

Histopatolojik Görüntülerle Diyabetin Akciğer Dokusundaki Etkisinin Sınıflandırılması: LBP ve GLCM Özellikleri ile Bir Karşılaştırma Çalışması

Tuğba ŞENTÜRK^{1*}, Fatma LATİFOĞLU^{2*}, Demet BOLAT³, Arzu YAY^{3,4} ve Münevver Baran⁵

^{1*} İnönü Üniversitesi, Biyomedikal Mühendisliği, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği, Malatya, Türkiye
(tugba.senturk@inonu.edu.tr) (ORCID: 0000-0002-1323-5752)

^{2*} Erciyes Üniversitesi, Biyomedikal Mühendisliği, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği, Kayseri, Türkiye
(flatifoglu@erciyes.edu.tr) (ORCID: 0000-0003-2018-9616)

³ Erciyes Üniversitesi, Tıp Fakültesi, Histoloji ve Embriyoloji Anabilim Dalı, Kayseri, Türkiye (demetbolat92@hotmail.com) (ORCID: 0000-0002-3496-1630)

⁴ Erciyes Üniversitesi, Tıp Fakültesi, Genom ve Kök Hücre Merkezi (GENKOK), Kayseri, Türkiye (arzu.yay38@gmail.com) (ORCID: 0000-0002-0541-8372)

⁵ Erciyes Üniversitesi, Eczacılık Fakültesi, Eczacılık Temel Bilimler Anabilim Dalı, Kayseri, Türkiye (muneverbaran@erciyes.edu.tr) (ORCID: 0000-0003-0369-1022)

Türkçe Özet – Bu çalışma, diyabet hastalığının akciğer dokusu üzerindeki etkilerini incelemek amacıyla ratlarda bir diyabet modeli kullanarak histopatolojik görüntülerin analiz ve sınıflandırılmasını hedeflemektedir. Çalışmanın başlangıcında, kontrol ve Streptozotosin (STZ) ile diyabetik gruplar oluşturulmuştur. Akciğer dokusundaki değişiklikleri incelemek için kaspaz immunohistokimyasal boyama kullanılmıştır. Görüntülerden Yerel İkili Örüntüler (Local Binary Pattern, LBP) ve Gri Seviye Eş Oluşum Matrisi (Gray-Level Co-Occurrence Matrix, GLCM) gibi özellikler elde edilmiştir. Bu özellikler ile diyabetin akciğer dokusuna etkilerini analiz etmek amacıyla histopatolojik görüntüler analiz edilmiştir. Daha sonra, Lasso yöntemi ile en önemli özellikler seçilmiş ve kullanılmıştır. Elde edilen özellikler, Destek Vektör Makinesi (Support Vector Machine, SVM), K-en Yakın Komşu (K-nearest neighbors, KNN), Yapay Sinir Ağları (YSA) ve Karar Ağacı (Decision Tree, DT) gibi dört farklı yöntemi ile sınıflandırılmıştır. Bu yöntemler, görüntülerin sınıflandırılmasında kullanılmış ve görüntülerde sınıflandırma sonuçları elde edilmiştir. Kırmızı ve mavi kanallardan elde edilen görüntüler ile en iyi sınıflandırma performansı sırasıyla %91.08 ve %93.87 doğruluk oranlarıyla YSA sınıflandırıcısıyla elde edilirken, yeşil kanaldan elde edilen görüntüler ile en yüksek doğruluk oranı %87.15 olarak SVM sınıflandırıcısıyla elde edilmiştir. Bu sonuçlara göre, histopatolojik görüntü analizi yoluyla diyabetin akciğer dokularına etkisini objektif bir şekilde değerlendirmek için LBP, GLCM özellikleri ve makine öğrenme algoritmalarından oluşan sınıflandırma modelinin önemli bir potansiyele sahip olduğu görülmektedir.

Anahtar Kelimeler – Diyabet Hastalığı, Streptozotosin, GLCM, LBP, SVM, KNN, DT, YSA

Atf: Şentürk, T., Latifoğlu, F., Bolat, D., Yay, A., Baran, M., (2023). Histopatolojik Görüntülerle Diyabetin Akciğer Dokusundaki Etkisinin Sınıflandırılması: LBP ve GLCM Özellikleri ile Bir Karşılaştırma Çalışması. Bilişsel Modeller ve Yapay Zeka Konferansı, 7(2): 84-89.

