



Görüntü İşleme ve Evrişimsel Sinir Ağları Kullanarak Diyabetik retinopati Teşhisi

Diagnosis of Diabetic Retinopathy Using Image Processing and Convolutional Neural Network

Ömer DEPERLİOĞLU
Bilgisayar Teknolojileri Bölümü,
Afyon Kocatepe Üniversitesi,
Afyonkarahisar, Türkiye
deperlioglu@aku.edu.tr

Utku KÖSE
Bilgisayar Mühendisliği Bölümü,
Süleyman Demirel Üniversitesi,
Isparta, Türkiye
utkukose@sdu.edu.tr

Özetçe— Diyabetik retinopati, şeker hastalığı kaynaklı ciddi bir göz hastalığıdır ve gelişmiş ülkelerde körlüğün en yaygın nedenidir. Bu çalışma retinal fundus görüntülerinden diyabetik retinopatiyi teşhis etmek için görüntü işleme ve derin öğrenmenin kullanımını açıklamaktadır. Retinal fundus görüntülerini iyileştirmek için HSV, V dönüşümü algoritması ve histogram eşitleme tekniklerini içeren pratik bir yöntem kullanılmıştır. Son olarak, retinal fundus görüntüsüne Gauss alçak geçiren filtre uygulanmıştır. Görüntü işlemeden sonra, Sınıflandırma Evrişimsel Sinir Ağı kullanılarak yapılmıştır. Önerilen yöntemin performansı Kaggle Diyabetik Retinopati Saptama veri tabanındaki 400 retinal fundus görüntüsü kullanılarak değerlendirilmiştir. Görüntü işleme sonrası, görüntü işleminin her aşaması için sınıflandırma çalışması yapılmıştır. Her aşama için yirmi deneme yapılmış ve ortalama değerler alınmıştır. Bu çalışmada doğruluk % 96,67, duyarlılık % 93,33, özgüllük % 97,78, hassasiyet ve hatırlama % 93,33, F skoru % 93,33 olarak bulunmuştur. Elde edilen sonuçlar, önerilen yöntemin, retinal fundus görüntülerinden diyabetik retinopatiyi teşhis etmek için çok etkili ve başarılı olduğunu göstermektedir.

Anahtar Kelimeler — *Diyabetik retinopati; Kaggle Diyabetik Retinopati Saptama veri tabanı; Görüntü işleme; Evrişimsel sinir ağı.*

Abstract— Diabetic retinopathy is a serious eye disease that originates from diabetes mellitus and is the most common cause of blindness in the developed countries. This study describes the use of image processing and deep learning to diagnose diabetic retinopathy from retinal fundus images. For retinal fundus images enhancement approach, a practical method which contains HSV, V transform algorithm and histogram equalization technics was used. Finally, Gaussian low-pass filter was applied to the retinal fundus image. After the image processing, the classification was made using the Convolutional Neural Network. The performance of the

proposed method was assessed using 400 retinal fundus images in the Kaggle Diabetic Retinopathy Detection database. In experiments, classification work has been done for each stage of the image processing. The classification study performed after image processing. Twenty experiments were done for every stage and average values were found. In this experiment, the accuracy was 96.67%, the sensitivity was 93.33%, the specificity was 93.33%, the precision was 93.33%, the recall was 93.33%, and the F-score was 93.33%. The obtained results show that the proposed method is very efficient and successful to diagnose diabetic retinopathy from retinal fundus images.

