



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Papüloskuamöz Hastalıkların Belirlenmesi için Yapay Zeka Yöntemleriyle Kural Tabanlı Teşhis Algoritmalarının Geliştirilmesi

 Muhammed Kürşad UÇAR^{a,*},  Serkan DÜZAYAK^b

^a Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Sakarya Üniversitesi, Sakarya, TÜRKİYE

^b Deri ve Zührevi Hastalıkları Anabilim Dalı, Karasu Devlet Hastanesi, Sakarya, TÜRKİYE

* Sorumlu yazarın e-posta adresi: mucar@sakarya.edu.tr

DOI: 10.29130/dubited.706225

ÖZET

Papüloskuamöz deri hastalıkları halk arasında oldukça sık rastlanan ve kendine has morfolojik özellikleri olan deri hastalıkları grubudur. Papüloskuamöz deri hastalıklarının alt gruplarının belirtileri birbirine çok yakın olduğu için teşhis süreci bazı durumlarda zahmetlidir. Hastalığın teşhisi klinik muayenede konulabilir. Klinik muayenenin yetersiz olduğu durumlarda, tanı deri biyopsisi ile histopatolojik değerlendirme ile konulmaktadır. Bu süreçte dermatolog ve patoloğun uyumlu bir şekilde çalışması ve her iki hekimin de teşhis süreci ile ilgili bilgi birikiminin iyi olması gerekir. Bu yüzden Papüloskuamöz deri hastalıklarının tanısı deri biyopsisine ihtiyaç duyulmadan sadece klinik muayene ile dermatolog tarafından konulabilmesi için daha basit, yüksek başarı oranına sahip ve klinikte kullanılabilir yöntemlere ihtiyaç duyulmaktadır. Bu çalışmanın amacı Papüloskuamöz deri hastalıklarının yüksek başarı oranı ile tespit edebilecek, klinikte dermatolog tarafından kullanılacak, yapay zeka yöntemleriyle geliştirilmiş kural tabanlı algoritma geliştirmektir. Çalışma kapsamında daha önce toplanmış veri seti kullanılmıştır. Veri setinde Papüloskuamöz deri hastalıklarının altı farklı alt grubu için klinik ve histopatolojik bulgular bulunmaktadır. Öncelikle veri seti ikişer sınıflı olacak şekilde gruplandırılmıştır. Daha sonra özellik seçme algoritmalarıyla klinik ve histopatolojik bulgular seçilmiştir. Daha sonra karar ağaçları yardımıyla kural tabanlı teşhis algoritmaları oluşturulmuştur. Çalışma sonucunda, sadece seçilmiş klinik bulgular kullanılarak ortalama %82.98 doğruluk oranı, 0.89 duyarlılık, 0.76 özgüllük oranıyla Papüloskuamöz deri hastalıkları kural tabanlı algoritmalar geliştirilmiştir. Sonuç olarak, bu çalışmada elde edilen sonuçlara göre, çalışma kapsamında geliştirilen algoritmalar, Papüloskuamöz deri hastalıklarının teşhisi için yapay zeka yöntemleriyle geliştirilen yüksek doğruluk oranına sahip kural tabanlı algoritmalar klinikte kullanılabilir.

Anahtar Kelimeler: Papüloskuamöz deri hastalıkları, Klinik bulgular, Yapay zeka, Kural tabanlı teşhis algoritması, Karar ağaçları

Development of Rule-Based Diagnostic Algorithms with Artificial Intelligence Methods to Identify Papulosquamous Diseases

ABSTRACT

Papulosquamous skin diseases are common skin diseases and have morphological features. The diagnosis process is sometimes troublesome, as the symptoms of the subgroups of papulosquamous skin diseases are very close to each other. The diagnosis of the disease can be made at the clinical examination. In cases where the clinical examination is insufficient, the diagnosis is made by histopathological evaluation by skin biopsy. In this process, dermatologists and pathologists should work in harmony, and both doctors should have a good knowledge of the diagnosis process. Therefore, more uncomplicated, higher success rate, and clinically practical methods are needed in order for Papulosquamous skin diseases to be established only by a clinical examination by a dermatologist

without the need for a skin biopsy. This study aims to develop a rule-based algorithm that can detect Papulosquamous skin diseases with a high success rate, can be used by dermatologists in the clinic, developed with artificial intelligence methods. Within the scope of the study, the previously collected data set was used. The data set contains clinical and histopathological findings for six different subgroups of Papulosquamous skin diseases. Firstly, the data set is grouped into two classes. Then, clinical and histopathological findings were selected with feature selection algorithms. Then, rule-based diagnostic algorithms were created with the help of decision trees. As a result of the study, Papulosquamous skin diseases rule-based algorithms have been developed with an average of 82.98% accuracy rate, 0.89 sensitivity, and 0.76 specificity rate using only selected clinical findings. Consequently, according to the results obtained in this study, algorithms developed within the scope of the study, high-accuracy rule-based algorithms developed with artificial intelligence methods can be used in the clinic for the diagnosis of Papulosquamous skin diseases.

Keywords: Papulosquamous skin diseases, Clinical findings, Artificial intelligence, Rule-based diagnostic algorithm, Decision trees

I. GİRİŞ

Papüloskuamöz deri hastalıkları, kendine has morfolojik özellikleri olan bir deri hastalıkları grubudur. Papüloskuamöz deri hastalıklarından en sık rastlanılanları Psoriasis, Liken planus, Seboreik dermatit, Kronik ekzema, Pitriyazis rosea, Pitriyazis rubra pilaris'dir [1].

Hastalıkların teşhisi klinik ve fiziksel muayene ile konulur. Ancak ileri tetkik gereken durumlarda hastalıklı bölgeden alınan biyopsi özel olarak incelenir. Histopatolojik analiz sonucunda teşhis konulabilir. Tedavi süresince bazı zorluklar vardır. Dermatolojik hastalıklarda aynı bulguların pek çok hastalıkta ortaya çıkması sebebiyle bulguların yorumlanması oldukça zordur. Bu nedenle deri biyopsisinde Histopatolojik bulgular değerlendirmede önemli rol oynamaktadır [2]–[4].

Histopatolojik incelemede amaç dermatoloğun tanısını onaylamak veya tanısı konulamamış durumlarda dermatoloğa yol göstermektir. Şüpheli vakaların sağlıklı bir şekilde sonuçlandırılabilmesi için dermatolog ve patoloğun uyumlu bir şekilde çalışması gerekmektedir. Tanı için işbirliğinin yanı sıra dermatoloğun dermapatolojik temel bilgilere, patoloğun ise temel dermatoloji bilgilerine sahip olması hayati öneme sahiptir [2], [4], [5]. İncelemenin sağlıklı yapılabilmesi için kişinin demografik bilgilerinin doğru ve eksiksiz verilmesi gerekir [5]. Ayrıca histopatolojik tanıda başarı, biyopsi yerinin belirlenmesi, alınması ve değerlendirilmesi başta olmak üzere sürecin doğru yönetilmesi ile doğrudan ilişkilidir [6].

Deri hastalıkları dış görünüşü etkilediği için bireyleri, psikolojik, sosyal ve mesleki açıdan doğrudan etkilemektedir [7]. Bireyler teşhisin bir an evvel konulması ve tedavinin sonuçlanmasını arzu etmektedir. Klinik muayene ile teşhis konulamadığında histopatolojik incelemeye ihtiyaç duyulması durumunda tanı iki-dört hafta kadar uzamaktadır. Tanı için tüm bu süreçler göz önüne alındığında histopatolojik sürecin yerini alabilecek sadece dermatoloğun klinik bulguları ile yüksek doğruluk oranına sahip teşhis sistemlerinin geliştirilmesi elzemdir.