Classification of the Effects of Diabetes on Lung Tissue with Histopathological Images: A Comparative Study Using LBP and GLCM Features

Extended Abstract

This study aims to analyze and classify histopathological images using a rat model of diabetes to examine the effects of diabetes on lung tissue. At the beginning of the study, control and diabetic groups were established using Streptozotocin (STZ). Caspase immunohistochemical staining was used to examine changes in lung tissue. Features such as Local Binary Patterns (LBP) and Gray-Level Co-Occurrence Matrix (GLCM) were extracted from the images. These features were analyzed to assess the impact of diabetes on lung tissue. Subsequently, the most important features were selected and used with the Lasso method. The obtained features were classified using four different methods: Support Vector Machine (SVM), K-nearest neighbors (KNN), Artificial Neural Networks (ANN), and Decision Tree (DT). These methods were used for image classification, and classification results

were obtained. The best classification performance was achieved with images obtained from the red and blue channels, with accuracy rates of %91.08 and %93.87 using the ANN classifier, while images obtained from the green channel yielded the highest accuracy rate of %87.15 with the SVM classifier. According to these results, it is evident that a classification model comprising LBP, GLCM features, and machine learning algorithms has significant potential for objectively assessing the impact of diabetes on lung tissues through histopathological image analysis.

Keywords – Diabetes Mellitus, Streptozotocin, GLCM, LBP, SVM, KNN, DT, ANN

Citation: Şentürk, T., Latifoğlu, F., Bolat, D., Yay, A., Baran, M., (2023). Classification of the Effects of Diabetes on Lung Tissue with Histopathological Images: A Comparative Study Using LBP and GLCM Features. Cognitive Models and Artificial Intelligence Conference, 7(2): 84-89.

I. GİRİŞ

Diyabet hastalığı (Diabetes mellitus, DM), insülin yetersizliği (Tip 1) veya direnci (Tip 2) sonucunda oluşan metabolik bozukluklara neden olan, kronik hiperglisemi ile karakterize bir endokrin hastalıktır [1]. Dünya genelindeki insanların yaklaşık %90-95'i Tip 2 DM hastasıdır [2]. Bu hastalık ölümlere neden olabilir ve aynı zamanda yüksek plazma glikozu artışına bağlı olarak retinopatiler, nöropatiler, nefropatiler ve akciğerdeki küçük kan damarlarının tahrip edilmesi gibi mikrovasküler ve makrovasküler komplikasyonlara yol açar [3], [4]. DM hastalarının belli çoğunluğunda da kronik obstrüktif akciğer hastalığı, pulmoner fibroz ve astım riski yüksektir. Ayrıca akciğer kapasitesinin azaldığı ve pulmoner disfonksiyonun geliştiği tespit edilmiştir [5]. Akciğerlerdeki bu işlev bozukluğu ventilasyonun bozulmasına ve hipoksiye yol açabilir. Hipoksi aynı zamanda iltihaplanma, oksidatif stres ve organlarda hasara neden olabilir.

Tıbbi teşhis ve hastalığın etkilerini incelemek için hastalardan plazma glukoz konsantrasyonu, diyastolik kan basıncı, triceps deri kıvrım kalınlığı, serum insülini, vücut kütlesi, yaş vb. veriler alınmaktadır [6]. Bu verilerin analizi ve değerlendirilmesi, hekimler tarafından manuel olarak uzun sürebilir ve bazen yanlış gözlemlere ve yargılara yol açabilir [7]. Bu nedenle klinik ve fiziksel verilere dayalı yapay zeka teknikleri, görüntü işleme ve derin öğrenme gibi ileri teknoloji ve yazılım tabanlı çeşitli programların kullanımı önemlidir.

Literatürdeki son çalışmalar, özellikle diyabet teşhisine odaklanmış gibi görünmektedir. Bu çalışmalarda genellikle histopatolojik görüntüler kullanılarak yapay zeka teknikleriyle sınıflandırma çalışmaları yapılmıştır.

Kannadasan ve ark. [8], diyabet verilerini sınıflandırmak için yığınlaştırılmış otokodlayıcıları kullanarak bir derin sinir ağı önerdiler. Önerilen bu model, yığınlaştırılmış otokodlayıcılarla birleştirilmiş softmax sınıflandırıcıyı Pima Indian diyabet veri kümesi üzerinde kullanmıştır. Bu model, literatürdeki diğer birçok sinir ağı yaklaşımıyla karşılaştırıldığında %86.26 doğruluk oranıyla daha iyi bir performans sergilediği görülmüştür. Ayrıca modelin hassasiyet değeri %90.66 ve duyarlılık değeri %87.92 sağlamıştır.

Heydari ve ark. [9] çalışmasında, diyabet sınıflandırması için çeşitli çoklu sınıflandırma algoritmaları karşılaştırılmıştır. Kullanılan veri seti, Tip 2 diyabet için taranan 2536 vaka içermektedir ve farklı algoritmaların performansı test edilmiştir. En iyi performans %97,44 ile yapay sinir ağından (YSA) elde edilmiştir. SVM, KNN, DT ve Bayes sınıflandırıcıları sırasıyla %81.19, %90.85, %95.03 ve %91.60 doğruluk oranlarına sahiptir.

Yurttakal ve ark. [10] çalışmasında, sıçan böbreği histopatoloji görüntülerini kullanarak diyabetes mellitusun otomatik tespiti için transfer öğrenmeye dayalı bir evrişimli sinir ağı modeli önerilmiştir. Model, diyabetin neden olduğu yapısal değişiklikleri özellikle glomerül ve böbreğin diğer bölgelerinde simüle etmektedir. Elde edilen sonuçlara göre, önerilen model %97.5 doğruluk oranı elde etmiştir. Önerilen modelin histopatoloji görüntülerini hızlı ve doğru bir şekilde sınıflandırılabilirliği ve patolojilere kritik durumlarda ikinci bir okuyucu olarak yardımcı olabilmesi konusunda önemi ortaya konmuştur.