Keywords — *Diabetic Retinopathy; Kaggle Diabetic Retinopathy Detection database; Image Processing; Convolutional Neural Network.*

I. GİRİŞ

Diyabetle ilişkili başlıca istenmeyen durumlardan birisi de uzun süreli tedavi eksikliklerinde görme bozukluğuna neden olan diyabetik retinopatidir. Diyabetik retinopati (DR), şeker hastalığının neden olduğu ciddi bir göz hastalığıdır ve gelişmiş ülkelerde körlüğün en yaygın nedenidir. Üç şeker hastası bireyden biri DR belirtileri göstermektedir ve maalesef bu hastaların görme yetenekleri için çok şiddetli bir tehdit oluşturmaktadır. Doğal olarak, hastaların bu durumdan etkilenmesini önlemek ya da en azından DR'nin ilerlemesini yavaşlatmak için erken tanı ve tedavi çok önemlidir. Bu nedenle diyabetik hastaların kitle taraması son derece önemlidir. Bununla birlikte, manuel derecelendirme her zaman doğru sonuçları vermeyebilir çünkü iyi bir deneyim ve uzmanlık gerektirir. Bu nedenle, renkli fundus görüntülerine dayanan güvenilir bilgisayarlı tarama sistemlerinin kurulması için çok çaba harcanmıştır [1, 2].



Aynı şekilde, görüntü işleme ve makine öğrenmesini kullanarak bilgisayar destekli DR'nin saptanması üzerine birçok çalışma yapılmıştır. Seoud ve arkadaşları Diyabetik retinopati için otomatik bir derecelendirme sistemi önermişlerdir. Çalışmalarında, bir lezyon olasılık haritası oluşturmak için kırmızı bir lezyon tespit ederek sınıflandırma için boyut ve olasılık bilgisini birleştiren 35 özellik elde etmişlerdir. Bu özellikleri rastgele bir orman kullanarak sınıflandırmışlar ve %74,1'lik bir sınıflandırma doğruluğu elde etmişlerdir [3]. Savarkar ve meslektaşları, aday pikselde merkezlenen farklı yönlerin kesikli kesimleri boyunca yoğunluk değerlerinin analizi yoluyla mikro anevrizmaları (MA) algılama yöntemini önermişlerdir. Bu yöntemde, görüntüde önce tepe değerleri belirlenmiş ve daha sonra özellik kümesi belirlenerek sınıflandırılmıştır [4]. Sreejini ve Govindan, görüntü ön işlemlerini, Parçacık Sürü Optimizasyonu (PSO) algoritması ve Fuzzy C-Means Kümelenebilirlik kombinasyonunu içeren, eksüda bölütlemesi, optik disk eliminasyonu, fovea ve maküler bölge lokalizasyonu ve sınıflandırması için bir yöntem önermiştir [5]. Bir başka çalışmada Safitri ve Juniati, filtre bankaları kullanarak MA'ların erken teşhisi için üç aşamalı bir sistem önerilmiştir. İlk aşamada, sistem retinal görüntüde mevcut MA'lar için olası tüm aday bölgeleri çıkarmaktadır. Bu bölgeler, Gaussian karışım modelini ve destek vektör makinesini birleştiren hibrid bir sınıflandırıcı ile sınıflandırılmıştır [6]. Akremetal ve arkadaşları görüntü ön işlemlerini ve sınıflandırmayı kullanan başka bir teşhis yönteminde, Fractal analizini ve K en yakın komşu bileşenlerini kullanmışlardır. Bu çalışmada sınıflamanın doğruluğu % 98.17'dir [7]. Acharya ve diğerleri doku özelliklerini kullanarak ve diyabetik retinopatinin otomatik kitle taraması için destek vektör makine sınıflandırıcısını önermişlerdir [8].

Son zamanlarda yaygın olarak kullanılmaya başlayan *Derin Öğrenme*, birbirleriyle iletişim kuran çok sayıda soyut katmanın bulunduğu gelişmiş bir makine öğrenme tekniğidir. Her katman önceki katmana derinden bağlıdır ve kararlarını önceki katman tarafından beslenen çıktıya dayanarak yapar. Başka bir deyişle *Derin Öğrenme*, Yapay Zekada yapısal olmayan veya etiketlenmemiş verilerin denetimsizliğini öğrenebilen ağlara sahip makine öğrenmesinin bir alt kümesidir. Derin Öğrenme veya Derin Sinir Ağı olarak da bilinmektedir [9]. Özellikle görüntüleri sınıflandırmak için Evrimsel Sinir Ağları (ESA) geliştirilmiştir.