Literatürde teşhis doğruluk oranının artırılabilmesi için Papüloskuamöz hastalıkların tanısı için bazı algoritmalar geliştirilmiştir [8]. Bu algoritmalarda klinik ve histopatolojik bulgular birlikte kullanılarak yeni bir teşhis algoritması oluşturulmuştur [8]. Biyopsi işleminin yerine kullanılacak bir algoritma mevcut değildir. Ayrıca algoritmanın okunabilirliği oldukça zordur. Çalışma sonucunda oluşturulan veri seti açık kaynaklı olarak paylaşılmıştır [8], [9]. Daha sonra farklı bilim insanları bu veri setlerini kullanarak yapay zeka tabanlı farklı teşhis algoritmaları geliştirmiştir [10]–[13]. Bazı çalışmalarda ise özellik seçme algoritmaları kullanılmış ve teşhis performansı artırılmaya çalışılmıştır [14]–[18]. Bu çalışmalar kapsamında destek vektör makineleri (Support Vector Machines - SVMs), k-ortalama kümeleme (k-means clustering), yapay sinir ağları (Artificial Neural Network - ANN), karar ağaçları, veri madenciliği, topluluk sınıflandırıcıları, bulanık mantık (Fuzzy Logic – Fuzzy Lojik) gibi birçok yapı kullanılmıştır [19]–[21]. Bu yapıların yanı sıra, özellik puan (Feature Score / F-Score) ve SVMs tabanlı

özellik seçme algoritmaları yardımıyla performans artırılmaya çalışılmıştır [18], [22], [23]. Bu kapsamda özellik veri setleri ayrıştırılmadan tüm özelliklerden seçim yapılarak sınıflandırma işlemleri gerçekleştirilmiştir. Çalışmalarda elde edilen doğruluk oranları %80-100 arasında değişmektedir [20], [24], [25].

Literatürde yapılan bu çalışmalar genel olarak incelendiğinde, veri setinde bulunan 34 özellik ya da direkt yapay zeka algoritmaları ile sınıflandırılmış [11], [12], ya da özellik seçme algoritmaları ile sınıflandırılmıştır [18], [22], [23]. Tasarlanan sistemler oldukça karmaşıktır. Klinikte kullanım için doktorun kullanımına uygun değildir. Bir klinisyenin geliştirilen algoritmayı kullanabilmesi için öncelikle histopatolojik bulguların bilinmesi gerekmektedir. Oysa sadece klinik bulgulara göre her bir hastalık için bir teşhis algoritması geliştirilse, hem deri biyopsi işlemine gerek duyulmayacak hem de hem de teşhis süresi kısaltacaktır. Deri hastalıklarında dış görünüş etkilendiği için teşhisin erken yapılması ve tedavinin acilen başlatılması elzemdir.

Bu çalışmanın amacı, Papüloskuamöz deri hastalıklarının tanısında histopatolojik incelemeye gerek duyulmadan, sadece klinik bulgular ile hastalığın teşhis edilebilmesi için yapay zeka yöntemleriyle kural tabanlı teşhis algoritmaları geliştirebilmektir. Bu amaçla daha önce toplanmış ve içerisinde en sık rastlanılan Papüloskuamöz çeşitleri bulunan veri seti kullanılmıştır. Veri setinde bireylere ait hem klinik hem de histopatolojik bulgular mevcuttur.


Çalışma şu şekilde organize edilmiştir. Öncelikle bulgular klinik ve histopatolojik olmak üzere gruplandırılmıştır. Özellik seçme algoritmaları yardımıyla hastalıklarla ilişki düzeyi yüksek bulgular seçilmiştir. Daha sonra altı farklı Papüloskuamöz çeşidi için karar ağaçları yardımıyla kural tabanlı teşhis algoritması hazırlanmıştır.

Çalışma sonucunda elde edilen bulgulara her bir hastalık çeşidi için oluşturulan modeller ortalama 82.98 doğruluk oranı, 0.89 duyarlılık, 0.76 özgüllük performans değerleri ile çalışmaktadır.

II. MATERYAL VE YÖNTEM

Çalışma

Şekil 1'de belirtildiği üzere gerçekleştirilecektir. Öncelikle veriler elde edilecek ve özellik gruplarına göre (Klinik ve Histopatolojik bulgular) ayrılacaktır. Daha sonra bulgular özellik seçme algoritmaları ile seçilecek ve karar ağaçlarıyla kural tabanlı sınıflandırma işlemi yapılacaktır.



Şekil 1. Çalışma akış diyagramı

A. VERİLERİN TOPLANMASI

Çalışmada kullanılan verilerin UCI Machine Learning Repository sitesinden indirilmiştir [8], [9]. Veri seti 366 bireyden alınan örnekler ve bu örneklere verilen teşhis değerlerinden oluşmaktadır (Tablo 1). Teşhis için altı farklı Papüloskuamöz deri hastalıkları etiketi kullanılmıştır (Tablo 1).

Tablo 1. Veri setinin dağılımı

Hastalık	n	Yüzde (%)
1 Psoriasis	112	30.60
2 Liken planus	72	19.67
3 Seboreik dermatit	61	16.67
4 Kronik ekzema	52	14.21
5 Pitriyazis rosea	49	13.39
6 Pitriyazis rubra pilaris	20	5.46
Toplam	366	100

B. HASTALIK BULGULARI

Hastalık teşhis süreci şu şekilde gerçekleştirilmektedir. Kliniğe başvuru yapan birey klinik olarak incelenir ve klinik bulgular belirli standartlar altında toplanır. Daha sonra deriden alınan numune histopatolojiye gönderilecek hastalık teşhisi gerçekleştirilir. Her bir bireye ait hem klinik hemde histopatolojik bulgular yer almaktadır.

Her bir hasta için 12 adet klinik ve 22 adet histopatolojik bulgular incelenmiştir. İncelenen her bir parametre Tablo 2’de özetlenmiştir.

Tablo 2. Klinik ve Histopatoloji bulguların / özelliklerin dağılımı

Klinik Bulgular	
1 Eritem –x1	7 Folliküler papüller–x7 – x4
2 Pulanma–x2	8 Oral mukoza tutulumu–x8 – x3
3 Keskin sınırlar–x3	9 Diz ve dirsek tutulumu–x9
4 Kaşıntı–x4	10 Saçlı deri tutulumu–x10
5 Köbner fenomeni–x5	11 Aile hikayesi (1 veya 0) –x11
6 Poligonal papüller–x6 – x1	34 Yaş–x12 – x2
Histopatolojik Bulgular	
12 Melanin inkontinansı	23 Spongioform püstül
13 İnfiltratta eozinofil varlığı	24 Munro mikroabsesi
14 İnfiltratta nötrofil varlığı	25 Fokal hipergranüloz
15 Papiller dermiste fibrozis	26 Granuler tabakanın kaybolması
16 Ekzositoz	27 Bazal tabaka hasarı ve vakuolizasyon
17 Akantozis	28 Spongiyozis
18 Hiperkeratoz	29 Retelerde testere dişi görünüm
19 Parakeratoz	30 Folliküler boynuzsu tıkaç
20 Retelerde çomaklaşma	31 Perifoliküler hiperkeratoz
21 Retelerde uzama	32 Mononükleer hücre infiltrasyonu
22 Suprapapiller epidermisin incilmesi	33 Bant tarzında infiltrat

Aksi belirtilmediği sürece tüm bulgular 0, 1, 2, veya 3 değerini alır.
0 bulgu yok, 1-3 arası bulgu şiddetini temsil etmektedir.