Harman [11], Pima Indian Diyabet veri seti üzerinde erken dönemde DM teşhisini koymaya yönelik Naive Bayes ve SVM algoritmalarını kullanarak bir çalışma yapmıştır. Sınıflandırıcı performansını artırmak için veri standardizasyonu ve eksik verilerin yeniden yapılandırılması gibi ön işleme adımları uygulamıştır. Ayrıca sınıf dengesizliği problemi için Sentetik Azınlık Aşırı-Örnekleme (SMOTE) tekniğini kullanmıştır. Bu yöntemlerin kullanılmasıyla SVM, %90 doğruluk oranıyla en iyi sonucu vermiştir.

Başka bir çalışmada [12], Rastgele Orman, Gradyan Arttırma, KNN, Derin Sinir Ağları ve Oylama topluluk sınıflandırıcısı ile oluşturulan modellerin performansları, dışarıda tutma ve 5-kat çapraz doğrulama yöntemleri kullanılarak gerçek zamanlı DM erken teşhisine yönelik olarak test edilmiştir. Bu çalışma, 200 negatif ve 320 pozitif örnek içeren bir veri seti üzerinde yapılmıştır. Oylama topluluğu sınıflandırıcısı, %100'lük bir sınıflandırma doğruluğu ve 5 kat çapraz doğrulamalı ortalama %97.31'lik bir sınıflandırma doğruluğu ile en iyi performansı göstermiştir.

DM'nin uzun vadeli etkileri, insan vücudunda çeşitli hasarlara, organ yetmezliklerine, özellikle göz, böbrek, kalp ve damar hasarlarına neden olabilir. Tarihi ve ark. [13], deneysel diyabet oluşturulan sıçan beyin dokusunda irisin immünreaktivitesi üzerine enalaprilin (EN) etkilerini incelemiştir. Çalışmada DM, DM+EN ve kontrol grupları kullanılarak, irisin immünreaktivitesinin incelenmiş ve EN'nin diyabetik beyin hasarına karşı etkili olduğu sonucuna varılmıştır.

Literatürden görüldüğü gibi, DM'nin sınıflandırılması üzerine birçok çalışma yapılmış olsada, spesifik olarak dokular üzerindeki etkilerini incelemeye yönelik ve akciğer dokusu üzerindeki STZ'nin etkilerini belirleyen bir çalışma henüz bulunmamaktadır.


Bu çalışma, sıçanlarda bir diyabet modeli oluşturularak bu durumun akciğer dokusundaki etkilerini incelemeyi amaçlamaktadır. Histopatolojik görüntülerdeki değişiklikleri analiz etmek ve sınıflandırmak amacıyla kaspaz immunohistokimyasal boyama ile Kontrol (sağlıklı) ve STZ ile diyabetik rat modeli veri grupları oluşturulmuştur. Elde

edilen görüntülerin LBP ve GLCM özellikleri çıkarılmıştır. Bu özelliklerin sınıflandırılması için SVM, KNN, YSA ve DT algoritmaları gibi 4 farklı makine öğrenme algoritması uygulanmış ve gruplar arası farklılıklar analiz edilmiştir. Böylece literatürde ilk kez DM'nin akciğer dokularına olan etkilerini incelemek amacıyla kaspas immunohistokimya görüntülerinin LBP ve GLCM özellikleri ile analizi ve sınıflandırılması yapılmıştır.

II. MATERYAL VE METHOD

A. Veri Seti

Erciyes Üniversitesi Deneysel Hayvanları Etik Kurulu tarafından onaylanan (Karar numarası: 19/004) mevcut çalışma protokolü, daha önce çiftleşmemiş üç aylık, sağlıklı 14 yetişkin (8-10 haftalık) Wistar albino dişi sıçandan oluşan bir grup tarafından üretilmiştir. Bu sıçanlar rastgele iki gruba ayrılmıştır; her biri yedi sıçan içeren Kontrol ve STZ gruplarına ayrılmıştır. Diyabet modeli oluşturulan STZ grubundaki sıçanlar, bir gece aç bırakıldıktan sonra sitrat tamponunda taze hazırlanmış tek bir doz STZ (Sigma-Aldrich, St. Louis, MO, ABD) (0.1 M, Ph 4) intraperitoneal (ip) olarak enjekte edilirken, kontrol grubundaki sıçanlara eşit miktarda sadece sitrat tamponu uygulanmıştır. Hem kontrol hem de STZ grupları aktif kaspaz-3 immunohistokimyasal boyama yöntemi ile boyandı. İşlem sırasında rastgele 14 sıçan üzerinden, 7 alan seçilerek 49 adet STZ ve 49 adet kontrol grubu elde edilmiştir. Görüntülerin anlaşılabilirliği (netliği, görünürlüğü) açısından kontrol grubundan rastgele seçilen 2 görüntü daha eklenerek 51 adet kontrol grubu oluşturularak sınıflandırma çalışmasında kullanıldı. Bu görüntülerin boyutları 3072x4080 idi ve görüntü sayısını artırmak amacıyla tüm görüntüler, her bir görüntüden 9 adet görüntü parçası elde etmek için 1024x1360 olarak bölündü. Şekil 1'de gösterildiği gibi her bir görüntü parçası oluşturuldu.