Yukarıda verilen örneklerden de görülebileceği gibi, retinal fundus görüntülerinin sınıflandırma başarısını arttırmak için yüksek işlem yüküne sahip karışık yöntemler kullanılmaktadır. Bu çalışmanın amacı, klasik ve basit görüntü işleme yöntemlerini ve Evrimsel Sinir Ağları kullanarak sınıflamanın kolayca yapılabileceğini, böylece etkili bir teşhis ortaya konulabileceğini göstermektir. Çalışmanın kalanında kullanılan yöntemler, yapılan uygulama ve elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Görüntü işleminin her aşaması için yapılan

sınıflandırma çalışmalarında elde edilen sonuçlar karşılaştırılmış ve görüntü işleminin önemi vurgulanmıştır.

II. MATERYAL METOT

Bu çalışmada, görüntü işleme ve ESA kullanılarak diyabetik retinopati teşhis çalışması yapılmıştır. Çalışmada Kaggle retina görüntüleri veritabanı kullanılmıştır. Diyabetik retinopati teşhis çalışmasının aşamaları sırasıyla aşağıda verilmiştir.

A. Kaggle Diyabetik Retinopati Saptama Veritabanı

Kaggle Diyabetik Retinopati Saptama Veri tabanı 80000'nin üzerinde renkli fundus görüntüsü içeren herkese açık bir veri tabanıdır [10]. Görüntüler, çeşitli dijital fundus kameraları ile Kaliforniya ve diğer yerlerdeki birçok birincil bakım merkezinden toplanmıştır. Tanımları 433×289 piksel ile 5184×3456 piksel arasındadır ve tüm dosyalar jpeg formatındadır. Bu görüntüler daha sonra DR taraması için ücretsiz bir platform olan EyePACS'a yüklenmiştir [11]. Her bir göz için, DR şiddeti ETDRS [12] skalasına göre bir uzman tarafından derecelendirilmiştir. Bunlar: 'DR yokluğu', 'hafif proliferatif olmayan DR (NPDR)', 'orta NPDR', 'şiddetli NPDR' ve 'proliferatif DR (PDR)' dir [13].

B. Görüntü İşleme

Önerilen yöntemde, retina fundus görüntülerini iyileştirmek için HSV, V dönüşümü algoritması ve histogram eşitleme tekniklerini içeren pratik bir yöntem kullanılmıştır [14]. İlk olarak, bir fundus görüntüsü R (Kırmızı), G (Yeşil) ve B (Mavi) bileşenlerine ayrılıp RGB renk uzayından HSV renk uzayına dönüştürülmüştür. İkinci olarak, V elemanının uzantısı, aralığın ve aralığın sonunun kontrolü altında koordine edilmiştir. Daha sonra HSV renk uzayından RGB renk uzayına dönüştürülüp histogram eşitlemesi her R, G, B bileşenine uygulanmıştır. Bundan sonra, R, G, B bileşenleri renkli bir görüntü oluşturmak için birleştirilmiştir. Son olarak, retinal fundus görüntüsüne Gauss alçak geçiren filtre uygulanmıştır.

1) HSV Renk Sistemi

Ton, Doygunluk, Değer (Hue, Saturation, Value-HSV) renk alanı, renk ve yoğunluk arasında ayırım yapma yeteneğine sahip daha yaygın kullanılan renk sistemidir. HSV, görüntüleri RGB renk uzayından daha iyi bir şekilde yeniden yapılandırabilmektedir. Ton, kırmızı, mavi veya sarı gibi renk türüdür. Karşılık gelen renkler, kırmızı ile sarı, yeşil-mavi, mavi-macenta arasında, 0 ile 1 arasında renk tonları arasında değişmektedir. Örneğin, 0 kırmızıdır veya 55 sarı renktedir. Doygunluk, rengin yoğunluğudur. Doygunluk 0'dan 1,0'a kadar değiştiği için, karşılık gelen renkler, siyah ile beyaz arasındaki bir gri tonu olan doymamış (0) ve tam olarak doymuş (1) yoğun renk anlamına gelir. Değer, rengin parlaklığıdır. Değer veya parlaklık 0 ile 1 arasında değişirken, karşılık gelen renkler giderek daha parlak hale gelir. Örneğin, doymuşluğa bağlı olarak, 0 her zaman siyah veya 1 beyaz veya biraz doymuş renk olabilir [15].