C. FISHER ÖZELLİK SEÇME ALGORİTMASI

Fisher Score sınıflandırma işlemi için en uygun özellikleri belirleyen bir yöntemdir [26]. Yöntem hesaplamaları ayırıcı yöntemler ve üretken istatistiksel modellere dayanır. Her bir özellik için Fisher Score değeri hesaplanır. En yüksek puanı alan özellik sınıflar ile en uyumlu özelliği gösterir. Özellikler Fisher Score değeri büyükten küçüğe doğru sıralanır. Kullanıcı istediği miktarda özelliği olarak sınıflandırma yapabilir.

Bu çalışmada klinik ve histopatolojik bulgular fisher özellik seçme algoritması ile seçilerek hastalık teşhisi yapılmaya çalışılmıştır. Klinik bulgular ve tüm bulgular birlikte iki farklı veri seti olarak değerlendirilmiş ve özellik seçme algoritması bu iki veri grubu için çalıştırılmıştır. Bu veri gruplarına ait özellikler Fisher algoritması ile soldan sağa doğru (ilişki düzeyi en yüksekte küçüğe) sıralanmıştır (Tablo 3). Tablo üzerinde %5-50 arasında verilerin gruplandırılışı gösterilmektedir. Örneğin klinik bulgulardaki 12 özelliğin %5-50'si seçilmiştir. Klinik bulguların %45'i için 5 adet özellik seçilmiştir (Özellik No 6-34-8-7-9).

Tablo 3. Özellik seçme algoritması sonucu seçilen özelliklerin dağılımı

		Özellik Miktarı (%)															
Yüzde		50															
		45															
		40															
		35															
		30															
		25															
		20															
		15															
		10															
		5															
Klinik Bulgular	6	34			8				7		9		10				
Tüm Bulgular	34	33	27	29	31	6	12	15	25	8	20	22	21	30	7	9	16
		Özellik Numaraları															

D. KARAR AĞAÇLARI

Bu çalışmada sınıflandırma algoritması olarak karar ağaçları yöntemi seçilmiştir. Bu yöntemin seçilmesinin amacı kural tabanlı hastalık teşhis sürecini ortaya çıkarabilmek ve klinikte uygulanabilir bir sistem tasarlamaktır. ANN, SVMs gibi diğer makine öğrenmesi algoritmaları kara kutuya benzer şekilde işlemleri içerisinde yapmakta, dışarıdan kuralları görebilmek mümkün değildir [27], [28]. Bu yüzden klinikte kullanılabilecek kurallar bütünü verme makine öğrenmesi yöntemlerinden biri olan karar ağaçları tercih edilmiştir.

E. DENGELEME

Çalışmadaki veri dağılımı Tablo 1'de önceki bölümde verilmişti. Çalışmanın amacına uygun olacak şekilde veri setleri 2 sınıflı olacak şekilde tekrar revize edilmiştir. Örneğin 1 nolu Psoriasis hastalığının teşhis algoritmasının geliştirilmesi için 1 ve Diğerleri (1-D) şeklinde veri setleri tekrar etiketlenmiştir (Tablo 1). Ancak bu durumda veri dağılımının orantılı bir şekilde yeniden düzenlenmesi gerekmektedir. Gruplandırmalar yapılırken şu şekilde bir prosedür izlenmiştir.

1. Teşhis edilmek istenen hastalık belirlenir. Bu durumda X hastalığı ve diğerleri şeklinde gruplama yapılacaktır. (Örneğin 1 Psoriasis, 1-D)
2. Seçilen gruptaki tüm örnekler alınır. (Örneğin 1 Psoriasis - 112 hasta örneği - Tablo 1)
3. Diğer gruplardan da toplam 112 adet örnek seçilecektir. Bu durumda her gruptan $112/5 \cong 22$ adet örnek seçilecektir. Seçilecek örnekler sistematik örnekleme teoremine göre seçilmiştir [29].
4. Bu işlem tüm hasta grupları için tekrarlanacaktır. İşlem sonucunda 1-D, 2-D, 3-D, 4-D, 5-D, 6-D olmak üzere 6 hastalık çeşidi için 6 farklı veri seti oluşacaktır.
5. Her bir veri seti için özellik seçme algoritmaları uygulanacak, sınıflandırma işlemi yapılacak ve her bir hastalık için karar ağacı kuralları, yani hastalık teşhis algoritması çıkarılacaktır.

Verilerin dengelenmesi sonucunda Tablo 4'teki dağılım meydana gelmiştir. Tabloda koyu gösterilen sayılar ilk sınıf diğerlerini göstermektedir.

Tablo 4. Dengelenmiş veri setleri

Dengelenmiş Veri Seti İsmi	Gruplar Alınan Örnek Miktarları						Dengelenmiş Veri Dağılımı		
	1	2	3	4	5	6	İlk Sınıf	Diğer Sınıflar	Toplam
1-D	112	22	22	22	22	22	112	110	222
2-D	12	61	12	12	12	12	61	60	121
3-D	14	14	72	14	14	14	72	70	142
4-D	10	10	10	49	10	10	49	50	99
5-D	10	10	10	10	52	10	52	50	102
6-D	4	4	4	4	4	20	20	20	40

F. PERFORMANS DEĞERLENDİRME KRİTERLERİ

Çalışma kapsamında doğruluk oranı (D), duyarlılık (Duy), özgüllük (Özg), F-Ölçümü (F-Measure – F-Ö), Kappa ve alıcı işletim karakteristiği (Receiver Operating Characteristic - ROC) altındaki alan (Area Under The Curve - AUC) olmak üzere 6 farklı performans değerlendirme kriteri kullanılmıştır [27], [28].

G. EĞİTİM VE TEST SÜRECİ

Sınıflandırma işlemleri için eğitim ve test matrisleri oluşturulmuştur. Veri setinin %25'i test için, %75'i eğitim için kullanılmıştır. Veri setlerinin dağılımı Tablo 5'te verilmiştir.

Tablo 5. Eğitim ve test süreci için veri dağılımı

Gruplar	Eğitim (%75)		Test (%25)		Toplam	
	İlk Sınıf	Diğer Sınıflar	İlk Sınıf	Diğer Sınıflar	İlk Sınıf	Diğer Sınıflar
1-D	84	83	28	27	112	110
2-D	45	46	16	14	61	60
3-D	54	53	18	17	72	70
4-D	36	39	13	11	49	50
5-D	39	38	13	12	52	50
6-D	15	15	5	5	20	20

III. SONUÇLAR

Bu çalışmanın amacı Papüloskuamöz deri hastalıkları teşhisini kolaylaştırabilmek, histopatoloji değerlendirmesine gerek duyulmadan, sadece klinik gözlemlerle teşhis yapılabilmesi için yapay zeka yöntemleriyle kural tabanlı teşhis algoritması geliştirebilmektir. Papüloskuamöz deri hastalıklarının 6 farklı çeşidi için çalışma deneysel olarak tasarlanmıştır. Çalışmada kullanılan veri setinde bireylere ait teşhis sonuçları ve teşhis konulurken doktora tarafından toplanan klinik bulgular (12) ve histopatolojik (22) bulgular bulunmaktadır. Altı farklı hastalık çeşidi olduğu için veri seti 2 grup olacak şekilde dengelenmiştir. Dengeleme sonunda 6 hastalık için 6 veri seti oluşturulmuştur. Her veri seti için özellik seçme algoritmaları ile özellikler (bulgular) seçilmiş ve karar ağaçları ile sınıflandırılmıştır. Elde edilen sonuçlara göre her hastalık için teşhis algoritması oluşturulmuştur.