Şekil 1. (Üst) Kontrol grubu – (Alt) STZ grubu örnek görüntüleri

B. Öznitelik Çıkarımları

- Yerel İkili Örüntüler (Local Binary Pattern, LBP)


LBP operatörü, gri seviyeden bağımsız olan bir doku ölçümü yöntemidir. Bu yöntem ile görüntünün her pikseli için birer ve sıfırlardan oluşan etiketler verilir. Bu etiketler merkez pikselin NxN komşuluğundaki piksellerin karşılaştırılmasıyla oluşur. Bu operatörün en önemli özelliği ise parlaklık değişimlerine karşı dayanıklı olmasıdır. Genel olarak LBPP,R

üç farklı dairesel komşulukla tanımlanabilir. P komşu sayısını, R ise örnekleme yarıçapını temsil etmektedir. Kullandığımız LBP operatörleri şekil 2' de gösterilmektedir [14], [15].

LBP formülü denklem 1'deki gibi ifade edilir ;

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) x^p$$

$$u(y) = \{1, y \geq 0 \quad 0, y < 0\} \quad (1)$$



P=8 R=1

Şekil 2. Kullanılan dairesel LBP_{P,R} operatörleri

Burada X_c üretilen merkez pikseli, X_p, X_c' nin komşularını, R komşuların merkez piksele olan uzaklığını, P ise işleme giren komşu sayısını ifade etmektedir.

Bu çalışmada LBP_{8,1} operatörü kullanılarak 3 x 3' lük matrisler ile komşuluk analizleri yapılacaktır.

- Gri Seviye Eş Oluşum Matrisi (Gray-Level Co-Occurrence Matrix, GLCM)

GLCM metodu, farklı dokuların sınıflandırılması için Haralick ve ekibinin geliştirdiği, piksel tabanlı bir görüntü işleme yöntemidir [16]. Bu yöntem, görüntüden öznitelik elde etmek için pikseller arasındaki ilişkiyi kullanır. GLCM matrisini oluşturmak için, pikseller arasındaki uzaklık (D), piksellerin açısı (0°, 45°, 90° ve 135° = θ), ve gri ton seviye sayısı (maksimum 256) gibi parametreler temel alınır [17]–[19]. Haralick ve diğerleri tarafından tanımlanan 14 farklı doku özelliği, görüntü analizi için kullanılmıştır. Bu özellikler arasında homojenlik, entropi, enerji, kontrast gibi değerler bulunur [20] Bu çalışmada, pikseller arasındaki uzaklık bir birim, yönlendirme açısı olarak ise 0° seçilmiş ve Haralick özellikleri arasından kontrast, korelasyon, homojenlik ve enerji hesaplanmıştır [21]. Enerji, Denklem 2' de gösterildiği gibi hesaplanır ve GLCM'den elde edilen enerji, görüntünün homojenliğini gösteren bir özniteliktir [22].

$$Enerji = \sum_{ij} p_{ij}^2 \quad (2)$$

Kontrast özelliği görüntüde bulunan yerel değişimlerin seviyesine dair bilgi vermektedir. Denklem 3' deki şekilde ifade edilir [22].

$$Kontrast = \sum_{ij} |i - j|^2 p_{ij} \quad (3)$$

Homojenlik, GLCM' deki elemanlar ve çapraz şekilde oluşacak olan elemanların dağılımına yakınlığını denklem 4' deki gibi ölçmektedir [22].

$$\text{Homojenlik} = \sum_{ij} \frac{p_{ij}}{1+|i-j|} \quad (4)$$

Korelasyon özelliği piksel ve komşusunun birbirleriyle ne kadar ilişkili olduğuna dair bilgi vermektedir. Denklem 5 ile ifade edilmektedir. Bu denklemdeki μ ortalamayı, σ standart sapmayı ve P ise indislerin belirttiği GLCM elemanını göstermektedir [22].

$$\text{Korelasyon} = \sum_{ij} \frac{p_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (5)$$

Böylece her bir görüntüden 59 adet LBP ve 4 adet GLCM olmak üzere toplam 63 adet özellik çıkarılmıştır. Bu özelliklerden en önemlilerini seçmek amacıyla Lasso yöntemi kullanılmıştır. Lasso, regresyon katsayılarını sıfıra yaklaştırarak (bazı katsayıları tamamen sıfır yapar) özellik seçimi yapar. Hem modeli daha az karmaşık hale getirir hemde gereksiz veya etkisiz özellikleri modelden çıkarılmasına olanak sağlar [23]. Bu çalışmada lasso yöntemi ile özellikler random seçilerek sınıflandırma çalışmasında kullanılmıştır.

