasia ve Pal (2020)	k-NN	85.57
	SVM	92.10
	CART	93.50
	NB	89.02
	PAC	97.38
	LDA	98.98
Verma ve ark. (2020)	RNC	99.68
	BNB	95.36
	NB	98.66
	ETC	97.65
	NB	97.54
	SVM	96.99
Rashid ve ark. (2020)	k-NN	95.62
	J48	95.90
	RF	97.54
	LR	96.99
	Derm2Vec	96.92
	Derin Sinir Ağı	96.65
	XGBoost	95.80
	DT	93.10
Putatunda (2020)	Yapay Sinir Ağı	74.29
	SVM	82.13
	RF	51.13
	NB	92.68
	k-NN	79.30
Shastri ve ark. (2021)	GBoost	99.45
Bu çalışma	SVM	99.73

Dermatoloji veri seti ile ilk çalışmayı yapan Guvenir ve ark. (1998), VFI5 adlı yeni bir sınıflandırma algoritması ile doğruluk oranını %99.2 olarak bulmuşlardır. Genetik algoritma kullanan Fidelis ve ark. (2000), doğruluk oranını %95 olarak elde etmişlerdir. Birlikte kuralları ve sinir ağları tabanlı yeni bir özellik seçme yöntemi sunan Karabatak ve İnce (2009), önerdikleri yöntemin doğru sınıflandırma oranını %98.61 olarak bulmuşlardır. Xie ve Wang (2011), SVM tabanlı ardışık ileri yönde seçim algoritması ile %98.61 sınıflandırma doğruluğu elde etmişlerdir. Çifci ve ark. (2014), çok katmanlı yapay sinir ağı oluşturarak ağı korelasyon katsayısını 0.98 olarak bulmuşlardır. Parikh ve Shah (2017), sınıflandırıcı olarak SVM ile sarmal yöntemini kullanarak %97.27 doğruluk elde etmişlerdir. Torbalama ve artırma uygulanarak oluşturulan CHAID karar ağacı algoritmasını kullanan Elsayad ve ark. (2018), %93.81 doğruluk oranına ulaşmıştır. Idoko ve ark. (2018), tasarladıkları FNN tanımlama sistemi ile %98.37 doğruluk oranı elde etmişlerdir. Dermatoloji veri setine birçok yöntem uygulayan Chaurasia ve Pal (2020), LR ile %97.94'lük doğruluk oranına ulaşmışlardır. Verma ve ark. (2020) ise en yüksek doğruluk oranına %99.68 ile RNC yöntemiyle ulaşmışlardır. NB ve RF yöntemleriyle en yüksek doğruluk oranını elde eden Rashid ve ark. (2020), %97.54 olarak doğruluk oranını bulmuşlardır. Putatunda (2020), dermatoloji veri setine tablodan da görüleceği

üzere birçok yöntem uygulamıştır. Derm2Vec (%96.92), derin sinir ağları (%96.65) ve XGBoost Sınıflandırıcı (%95.80) yöntemlerinde en yüksek skorlara ulaşmıştır. Aynı veri seti üzerinde çok yeni bir çalışmada, Shastri ve ark. (2021), GBoost kullanarak %99.45 gibi yüksek bir tahmin başarısına ulaşmışlardır. Tablodan da açıkça görülebileceği üzere dermatoloji veri seti için bu çalışmada elde edilen sonuçlar literatürde gerçekleştirilmiş olan diğer çalışmalar ile karşılaştırıldığında, SVM yönteminin hayli başarılı bir yöntem olduğu ortaya çıkmaktadır.