Öncelikle, çalışma kapsamında tüm bulgular kullanılarak hastalıklar teşhis edilmeye çalışılmıştır. Altı farklı hastalık için yapılan değerlendirmede ortalama %86.80 doğruluk oranı, 0.93 duyarlılık ve 0.80 özgüllük değeri ile teşhis yapılabilir (Tablo 6).

Tablo 6. Tüm özellikler için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	89.22	0.98	0.81	0.88	0.78	0.89
	T	87.27	0.96	0.78	0.86	0.74	0.87
2-D	E	86.81	1.00	0.74	0.85	0.74	0.87
	T	76.67	0.81	0.71	0.76	0.53	0.76
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	89.33	0.97	0.82	0.89	0.79	0.90
	T	79.17	0.85	0.73	0.78	0.58	0.79
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	90.94	0.99	0.83	0.90	0.82	0.91
	T	86.80	0.93	0.80	0.86	0.73	0.87

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tüm özellikler ile yapılan değerlendirme sonrasında özellikler (bulgular) seçilerek değerlendirmeler tekrarlanmıştır. Seçilen özellik sayıları daha önce Tablo 3'te özetlenmiştir. Buna göre tüm bulguların önce %5'i (2 özellik 33, 34), daha sonra %10-50 arasında değerlendirilmesi gerçekleştirilmiştir. 2 özellik (%5) için elde edilen sonuçlar

Tablo 7'de, 3 özellik (%10) için elde edilen sonuçlar Tablo 8'de, 5 özellik (%15) için elde edilen sonuçlar

Tablo 9'da, 7 özellik (%20) için elde edilen sonuçlar

Tablo 10'da, 9 özellik (%25) için elde edilen sonuçlar Tablo 11'de, 10 özellik (%30) için elde edilen sonuçlar

Tablo 12'de, 12 özellik (%35) için elde edilen sonuçlar

Tablo 13'de, 14 özellik (%40) için elde edilen sonuçlar Tablo 14'te, 15 özellik (%45) için elde edilen sonuçlar

Tablo 15'de, 17 özellik (%50) için elde edilen sonuçlar

Tablo 16 Tablo 17'da özetlenmiştir. Tablo 17'de ise ortalama değerler gösterilmiştir. Elde edilen sonuçlara göre 1 numaralı hastalığın teşhisi için doğruluk oranı %74.71 duyarlılığı 0.93'tür. Diğer hastalıkların teşhis doğruluk oranları %67.80-99.09 arasında, duyarlılıkları ise 0.92-1 arasında değişmektedir.

Tablo 7. Tüm özelliklerden seçilmiş 2 özellik için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	59.88	1.00	0.19	0.32	0.19	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	89.72	1.00	0.79	0.88	0.79	0.90
	T	88.57	1.00	0.76	0.87	0.77	0.88
4-D	E	60.00	1.00	0.23	0.38	0.22	0.62
	T	62.50	1.00	0.18	0.31	0.19	0.59
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	93.33	0.93	0.93	0.93	0.87	0.93
	T	90.00	1.00	0.80	0.89	0.80	0.90
Ort	E	70.34	0.99	0.42	0.53	0.41	0.71
	T	71.70	1.00	0.41	0.53	0.41	0.70

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük,

Tablo 8. Tüm özelliklerden seçilmiş 3 özellik (%10) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	60.48	1.00	0.20	0.34	0.21	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	66.67	0.69	0.64	0.67	0.33	0.67
	T	54.17	0.62	0.45	0.52	0.07	0.53
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	72.81	0.95	0.51	0.59	0.46	0.73
	T	71.51	0.93	0.48	0.58	0.42	0.71

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 9. Tüm özelliklerden seçilmiş 5 özellik (%20) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	60.48	1.00	0.20	0.34	0.21	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	66.67	0.69	0.64	0.67	0.33	0.67
	T	54.17	0.62	0.45	0.52	0.07	0.53
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	72.81	0.95	0.51	0.59	0.46	0.73
	T	71.51	0.93	0.48	0.58	0.42	0.71

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 10. Tüm özelliklerden seçilmiş 7 özellik (%20) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	63.47	0.58	0.69	0.63	0.27	0.64
	T	58.18	0.36	0.81	0.50	0.17	0.59
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	60.00	1.00	0.23	0.38	0.22	0.62
	T	62.50	1.00	0.18	0.31	0.19	0.59
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63

6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	72.20	0.93	0.52	0.59	0.45	0.72
	T	72.29	0.88	0.54	0.57	0.43	0.71

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 11. Tüm özelliklerden seçilmiş 9 özellik (%25) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	70.66	1.00	0.41	0.58	0.41	0.70
	T	70.91	1.00	0.41	0.58	0.41	0.70
2-D	E	73.63	1.00	0.48	0.65	0.48	0.74
	T	66.67	0.94	0.36	0.52	0.31	0.65
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	73.33	1.00	0.49	0.66	0.48	0.74
	T	66.67	1.00	0.27	0.43	0.29	0.64
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	82.98	1.00	0.66	0.78	0.66	0.83
	T	80.33	0.98	0.61	0.71	0.59	0.79

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 12. Tüm özelliklerden seçilmiş 10 özellik (%30) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	70.66	1.00	0.41	0.58	0.41	0.70
	T	70.91	1.00	0.41	0.58	0.41	0.70
2-D	E	70.33	1.00	0.41	0.58	0.41	0.71
	T	70.00	1.00	0.36	0.53	0.37	0.68
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	72.00	1.00	0.46	0.63	0.45	0.73
	T	66.67	1.00	0.27	0.43	0.29	0.64
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	82.21	1.00	0.65	0.76	0.65	0.82
	T	80.88	0.99	0.61	0.71	0.60	0.80

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 13. Tüm özelliklerden seçilmiş 12 özellik (%35) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	89.22	0.98	0.81	0.88	0.78	0.89
	T	87.27	0.96	0.78	0.86	0.74	0.87
2-D	E	80.22	1.00	0.61	0.76	0.61	0.80
	T	80.00	1.00	0.57	0.73	0.59	0.79
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	82.67	1.00	0.67	0.80	0.66	0.83
	T	75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92

6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	88.73	1.00	0.78	0.87	0.78	0.89
	T	86.66	0.98	0.73	0.83	0.73	0.86

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 14. Tüm özelliklerden seçilmiş 14 özellik (%40) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	89.22	0.98	0.81	0.88	0.78	0.89
	T	87.27	0.96	0.78	0.86	0.74	0.87
2-D	E	76.92	0.93	0.61	0.74	0.54	0.77
	T	76.67	1.00	0.50	0.67	0.52	0.75
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	82.67	1.00	0.67	0.80	0.66	0.83
	T	75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	88.18	0.98	0.78	0.87	0.76	0.88
	T	86.11	0.98	0.72	0.82	0.71	0.85

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 15. Tüm özelliklerden seçilmiş 15 özellik (%45) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	89.22	0.98	0.81	0.88	0.78	0.89
	T	87.27	0.96	0.78	0.86	0.74	0.87
2-D	E	76.92	0.93	0.61	0.74	0.54	0.77
	T	76.67	1.00	0.50	0.67	0.52	0.75
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	82.67	1.00	0.67	0.80	0.66	0.83
	T	75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92
6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	88.18	0.98	0.78	0.87	0.76	0.88
	T	86.11	0.98	0.72	0.82	0.71	0.85