C. Sınıflandırma Yöntemleri

Elde edilen öznelikler, bu çalışmada dört adet sınıflandırma yöntemi ile sınıflandırılmıştır.

- Destek Vektör Makinesi (Support Vector Machine, SVM)


SVM, sınıflandırma yapılırken sınıfları birbirinden ayıracak olan optimal ayırma hiper düzleminin elde edilmesini amaçlayan veri odaklı araştırma alanlarında sıkça kullanılan makine öğrenme yaklaşımıdır [24], [25]. Bu amaç doğrultusunda farklı sınıflara ait destek vektörleri arasındaki uzaklık maksimize etmektedir. Bu yöntem ile iki veri sınıfını en iyi şekilde ayırtmak için karar sınırları veya hiper düzlemler belirlenir. Doğrusal olmayan bir veri kümesinde, SVM'ler doğrusal bir hiper düzlem çizemez. Bu nedenle çekirdek numaraları kullanılmaktadır.

- K-en yakın komşu (K-Nearest Neighbors, KNN)

KNN, sınıflandırma yapılacak verilerin öğrenme kümesindeki normal davranış verilerine benzerliklerini hesaplayarak; en yakın olduğunu düşündüğü k verinin ortalamasıyla, belirlenerek eşik değere göre sınıflara atan parametrik olmayan bir sınıflandırma yöntemidir [26]. Kullanılan k değeri sınıflandırma yapılacak olan verinin kaç veri ile yakınlığını belirlememizi sağlamaktadır.

- Yapay Sinir Ağlar (YSA)

YSA, insan beyninin işlemlerini taklit ederek nöronlardan oluşan basit işlem birimlerinin bağlantılarını kullanan bir tür yapay zeka sistemidir [26]. Yapay sinir ağları, girdiler, ağırlıklar, toplam fonksiyonlar, aktivasyon fonksiyonları ve çıktılardan oluşur. YSA'daki amaç, ağırlık değerlerini en uygun hale getirmektir. Bu amaçla girdi değerleri ile beklenen çıktıları karşılaştırarak eşik hata değerine ulaşmamışsa ağırlık değerleri tekrar güncellenir ve hatayı minimize etmek için çaba harcanır. Şekil 3' te bir yapay sinir ağı bileşenleri verilmiştir.



Şekil 3. YSA'ya ait bir algılayıcının temel yapısı

- Karar ağacı (Decision Tree, DT)

DT, bağımsız değişken kümesinin değerlerini kullanarak bir bağımlı değişkenin değerini tahmin etmek için kullanılan iki yönlü bölünmüş bir mantıksal modeldir [27]. Her dal, köke bağlı olarak düğümlere bağlanır. Verideki her bir öznelik, sınıflandırma sonrasında ağaçtaki düğüm noktalarını temsil eder. Her yaprak, bir sınıfı temsil ederken ağacın yapısı arasında kalan düğüm noktaları sınıflandırma kuralları olarak kabul edilir [28].

Kullanılan sınıflandırma modellerinin performansını değerlendirmek için karmaşıklık matrisi (confusion matrix) kullanılmıştır [28]. Bu matris, doğru pozitif (True Positive-TP), doğru negatif (True Negative-TN), yanlış pozitif (False Positive-FP) ve yanlış negatif (False Negative-FN) olmak üzere dört temel kategoriyi içerir. Mevcut verilerle tahmin edilen verilerin karşılaştırılması ile hassasiyet (kesinlik, precision), duyarlılık (sensitivity), F1 skoru (F1 score) ve doğruluk (accuracy) ve özgünlük (specificity) gibi kavramlar hesaplanmaktadır. Karmaşıklık matrisi ile elde edilen değerler [29] aşağıda verildiği gibi hesaplanır.

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{Duyarlılık (Sensitivity)} = \frac{TP}{TP + FN}$$

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP + FP}$$

$$\text{F1 Skor (f1 score)} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

$$\text{Özgünlük (Specificity)} = \frac{TN}{TN + FP}$$

III.SONUÇLAR

Önerilen çalışmada, her bir görüntünün, kırmızı, yeşil ve mavi (Red, Green, Blue - RGB) olmak üzere 3 kanalı da inceleyerek LBP ve GLCM yöntemleriyle öznelik çıkarılmıştır. Daha sonra bu öznelikler, 4 farklı makine öğrenmesi yöntemi (YSA, DT, SVM ve KNN) ile sınıflandırılmıştır. Yöntemlerin sınıflandırma sonuçları, Doğruluk (Accuracy), Hassasiyet (Precision), F1 skor (F1 score) ve Özgünlük (Specificity) metrikleri ile değerlendirilmiş ve sonuçlar Tablo 1, Tablo 2 ve Tablo 3'te sunulmuştur.