4. Sonuçlar (Conclusions)

Bilindiği üzere, dermatologlar deri hastalıklarının teşhisini ilgili alanın görsel incelemesine ve ilgili alandan alınan biyopsi ile histolojik örneklerin değerlendirilmesine dayandırır. Burada teşhisin doğruluğu hekimin deneyimine büyük ölçüde bağlıdır. Dolayısıyla insan faktörlü yanlış teşhislerin önlenmesi için bilgisayar destekli teşhis araçlarına ilgi gün geçtikçe artmaktadır. Makine öğrenmesi yöntemleri ve araçları geliştikçe, erken teşhisle birlikte maliyetler düşecek ve dermatoloji alanındaki rolü vazgeçilmez hale gelecektir. Bu çalışmada, eritematöz skuamöz hastalıkların teşhisi ve ayrıca daha iyi sınıflandırma doğruluğu için çeşitli makine öğrenmesi metotları kullanılmıştır. Bu çalışmanın literatüre olan temel katkısı, deri hastalıklarının erken teşhisi için yapılan en iyi algoritmayı bulmaktır. Çalışmada, SVM algoritması %99,73 değeri ile en iyi doğruluk sonucunu vermiştir. İkinci en iyi doğruluk değeri ise k-NN metodu ile çapraz doğrulama işlemi 10-KÇD seçilerek %99,67 elde edilmiştir.

Kaynaklar (References)

Abakar, K.A., Yu, C., 2014. Performance of SVM based on PUK kernel in comparison to SVM based on RBF kernel in prediction of yarn tenacity. *Indian Journal of Fibre & Textile Research*, 39, 55-59.

Borda, L.J., Wikramanayake, T.C., 2015. Seborrheic dermatitis and dandruff: a comprehensive review. *Journal of Clinical and Investigative Dermatology*, 3(2), 1-22.

Brochu, E., Cora, V. M., De Freitas, N., 2010. A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. *arXiv preprint arXiv:1012.2599*.

Chaurasia, V., Pal, S., 2020. Machine learning algorithms using binary classification and multi model ensemble techniques for skin diseases prediction. *International Journal of Biomedical Engineering and Technology*, 34(1), 57-74.

Çifci, A., İlkuçar, M., Bozkurt, M.R., Uyaroğlu, Y., 2014. Liken planus ve sedef deri hastalıklarının çok katmanlı yapay sinir ağı kullanılarak sınıflandırılması. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5 (1), 30-36.

Dua, D., Graff, C., 2019. UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science.

Dumas, N.S, Ntambi, M.J., 2018. A discussion on the relationship between skin lipid metabolism and whole-body glucose and lipid metabolism: systematic review. *Journal of Cell Signaling*, 3(3), 191.

Elsayad, A.M., Al-Dhaifallah, M., Nassef, A.M., 2018. Analysis and diagnosis of erythematous-squamous diseases using CHAID decision trees. *IEEE 15th International Multi-Conference on Systems, Signals & Devices (SSD)*. 19-22 March 2018, Yasmine Hammamet, Tunisia, pp. 252-262.

Fidelis, M.V., Lopes, S.H., Freitas, A.A., 2000. Discovering comprehensible classification rules with a genetic algorithm. *Proceedings of the 2000 Congress on Evolutionary Computation*, 16-19 July 2000, La Jolla, CA, USA, pp. 805-810.

Fonacier, L.S., Dreskin, S.C., Leung D.Y.M., 2010. Allergic skin diseases. *Journal of Allergy and Clinical Immunology*, 125(2), 138-149.

Freund, Y., Schapire, R.E., 1996. Experiments with a new boosting algorithm. *Machine Learning: Proceedings of the Thirteenth International Conference*, July 1996, pp. 148-156.

Fürnkranz, J., 2002. Round robin classification. *The Journal of Machine Learning Research*, 2, 721-747.

Gurusamy, L., Selvaraj, U., 2016. Clinicopathological study of lichen planus in a tertiary care center. *International Journal of Scientific Study*, 4(1), 244-247.

Güvenir H.A., Demiroz G., İltis N., 1998. Learning differential diagnosis of erythematous-squamous diseases using voting feature intervals. *Artificial Intelligence in Medicine*, 13, 147-165.