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 16. Tüm özelliklerden seçilmiş 17 özellik (%50) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	89.22	0.98	0.81	0.88	0.78	0.89
	T	87.27	0.96	0.78	0.86	0.74	0.87
2-D	E	76.92	0.93	0.61	0.74	0.54	0.77
	T	76.67	1.00	0.50	0.67	0.52	0.75
3-D	E	90.65	1.00	0.81	0.90	0.81	0.91
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	82.67	1.00	0.67	0.80	0.66	0.83
	T	75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	89.61	1.00	0.79	0.88	0.79	0.89
	T	92.00	1.00	0.83	0.91	0.84	0.92

6-D	E	100.00	1.00	1.00	1.00	1.00	1.00
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	88.18	0.98	0.78	0.87	0.76	0.88
	T	86.11	0.98	0.72	0.82	0.71	0.85

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 17. Tüm özelliklerle yapılan sınıflandırma sonuçlarının ortalaması

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	75.61	0.95	0.56	0.66	0.51	0.75
	T	74.71	0.93	0.56	0.64	0.49	0.74
2-D	E	70.83	0.98	0.44	0.58	0.42	0.71
	T	70.61	0.98	0.40	0.54	0.39	0.69
3-D	E	90.57	1.00	0.81	0.89	0.81	0.90
	T	85.97	0.95	0.76	0.85	0.72	0.86
4-D	E	74.42	0.94	0.56	0.68	0.50	0.75
	T	67.80	0.92	0.40	0.53	0.33	0.66
5-D	E	78.75	1.00	0.57	0.67	0.57	0.78
	T	81.82	1.00	0.62	0.72	0.63	0.81
6-D	E	99.39	0.99	0.99	0.99	0.99	0.99
	T	99.09	1.00	0.98	0.99	0.98	0.99
Ort	E	81.60	0.98	0.66	0.75	0.63	0.82
	T	80.00	0.96	0.62	0.71	0.59	0.79

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tüm bulgulara göre hastalıkların teşhis değerlerinin yüksek olması bekleniyordu. Yüksek teşhis doğruluk oranları önceki tablolarda tüm bulgular ile elde edilmiştir. Ancak bu çalışmanın amacı histopatolojik bulgulara gereksinim kalmadan sadece klinik bulgulara göre bireye teşhis koyabilmektir. Bunun için sadece klinik bulgular kullanılarak sınıflandırma işlemleri tekrar gerçekleştirilmiştir. Bu adımda tüm klinik bulgular kullanıldığı gibi, bulgular seçilerek de kullanılmıştır. Seçilen klinik bulgular ve bulguların numaraları daha önce Tablo 3'te özetlenmiştir. Tüm klinik bulgular işe yapılan sınıflandırma işleminde elde edilen sonuçlar Tablo 18'de özetlenmiştir. Tabloda koyu işaretlenmiş alanlar ilgili veri seti grubu için en iyi sınıflandırma sonuçlarını temsil etmektedir. Tablo 18'deki sonuçlara göre 1-D, 2-D, 4-D ve 5-D veri setleri için 12 klinik bulgu ile en iyi performanslar elde edilmiştir.

Tablo 18. Tüm klinik bulgular (özellikler) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	86.23	0.94	0.78	0.85	0.72	0.86
	T	81.82	0.93	0.70	0.80	0.63	0.82
2-D	E	82.42	0.91	0.74	0.82	0.65	0.83
	T	83.33	0.88	0.79	0.83	0.66	0.83
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	85.33	1.00	0.72	0.84	0.71	0.86
	T	75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	83.12	0.82	0.84	0.83	0.66	0.83
	T	72.00	0.62	0.83	0.71	0.44	0.72
6-D	E	96.67	1.00	0.93	0.97	0.93	0.97
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	87.25	0.94	0.80	0.87	0.75	0.87
	T	82.98	0.89	0.76	0.80	0.66	0.83

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tüm klinik bulgulardan sonra seçilen bulgular (1 (%5) - 6 (%50)) tekrar sınıflandırılmıştır. 1 klinik bulgu ile elde edilen sonuçlar Tablo 19’da, 2 klinik bulgu (%15) ile elde edilen sonuçlar Tablo 20’de, 3 klinik bulgu (%25) ile elde edilen sonuçlar Tablo 21’de, 4 klinik bulgu (%35) ile elde edilen sonuçlar Tablo 22’de, 5 klinik bulgu (%45) ile elde edilen sonuçlar Tablo 23’de, 6 klinik bulgu (%50) ile elde edilen sonuçlar Tablo 24’te özetlenmiştir. Genellikle bulgu sayısı azaldıkça performans oranının düştüğü görülmüştür (Tablo 19).

Tablo 19. 1 klinik bulgu (özellikler) (%5) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	59.28	1.00	0.18	0.31	0.18	0.59
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	89.72	0.96	0.83	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	57.33	1.00	0.18	0.30	0.17	0.59
	T	62.50	1.00	0.18	0.31	0.19	0.59
5-D	E	58.44	1.00	0.16	0.27	0.16	0.58
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	60.00	1.00	0.20	0.33	0.20	0.60
	T	60.00	1.00	0.20	0.33	0.20	0.60
Ort	E	64.02	0.99	0.29	0.41	0.28	0.64
	T	66.23	0.99	0.31	0.43	0.30	0.65

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 20. 2 klinik bulgu (özellikler) (%15) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	59.88	1.00	0.19	0.32	0.19	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	58.67	1.00	0.21	0.34	0.20	0.60
	T	62.50	1.00	0.18	0.31	0.19	0.59
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	60.00	1.00	0.20	0.33	0.20	0.60
	T	60.00	1.00	0.20	0.33	0.20	0.60
Ort	E	64.56	1.00	0.30	0.42	0.29	0.65
	T	66.23	0.99	0.31	0.43	0.30	0.65

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 21. 3 klinik bulgu (özellikler) (%25) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	59.88	1.00	0.19	0.32	0.19	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	59.34	1.00	0.20	0.33	0.19	0.60
	T	63.33	1.00	0.21	0.35	0.23	0.61
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85

4-D	E	58.67	1.00	0.21	0.34	0.20	0.60
	T	62.50	1.00	0.18	0.31	0.19	0.59
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	60.00	1.00	0.20	0.33	0.20	0.60
	T	60.00	1.00	0.20	0.33	0.20	0.60
Ort	E	64.56	1.00	0.30	0.42	0.29	0.65
	T	66.23	0.99	0.31	0.43	0.30	0.65

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 22. 4 klinik bulgu (özellikler) (%35) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	59.88	1.00	0.19	0.32	0.19	0.60
	T	61.82	1.00	0.22	0.36	0.23	0.61
2-D	E	62.64	0.98	0.28	0.44	0.26	0.63
	T	66.67	1.00	0.29	0.44	0.30	0.64
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	62.67	1.00	0.28	0.44	0.27	0.64
	T	66.67	1.00	0.27	0.43	0.29	0.64
5-D	E	59.74	1.00	0.18	0.31	0.19	0.59
	T	64.00	1.00	0.25	0.40	0.26	0.63
6-D	E	96.67	1.00	0.93	0.97	0.93	0.97
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	71.89	0.99	0.45	0.56	0.44	0.72
	T	74.14	0.99	0.47	0.58	0.46	0.73

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 23. 5 klinik bulgu (özellikler) (%45) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	82.04	0.81	0.83	0.82	0.64	0.82
	T	78.18	0.75	0.81	0.78	0.56	0.78
2-D	E	68.13	0.98	0.39	0.56	0.37	0.68
	T	70.00	1.00	0.36	0.53	0.37	0.68
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	70.67	1.00	0.44	0.61	0.43	0.72
	T	70.83	1.00	0.36	0.53	0.38	0.68
5-D	E	64.94	0.95	0.34	0.50	0.29	0.65
	T	76.00	1.00	0.50	0.67	0.51	0.75
6-D	E	96.67	1.00	0.93	0.97	0.93	0.97
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	78.69	0.95	0.62	0.72	0.58	0.79
	T	80.12	0.95	0.63	0.73	0.59	0.79