Tablo 1'de kırmızı kanal görüntülerin, Tablo 2'de yeşil kanal görüntülerin, ve Tablo 3'te mavi kanal görüntülerin

sınıflandırılması sonucu hesaplanan performans değerleri verilmiştir.

Tablo 1. Kırmızı Kanal için

	Doğruluk	Hassasiyet	Özgünlük	F1 Skor
DT	0.6737	0.64	0.6622	0.6472
KNN	0.8498	0.8378	0.6644	0.7710
SVM	0.8899	0.82	0.8022	0.8128
YSA	0.9108	0.8244	0.8222	0.8235

Tablo 2. Yeşil Kanal için

	Doğruluk	Hassasiyet	Özgünlük	F1 Skor
DT	0.6735	0.6400	0.6111	0.6309
KNN	0.7240	0.7044	0.6622	0.6899
SVM	0.8718	0.7889	0.7933	0.7906
YSA	0.8693	0.7978	0.7844	0.7925

Tablo 3. Mavi Kanal için

	Doğruluk	Hassasiyet	Özgünlük	F1 Skor
DT	0.7623	0.7089	0.6911	0.7026
KNN	0.8959	0.9600	0.7133	0.8546
SVM	0.9302	0.9044	0.8489	0.8800
YSA	0.9387	0.8556	0.8533	0.8546

Tablo 1’ den kırmızı kanal ve Tablo 3’ ten mavi kanal için en iyi sınıflandırma performansını YSA ile elde edildiği, Tablo 2’ den ise yeşil kanal için en iyi performansın SVM ile elde edildiği görülmektedir.

IV. TARTIŞMA

Yapılan çalışmada, diyabetin akciğer dokularında oluşturduğu hasarın sınıflandırılabilmesi amacıyla LBP ve GLCM yöntemleriyle elde edilen özellikler arasından Lasso yöntemi ile en önemli olanları kullanarak makine öğrenmesiyle sınıflandırma yapılmıştır. Böylece şeker hastalığının akciğer dokularına olan etkisi objektif bir şekilde analiz edilmiştir. Sınıflandırma yöntemleri ile elde edilen sonuçlar, RGB renk uzayının her kanalı için ayrı ayrı hesaplanan performans parametreleri ile değerlendirilmiştir.

Tablo 1’de RGB renk uzayının kırmızı kanalı için elde edilen görüntülerin sınıflandırma sonuçları incelendiğinde, en iyi sınıflandırma performansını YSA ile elde edildiği görülmektedir. YSA kullanıldığında %91.08 doğruluk, %82.44 hassasiyet, %82.22 özgünlük ve %82.35 f1 skoru elde edilmiştir.

Tablo 2’de ise yeşil kanal için elde edilen görüntülerin sınıflandırma sonuçları değerlendirildiğinde, en iyi sınıflandırma performansını %87.15 doğruluk ile SVM kullanarak elde edildiği görülmüştür. Diğer performans metriklerinin %78.89 hassasiyet, %79.33 özgünlük ve %79.06 f1 skoru olduğu gözlemlenmiştir.

RGB renk uzayının mavi kanalı için en iyi performansını %93.87 doğruluk, %85.56 hassasiyet, %85.33 özgünlük ve %85.46 f1 skor ile YSA sağlamıştır.

V. SONUÇ

Yapılan çalışmada, kaspaz immunohistokimya görüntülerinin LBP ve GLCM özelliklerinin diyabetin akciğer dokularındaki etkilerini objektif olarak analiz etmede etkili bir yol olduğunu gösterilmektedir. Çalışma, RGB renk uzayının farklı kanalları (kırmızı, yeşil ve mavi) için farklı sınıflandırma yöntemlerini değerlendirmiş ve en iyi performansın YSA ve SVM ile elde edildiği bulunmuştur.

Bu sonuçlar, diyabetin akciğer dokularına olan etkilerini değerlendirmenin, görüntü işleme ve makine öğrenme tekniklerini kullanarak daha iyi bir performans ile gerçekleştirilebileceğini göstermektedir. Özellikle YSA ve SVM gibi makine öğrenme yöntemlerinin, bu tür analizlerde yüksek doğruluk ve hassasiyet sağlayabileceği görülmüştür. Gelecek çalışmalarda farklı boyama teknikleriyle elde edilmiş görüntüler üzerinde renk uzayları (CMYK, HSV, XYZ vb.) uygulanarak derin öğrenme metoduyla sınıflandırılması planlanmıştır.

Yazarların Katkıları

Tuğba ŞENTÜRK ve Fatma LATİFOĞLU, algoritmaların geliştirilmesine, makalenin yazılmasına ve gözden geçirilmesine katkıda bulundular. Arzu YAY, Münevver BARAN ve Demet BOLAT ise deneysel çalışmaların tasarlanması ve yürütülmesinde önemli roller üstlendiler; aynı zamanda makalenin yazımına ve gözden geçirilmesine de katkıda bulundular. Tüm yazarlar aktif bir şekilde araştırmanın şekillendirilmesine katkı sağladılar ve makalenin nihai versiyonunu onayladılar.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etik Beyanı

Yazarlar, bu çalışmanın Araştırma ve Yayın Etik kurallarına uygun olduğunu beyan ederler.