Huang, S., Cai, N., Pacheco, P.P., Narrandes, S., Wang, Y., Xu, W., 2018. Applications of support vector machine (SVM) learning in cancer genomics. *Cancer Genomics-Proteomics*, 15(1), 41-51.

Idoko, J.B., Arslan, M., Abiyev, R. 2018. Fuzzy neural system application to differential diagnosis of erythematous-squamous diseases. *Cyprus J Med Sci*, 3(2), 90-97.

Karabatak M., Ince M.C., 2009. A new feature selection method based on association rules for diagnosis of erythematous-squamous diseases. *Expert Systems with Applications*, 36(10), 12500-12505.

Lee, S.H., Jeong, S.K., Ahn, S.K., 2006. An update of the defensive barrier function of skin. *Yonsei Medical Journal*, 47(3), 293-306.

Lu, Y., Tian, Q., 2009. Discriminant subspace analysis: An adaptive approach for image classification. *IEEE Transactions on Multimedia*, 11(7), 1289-1300.

Lyons, F., Ousley, L., 2014. *Dermatology for the advanced practice nurse*. Springer Publishing Company, New York.

Močkus, J., 1974. On Bayesian methods for seeking the extremum. *Optimization Techniques IFIP Technical Conference*. 1-7 July 1974, Springer, Berlin, Heidelberg, pp. 400-404.

Mohammed, M., Khan, M.B., Bashier, E.B.M., 2016. *Machine learning: algorithms and applications*. CRC Press.

Nedorost, S.T., 2012. *Generalized dermatitis in clinical practice*. Springer Science & Business Media, Berlin.

Parikh, K.S., Shah, T.P., 2017. Feature selection paradigm using weighted probabilistic approach. *International Journal of Advanced Science and Technology*, 100, 1-14.

- Putatunda, S., 2020. A hybrid deep learning approach for diagnosis of the erythemato-squamous disease. *IEEE International Conference on Electronics, Computing and Communication Technologies*. 2-4 July 2020, Bangalore, India, pp. 1-6.
- Rashid, A.N.M.B., Ahmed, M., Sikos, L.F., Haskell-Dowland, P., 2020. A novel penalty-based wrapper objective function for feature selection in Big Data using cooperative co-evolution. *IEEE Access*, 8, 150113-150129.
- Rasmussen, C.E., 2003. Gaussian processes in machine learning. *Summer School on Machine Learning*. Springer, Berlin, Heidelberg, pp. 63-71.
- Shastri, S., Kour, P., Kumar, S., Singh, K., Mansotra, V. 2021. GBoost: A novel Grading-AdaBoost ensemble approach for automatic identification of erythemato-squamous disease. *International Journal of Information Technology*, 13(3), 959-971.
- Subasi, A., Gursoy, M.I., 2010. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert systems with applications*, 37(12), 8659-8666.
- Tabassum, N., Hamdani, M., 2014. Plants used to treat skin diseases. *Pharmacognosy Review*, 8(15), 52-60.
- Verma, A.K., Pal, S., Kumar, S., 2020. Prediction of skin disease using ensemble data mining techniques and feature selection method—a comparative study. *Applied Biochemistry and Biotechnology*, 190(2), 341-359.
- Wang, D., Chong, V.C-L., Chong, W-S., Oon, H.H., 2018. A review on pityriasis rubra pilaris. *American Journal of Clinical Dermatology*, 19(3), 377-390.
- Xie, J., Wang, C., 2011. Using support vector machines with a novel hybrid feature selection method for diagnosis of erythemato-squamous diseases. *Expert Systems with Applications*, 38(5), 5809-5815.
- Yousef, H., Alhajj, M., Sharma, S., Anatomy, 2021. *Skin (Integument), Epidermis*. Treasure Island, FL: StatPearls Publishing.
- Zhou, Z.H., 2012. *Ensemble Methods: Foundations and Algorithms*. New York, USA, Chapman and Hall/CRC.