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

Tablo 24. 6 klinik bulgu (özellikler) (%50) için sınıflandırma sonuçları

		D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	86.23	0.94	0.78	0.85	0.72	0.86
	T	81.82	0.93	0.70	0.80	0.63	0.82
2-D	E	68.13	0.98	0.39	0.56	0.37	0.68
	T	70.00	1.00	0.36	0.53	0.37	0.68
3-D	E	89.72	0.98	0.81	0.89	0.79	0.90
	T	85.71	0.94	0.76	0.85	0.71	0.85

4-D	E	74.67	1.00	0.51	0.68	0.50	0.76
	T	70.83	1.00	0.36	0.53	0.38	0.68
5-D	E	68.83	1.00	0.37	0.54	0.37	0.68
	T	80.00	1.00	0.58	0.74	0.59	0.79
6-D	E	96.67	1.00	0.93	0.97	0.93	0.97
	T	100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	80.71	0.98	0.63	0.75	0.62	0.81
	T	81.39	0.98	0.63	0.74	0.62	0.80

Ort Ortalama, E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, F-Ö F-Ölçümü, AUC Alıcı İşletim Karakteristiği Altındaki Alan

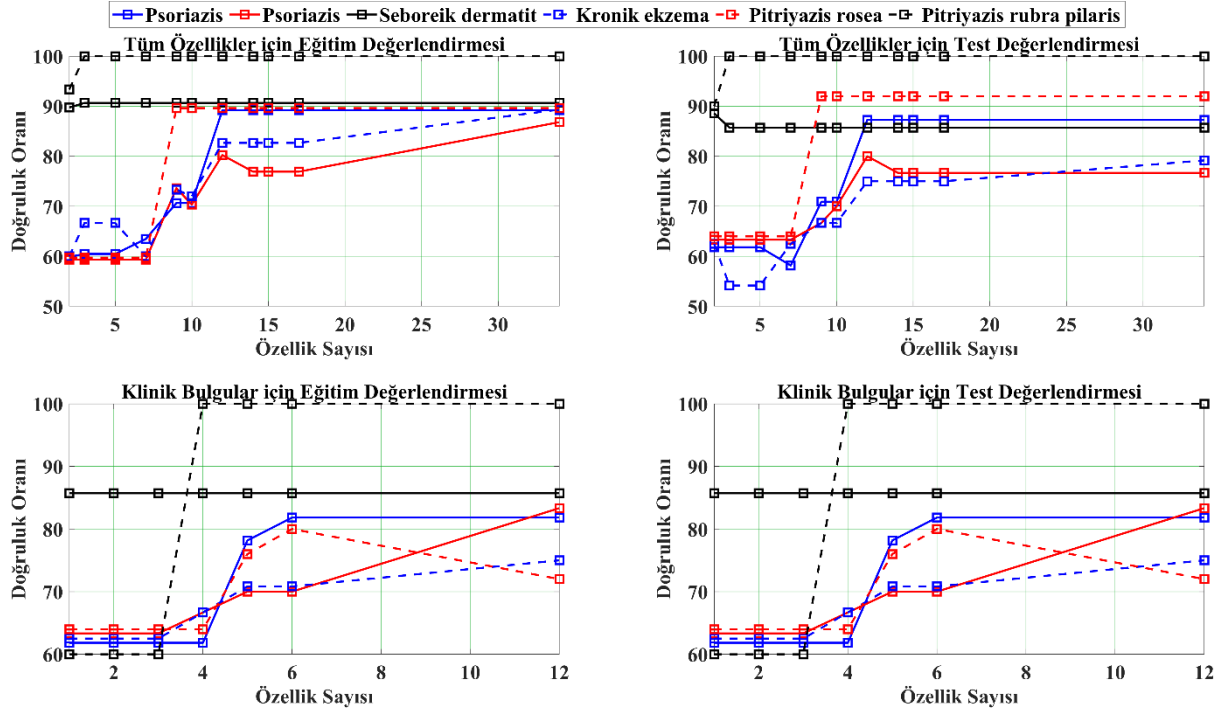
Klinik bulgulara göre elde edilen en iyi sonuçlar daha iyi anlaşılabilmesi için Tablo 25'te özetlenmiştir. Sonuçlara göre 12 ve 4 klinik bulgu ile oldukça yüksek performansta bir sistem tasarlamak mümkündür.

Tablo 25. Klinik bulgu (özellikler) için en iyi sınıflandırma sonuçları

		ÖS	D	Duy	Özg	F-Ö	Kappa	AUC
1-D	E	12	86.23	0.94	0.78	0.85	0.72	0.86
	T		81.82	0.93	0.70	0.80	0.63	0.82
2-D	E	12	82.42	0.91	0.74	0.82	0.65	0.83
	T		83.33	0.88	0.79	0.83	0.66	0.83
3-D	E	4	89.72	0.98	0.81	0.89	0.79	0.90
	T		85.71	0.94	0.76	0.85	0.71	0.85
4-D	E	12	85.33	1.00	0.72	0.84	0.71	0.86
	T		75.00	1.00	0.45	0.63	0.47	0.73
5-D	E	12	83.12	0.82	0.84	0.83	0.66	0.83
	T		72.00	0.62	0.83	0.71	0.44	0.72
6-D	E	4	96.67	1.00	0.93	0.97	0.93	0.97
	T		100.00	1.00	1.00	1.00	1.00	1.00
Ort	E	-	87.25	0.94	0.80	0.87	0.75	0.87
	T		82.98	0.89	0.76	0.80	0.66	0.83

E Eğitim, T Test, D Doğruluk Oranı, Duy Duyarlılık, Özg Özgüllük, AUC Alıcı İşletim Karakteristiği Altındaki Alan, ÖS Özellik Sayısı

Şekil 2'de hastalıkların özellik sayılarına göre elde edilen doğruluk oranları gösterilmiştir. Üstteki iki grafik tüm özelliklerin sınıflandırılması durumunda elde edilen eğitim ve test doğruluk oranlarını göstermektedir. Tüm özelliklerim test sonuçlarına göre 12 özellikten sonra aynı sonucu verdiği görülmektedir. Bu durum tüm özellikleri kullanmak yerine daha az özelliklerin kullanılabilceğini göstermektedir. Yine aynı şekilde klinik bulguların sayısına göre eğitim ve test sonuçları alttaki iki grafikte gösterilmiştir. Test sonuçlarına göre özellik sayısı arttıkça doğruluk oranı artmaktadır. Ancak 6 özellikten sonra doğruluk oranında fazla bir değişiklik olmadığı görülmektedir. Bu durum tüm özellikler yerine özelliklerin seçilerek kullanması gerektiğinin bir göstergesidir. Özellik seçme algoritmaları hastalıkların teşhisi için fayda sağlamıştır.



Şekil 2. Hastalıklara göre performans değerlendirme sonuçlarının grafiksel olarak gösterimi


Tablo 25’te özetlenen en iyi sonuçlara göre teşhis algoritmaları ağaç modelinde her bir hastalık için Şekil 3-

Şekil 8 arasında gösterilmiştir. Bu yapıların kullanımı ve açıkladığı bilgi şu şekildedir.