KAYNAKÇA

- [1] American Diabetes Association, "Diagnosis and Classification of Diabetes Mellitus," *Diabetes Care*, vol. 33, no. 1, pp. 62–69, 2010, doi: 10.2337/dc10-S062.
- [2] M. Panwar, A. Acharyya, R. A. Shafik, and D. Biswas, "K-nearest neighbor based methodology for accurate diagnosis of diabetes mellitus," *Proceedings - 2016 6th International Symposium on Embedded Computing and System Design, (ISED 2016)*, pp. 132–136, Jul. 2017, doi: 10.1109/ISED.2016.7977069.
- [3] S. K. Goswami, M. Vishwanath, S. Gangadarappa, R. Razdan, and M. N. Inamdar, "Efficacy of ellagic acid and sildenafil in diabetes induced sexual dysfunction," *Pharmacognosy Magazine*, vol. 10, no. 3, pp. 581–587, Jul. 2014, doi: 10.4103/0973-1296.139790.
- [4] M. Lotfy, J. Adeghate, H. Kalasz, J. Singh, and E. Adeghate, "Chronic Complications of Diabetes Mellitus: A Mini Review," *Current Diabetes Reviews*, vol. 13, no. 1, pp. 3–10, 2017.
- [5] D. Bolat, M. Ülger, M. Baran, I. T. Turan, and A. Yay, "Lung injury aggravated by Streptozotocin-induced diabetes: an experimental study," *Cukurova Medical Journal*, vol. 47, no. 1, pp. 175–182, Mar. 2022, doi: 10.17826/CUMJ.1020617.
- [6] S. I. Ayon and M. M. Islam, "Diabetes Prediction: A Deep Learning Approach," *I. J. Information Engineering and Electronic Business*, vol. 12, no. 2, pp. 21–27, 2019, doi: 10.5815/ijieeb.2019.02.03.
- [7] S. Palaniappan and R. Awang, "Intelligent heart disease prediction system using data mining techniques," *AICCSA 08 - 6th IEEE/ACS International Conference on Computer Systems and Applications*, pp. 108–115, 2008, doi: 10.1109/AICCSA.2008.4493524.
- [8] K. Kannadasan, D. R. Edla, and V. Kuppli, "Type 2 diabetes data classification using stacked autoencoders in deep neural networks," *Clin Epidemiol Glob Health*, vol. 7, no. 4, pp. 530–535, Dec. 2019, doi: 10.1016/J.CEGH.2018.12.004.
- [9] M. Heydari, M. Teimouri, Z. Heshmati, and S. M. Alavinia, "Comparison of various classification algorithms in the diagnosis of type 2 diabetes in Iran," *Int J Diabetes Dev*

- Ctries, vol. 36, no. 2, pp. 167–173, Jun. 2016, doi: 10.1007/S13410-015-0374-4/TABLES/6.
- [10] A. H. Yurttakal, H. Erbay, G. Çınarar, and H. Baş, “Classification of Diabetic Rat Histopathology Images Using Convolutional Neural Networks,” *International Journal of Computational Intelligence Systems*, vol. 14, no. 1, pp. 715–722, 2021, doi: 10.2991/ijcis.d.201110.001.
- [11] A. Makalesi, G. Harman, Y. Üniversitesi, M. Fakültesi, and B. Mühendisliği Bölümü, “Destek Vektör Makineleri ve Naive Bayes Sınıflandırma Algoritmalarını Kullanarak Diabetes Mellitus Tahmini,” *European Journal of Science and Technology*, vol. 32, no. 32, pp. 7–13, Dec. 2021, doi: 10.31590/EJOSAT.1041186.
- [12] A. Makalesi Diyabet Hastalığının Erken Aşamada Tahmin Edilmesi İçin Makine Öğrenme Algoritmalarının Performanslarının Karşılaştırılması, K. Akyol, A. KARACI Bilgisayar Mühendisliği Bölümü, M. ve Mimarlık Fakültesi, and K. Üniversitesi, “Diyabet Hastalığının Erken Aşamada Tahmin Edilmesi İçin Makine Öğrenme Algoritmalarının Performanslarının Karşılaştırılması,” *Duzce University Journal of Science and Technology*, vol. 9, no. 6, pp. 123–134, Dec. 2021, doi: 10.29130/DUBITED.1014508.
- [13] G. Tarihi, F. Balgetir, and N. Kocaman, “Streptozotosin ile Oluşturulmuş Diyabetik Sıçanların Beyin Dokusunda İrisin Üzerine Enalaprilin Etkileri,” *Firat Med J*, vol. 21, no. 4, pp. 177–182, 2016.
- [14] T. Tuncer, E. Avcı, A. Bilişim, M. Bölümü, F. Üniversitesi, and Y. M. Bölümü, “Yerel İkili Örüntü Tabanlı Veri Gizleme Algoritması: LBP-LSB Local Binary Pattern Based Data Hiding Algorithm: LBP-LSB”.
- [15] B. Yang and S. Chen, “A comparative study on local binary pattern (LBP) based face recognition: LBP histogram versus LBP image,” *Neurocomputing*, vol. 120, pp. 365–379, Nov. 2013, doi: 10.1016/J.NEUCOM.2012.10.032.
- [16] H. Serçe, Y. Baştanlar, A. Temizel, and Y. Yardimci, “Tümyönlü imgeler için küresel alanda kenarların ve ilgi noktalarının tespiti üzerine,” 2008 IEEE 16th Signal Processing, Communication and Applications Conference, SIU, 2008, doi: 10.1109/SIU.2008.4632658.
- [17] C. Sweetlin Hemalatha, V. Vaidehi, and R. Lakshmi, “Minimal infrequent pattern based approach for mining outliers in data streams,” *Expert Syst Appl*, vol. 42, no. 4, pp. 1998–2012, Mar. 2015, doi: 10.1016/J.ESWA.2014.09.053.
- [18] R. M. Haralick, I. Dinstein, and K. Shanmugam, “Textural Features for Image Classification,” *IEEE Trans Syst Man Cybern*, vol. SMC-3, no. 6, pp. 610–621, 1973, doi: 10.1109/TSMC.1973.4309314.
- [19] S. N. Ondimu and H. Murase, “Effect of probability-distance based Markovian texture extraction on discrimination in biological imaging,” *Comput Electron Agric*, vol. 63, no. 1, pp. 2–12, Aug. 2008, doi: 10.1016/J.COMPAG.2008.01.007.
- [20] R. M. Haralick, I. Dinstein, and K. Shanmugam, “Textural Features for Image Classification,” *IEEE Trans Syst Man Cybern*, vol. SMC-3, no. 6, pp. 610–621, 1973, doi: 10.1109/TSMC.1973.4309314.
- [21] V. Göreke, E. Uzunhisarcıklı, A. Güven, C. Üniversitesi Sivas Meslek Yüksek Okulu Bilgisayar Teknolojileri Bölümü vğoreke, and E. Üniversitesi Kayseri Meslek Yüksekokulu Otomasyon Bölümü, “Biyomedikal Görüntü İşleme ve Yapay Zeka Uygulamaları 2. Gün 26 Eylül,” Cuma, 2014.
- [22] C. A. YAVRU, İ. S. ÜNCÜ, M. KALELİ, and S. AKYÜREKLİ, “CIGS İnce Film Yüzeyindeki Morfolojik Farklılıkların GLCM Görüntü İşleme Yöntemi ile İncelenmesi,” *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, vol. 17, no. 2, pp. 460–477, Nov. 2022, doi: 10.29233/SDUFEFFD.1125106.
- [23] S. Tiwari, N. Gupta, and P. Yadav, “Diabetes Type2 Patient Detection Using LASSO Based CFFNN Machine Learning Approach,” *Proceedings of the 8th International Conference on Signal Processing and Integrated Networks, SPIN 2021*, pp. 602–608, 2021, doi: 10.1109/SPIN52536.2021.9565965.
- [24] M. DEMİRCİ, “Destek Vektör Makineleri ve M5 Karar Ağacı Yöntemleri Kullanılarak Yağış Akış İlişkisinin Tahmini,” *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 10, no. 3, pp. 1113–1124, Sep. 2019, doi: 10.24012/DUMF.525658.
- [25] O. Uslu, S. Akyol, E. O. Üniversitesi, M.-M. Fakültesi, and M. Bölümü, “Türkçe Haber Metinlerinin Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırılması,” *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, vol. 2, no. 1, pp. 15–20, Jan. 2021, Accessed: Aug. 08, 2023. [Online]. Available: <https://dergipark.org.tr/en/pub/estudambilisim/issue/60018/852183>
- [26] A. Makalesi et al., “Destek Vektör Makineleri, YSA, K-Means ve KNN Kullanarak Arı Türlerinin Sınıflandırılması”.
- [27] H. R. Bittencourt and R. T. Clarke, “Use of Classification and Regression Trees (CART) to Classify Remotely-Sensed Digital Images,” *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 6, pp. 3751–3753, 2003, doi: 10.1109/IGARSS.2003.1295258.
- [28] S. B. Kotsiantis, “Decision trees: A recent overview,” *Artif Intell Rev*, vol. 39, no. 4, pp. 261–283, Apr. 2013, doi: 10.1007/S10462-011-9272-4/METRICS.
- [29] E. Betül KINACI, H. Bal, and H. Kinaci, “POLİTEKNİK DERGİSİ JOURNAL of POLYTECHNIC Epileptik nöbet tespiti için destek vektör regresyon temelli yeni bir sınıflandırma yaklaşımı A new classification approach based on support vector regression for epileptic seizure detection”, doi: 10.2339/politeknik.1055549.