Şekil 3’de Psoriasis için teşhis algoritması hazırlanmıştır. Bu yapıya göre dalların sonlarında bulunan 1 ve 2 etiketleri hastalıkları göstermektedir. 1 her zaman teşhis edilmeye çalışılan hastalığı, ki burada Psoriasis’i temsil etmektedir. 2 ise diğer hastalıkları (5 hastalık grubunu) temsil etmektedir. Oluşturulan yapı için Tablo 25’te 12 adet özellik kullanıldığı belirtilmiştir. $x_1, x_2, x_3, \dots, x_{12}$ ise değişkenleri temsil etmektedir. Değişkenlerin neyi ifade ettiği Tablo 2’de gösterilmiştir. 12 özellik kullanıldığında Tablo 2’de ilk x değerleri kullanılmıştır. Ancak 4 adet özellik kullanıldığında, Tablo 2’deki ikinci x değerleri kullanılmıştır.

Farklı bir örnek olarak


Şekil 5’te Seboreik dermatit için teşhis algoritması oluşturulmuştur. 1 etiketi Seboreik dermatit’i 2 etiketi ise diğer hastalıkları temsil etmektedir. Burada x_{12} ve x_6 değişkenleri kullanılmıştır. Seboreik dermatit Tablo 25’te 12 adet özelliğin kullanıldığı yazılmıştır. Buna göre ilk x değerleri kullanılmıştır (Tablo 2). x_{12} değişkeni yaşı, x_6 değişkeni Poligonal papüller’i temsil etmektedir. Değişkenlerin değerleri 0-3 arasında değişmektedir. Bu parametrelere göre sadece 2 bulgu ile teşhis konulabilmektedir.




Şekil 3. Psoriasis için teşhis algoritması



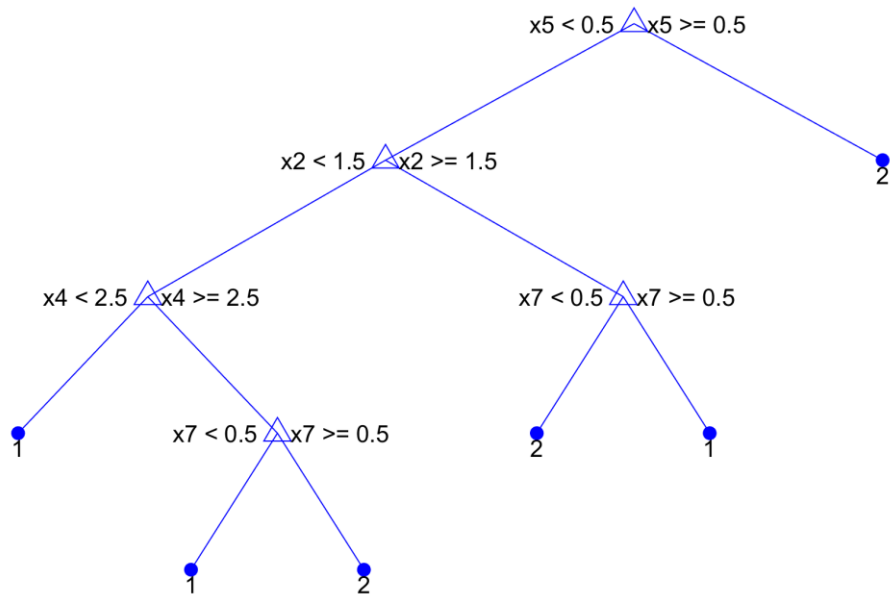
Şekil 4. Lichen planus için teşhis algoritması




Şekil 5. Seboreik dermatit için teşhis algoritması



Şekil 6. Kronik ekzema için teşhis algoritması



Şekil 7. Pitriyazis rosea için teşhis algoritması



Şekil 8. Pitriyazis rubra piliaris için teşhis algoritması

IV. TARTIŞMA VE SONUC

Bu çalışma kapsamında, Papüloskuamöz deri hastalıklarının teşhisi için, klinik muayene de kullanılabilir yüksek doğruluk oranına sahip yapay zeka yöntemleriyle kural tabanlı algoritmalar geliştirilmiştir.

Deri hastalıklarının tanısında klinik muayenenin yetersiz kalması durumunda deri biyopsi incelemesi devreye girer [4], [5]. Bu durum hastalık teşhis sürecinin uzamasına sebep olur [1], [30]. Deri hastalıklarında teşhis sürecinin uzaması bireylerin psikolojik olarak olumsuzluklara sebebiyet verebilir [7]. Bu sebeple Papüloskuamöz deri hastalıklarının teşhis sürecinin kısaltılması ve histopatolojik değerlendirme olmadan yüksek doğruluk oranı ile teşhis yapılması hayati öneme sahiptir.

Literatürde ise genellikle klinik ve histopatolojik bulgular kullanılarak yapay zeka yöntemleriyle hastalıkların teşhisi yapılmaya çalışılmıştır [11], [12], [15], [22]. Bazı çalışmalarda ise özellik seçme algoritmaları kullanılmıştır [15], [17], [23]. Bu çalışmada da literatürle uyumlu olarak özellik seçme algoritmaları ve makine öğrenmesi algoritmaları ile Papüloskuamöz deri hastalıklarının teşhisi yapılmıştır. Elde edilen yüksek başarı oranı literatür ile uyumludur [19], [23], [24]. Her üç çalışmada da hastalıkların teşhisi için ortalama duyarlılık oranı %84-100 arasında değişmektedir. Ancak bu sonuçlar alınırken sadece klinik bulgular değil diğer patolojik bulgularda kullanılmıştır. Bu çalışmada ortalama duyarlılık oranı %82-100 arasında değişmektedir. Bu sonuçlar literatür ile hem uyumlu hem de daha verimlidir. Çünkü literatürde patoloji özelliklerde de kullanılırken burada sadece klinik bulgular kullanılmıştır. Patolojik bulguların elde edilmesi oldukça zahmetlidir. Bu çalışmanın en önemli özgül yanı patoloji bulgularına gerek kalmadan anca patoloji bulguları kadar doğruluk oranı veren sistemler geliştirmektir. Çalışma bu çerçevede değerlendirildiğinde literatür ile uyumlu iken daha verimli bir model önermiştir. Buna ek olarak özellik seçme algoritmaları ile birlikte özellik sayısı azaltılarak performans yükseltilmiştir. Literatürde özellik seçme modellerinin kullanıldığı çalışmalarda doğruluk oranı yaklaşık %94-100 arasında duyarlılık değeri ise %92-100 arasındadır [14], [17]. Bu çalışmalarda tüm özellikler seçilerek uygulama tasarlanmıştır. Ayrıca özellik grupları üzerinde özellik seçme işlemi yapılmamıştır. Bu çalışmada ise özellik seçme algoritması hem tüm özellikler için hem de sadece klinik bulgular için uygulanmıştır. Elde edilen doğruluk oranı ortalama %85-100 arasında iken duyarlılık değeri %93-100 arasındadır. Bu sonuçlar literatür ile uyumlu iken önerilen modelin klinikte kullanılabilir olması sebebiyle literatürden bir adım öndedir.

Bu çalışmayı literatürden ayıran en önemli özellik geliştirilen teşhis algoritmasının klinikte uygulanabilir olmasıdır. Literatürde geliştirilen yüksek başarı oranına sahip sistemler bilgisayar ortamında çalışmaya uygun sistemlerdir [10], [13], [16]. Ancak bu sistemlerin klinikte doktor tarafından uygulanması oldukça zordur. Bu çalışma kapsamında geliştirilen yüksek başarı oranına sahip teşhis algoritmaları klinikte doktorlar tarafından kullanıma uygundur. Hekim kendisine gelen vakada belirli kriterlere göre hastalığın teşhisini rahatlıkla koyabilecektir. Diğer yöntemler ancak kullanılabilir cihazlara dönüştürülmesi durumunda kullanılabilir [15], [17].

Sonuç olarak, bu çalışmada elde edilen sonuçlara göre, çalışma kapsamında geliştirilen algoritmalar, Papüloskuamöz deri hastalıklarının teşhisi için yapay zeka yöntemleriyle geliştirilen yüksek doğruluk oranına sahip kural tabanlı algoritmalar klinikte kullanılabilir.

V. KAYNAKLAR

[1] S. P. Kartal ve C. T. Altunel, "Papüloskuamöz ve diğer inflamatuvar deri hastalıkları," *Türkiye Klin. Geriatr. - Özel Konular*, c. 5, s. 1, ss. 70-76, 2019.

[2] E. Brehmer-Andersson, *Dermatopathology*, 1. baskı, Berlin, Heidelberg, Germany, Springer-Verlag Berlin Heidelberg, 2006.

- [3] W. D. James, T. G. Berger, D. M. Elston, ve R. B. Odom, *Andrews' Diseases of The Skin : Clinical Dermatology.*, 10. baskı, Philadelphia: Saunders Elsevier, 2006.
- [4] B. Ç. Nursel Dilek, Yunus Saral, "Dermatozlarda klinik ve histopatolojik korelasyon," *Fırat Üniversitesi Sağlık Bilim. Derg.*, c. 23, s. 2, ss. 81–84, 2009.
- [5] G. Açıköz, M. Çayırılı, ve M. Tunca, "Deri hastalıklarının tanısında laboratuvar ve özel inceleme yöntemleri," *Smyrna Tıp Derg.*, c. 42, ss. 1–6, 2012.
- [6] Ö. F. Elmas, "Deri biyopsisi," *Türkiye Klin.*, c. 10, s. 1, ss. 33–38, 2017.
- [7] P. Yüksel Başak, "Sık görülen bazı deri hastalıklarının yaşam kalitesi üzerindeki etkilerinin karşılaştırılması," *Türkiye Klin.*, c. 10, s. 3, ss. 171–174, 2000.
- [8] H. A. Güvenir, G. Demiröz, ve N. İter, "Learning differential diagnosis of erythematous diseases using voting feature intervals," *Artif. Intell. Med.*, c. 13, s. 3, ss. 147–165, 1998.
- [9] N. İter ve H. A. Guvenir. "UCI Machine Learning Repository: Dermatology Data Set," <https://archive.ics.uci.edu/>, 1998. [Çevrimiçi]. Erişim Adresi: <https://archive.ics.uci.edu/ml/datasets/Dermatology>. Erişim Tarihi: 28.03.2020.
- [10] E. D. Übeyli, "Multiclass support vector machines for diagnosis of erythematous diseases," *Expert Syst. Appl.*, c. 35, s. 4, ss. 1733–1740, 2008.
- [11] L. Nanni, "An ensemble of classifiers for the diagnosis of erythematous diseases," *Neurocomputing*, c. 69, s. 7-9 SPEC. ISS., ss. 842–845, 2006.
- [12] H. A. Güvenir ve N. Emeksiz, "An expert system for the differential diagnosis of erythematous diseases," *Expert Syst. Appl.*, c. 18, s. 1, ss. 43–49, 2000.
- [13] E. D. Übeyli ve I. Güler, "Automatic detection of erythematous diseases using adaptive neuro-fuzzy inference systems," *Comput. Biol. Med.*, c. 35, s. 5, ss. 421–433, 2005.
- [14] A. K. Verma, S. Pal, ve S. Kumar, "Comparison of skin disease prediction by feature selection using ensemble data mining techniques," *Informatics Med. Unlocked*, c. 16, ss. 100202, 2019.
- [15] A. K. Verma, S. Pal, ve S. Kumar, "Prediction of Skin Disease Using Ensemble Data Mining Techniques and Feature Selection Method—a Comparative Study," *Appl. Biochem. Biotechnol.*, c. 190, s. 2, ss. 341–359, 2020.
- [16] S. K. Jha, Z. Pan, E. Elahi, ve N. Patel, "A comprehensive search for expert classification methods in disease diagnosis and prediction," *Expert Syst.*, c. 36, s. 1, ss. e12343, 2019.
- [17] M. J. Abdi ve D. Giveki, "Automatic detection of erythematous diseases using PSO-SVM based on association rules," *Eng. Appl. Artif. Intell.*, c. 26, s. 1, ss. 603–608, 2013.
- [18] J. Xie ve C. Wang, "Using support vector machines with a novel hybrid feature selection method for diagnosis of erythematous diseases," *Expert Syst. Appl.*, c. 38, s. 5, ss. 5809–5815, 2011.
- [19] E. D. Übeyli ve E. Doğdu, "Automatic detection of erythematous diseases using κ -means clustering," *J. Med. Syst.*, c. 34, s. 2, ss. 179–184, 2010.
- [20] A. Basu, S. S. Roy, ve A. Abraham, "A novel diagnostic approach based on support vector

machine with linear kernel for classifying the erythematous-squamous disease,” in *Proceedings - 1st International Conference on Computing, Communication, Control and Automation, ICCUBEA 2015*, Pune, India, 2015, ss. 343–347.

[21] K. Maghooli, M. Langarizadeh, L. Shahmoradi, M. Habibikoolae, M. Jebraeily, ve H. Bouraghi, “Differential diagnosis of Erythmato-Squamous Diseases using classification and regression tree,” *Acta Inform. Medica*, c. 24, s. 5, ss. 338–342, 2016.

[22] N. Badrinath, G. Gopinath, K. S. Ravichandran, J. Premaladha, ve R. Krishankumar, “Classification and prediction of erythematous-squamous diseases through tensor-based learning,” *Proc. Natl. Acad. Sci. India Sect. A Phys. Sci.*, ss. 1–9, 2018.

[23] B. Lahijanian, F. V. Farahani, ve M. H. F. Zarandi, “A new multiple classifier system for diagnosis of erythematous-squamous diseases based on rough set feature selection,” in *2016 IEEE International Conference on Fuzzy Systems, FUZZ-IEEE 2016*, Vancouver, BC, Canada, 2016, ss. 2309–2316.

[24] A. M. Elsayad, M. Al-Dhaifallah, ve A. M. Nassef, “Analysis and diagnosis of erythematous-squamous diseases using CHAID decision trees,” in *2018 15th International Multi-Conference on Systems, Signals and Devices, SSD 2018*, Hammamet, Tunisia, 2018, ss. 252–262.

[25] T. Liu, L. Hu, C. Ma, Z. Y. Wang, ve H. L. Chen, “A fast approach for detection of erythematous-squamous diseases based on extreme learning machine with maximum relevance minimum redundancy feature selection,” *Int. J. Syst. Sci.*, c. 46, s. 5, ss. 919–931, 2015.

[26] D. Richard O., H. Peter E., ve S. David G., *Pattern Classification*, 2. baskı, New York, NY, United States, John Wiley & Sons, New York, 2001.

[27] M. K. Uçar, M. R. Bozkurt, C. Bilgin, ve K. Polat, “Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques,” *Neural Comput. Appl.*, c. 29, s. 8, 2018.

[28] M. K. Uçar, M. R. Bozkurt, C. Bilgin, ve K. Polat, “Automatic detection of respiratory arrests in OSA patients using PPG and machine learning techniques,” *Neural Comput. Appl.*, c. 28, s. 10, 2017.

[29] T. Yamane, *Elementary Sampling Theory*, 1. baskı, New Jersey, United States, Prentice Hall, 1967.

[30] S. Sezgin, “Çocukluk Çağında Papüloskuamöz Hastalıklar”, Tıpta Uzmanlık Tezi, Deri ve Zührevi Hast. Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye, 2019.