2) Histogram Eşitleme

Histogram eşitleme (HE), görüntülerin görünürliğini ve kalitesini iyileştirmek için kullanılan en yaygın yöntemlerden birisidir. Bu yöntem, bir görüntünün histogramının dinamik aralığını artırır. HE bir giriş görüntüsünün gri seviyelerini bir çıktı görüntüsünün gri tonlarına eşler. Bu teknik, çok açık bir arka plan ve koyu ön plana sahip bir görüntü gibi, ilgili tonların geniş bölgelerine sahip görüntülerde özellikle yararlıdır. Bir görüntüdeki gizli detayları yerel bölgelerin karşıtlığını ortaya çıkararak bölgelerdeki farklılıkları gözlemlenebilir hale getirebilir [16].

C. Sınıflandırma

Bu çalışmada, Kaggle Diyabetik Retinopati Saptama Veri tabanındaki verilerin sınıflandırılması için, Evrişimsel Sinir Ağları (ESA) kullanılmıştır.


1) Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları, genellikle bir alt örnekleme adımı olan bir veya daha fazla sarmal katmandan oluşur. Daha sonra standart çok katmanlı sinir ağı gibi bir veya daha fazla tamamen bağlı katlardan oluşur. Bir ESA mimarisi, iki boyutlu (2B) görüntü girişlerin, 2B yapısından yararlanacak şekilde tasarlanmıştır. Bu, yerel bağlantılarla ve ilişkili ağırlıklarla, daha sonra sürekli değişen özelliklere yol açacak şekilde toplanır. ESA'ların diğer bir yararı, aynı sayıda gizli düğüme tamamen bağlı olan ağlardan daha az eğitim ve daha kolay parametreye sahip olmalarıdır. ESA'lar hayvanların biyolojik yapısından esinlenen çok katmanlı ileri beslemeli bir ağ türüdür. ESA'lar komşu katmanların nöronları arasında yerel bir bağlanma örneği uygulayarak mekânsal-yerel korelasyon kullanmaktadır. [17].


III. UYGULAMA

Tüm görüntü işleme ve sınıflandırma çalışmalarında MATLAB r2017a yazılımı kullanılmıştır. Bu çalışmada, i5 işlemcili, 8 GB bellekli bir bilgisayar kullanılması ve sınıflandırma çalışmalarının çok uzun sürmesi nedeniyle, Kaggle veritabanı, Train veri setindeki 5000 görüntüden ilk 400 renkli fundus sayısal görüntüleri, önerilen yöntemin performansını değerlendirmek için kullanılmıştır. Bu veri tabanı normal retina, proliferatif olmayan diyabetik retinopati (NPDR), proliferatif diyabetik retinopati (PDR) ve maküla ödemi (ME) gibi dört sınıf içermektedir.

Önce, bu görüntülere görüntü iyileştirme uygulanmıştır. Görüntü işleme çalışmalarında, elde edilen sonuçların karşılaştırılması ve değerlendirilmesi amacı ile entropi değeri ve histogram eğrilerine bakılmıştır. Örnek olarak "46_left.jpeg" görüntüsü için ölçülen orijinal görüntünün Entropi değeri 4,5827' den 6,8418'e yükselmiştir. Aynı görüntü için her aşamada elde edilen sonuçlar aşağıdaki sırada verilmiştir. (a) Yeniden ölçülen görüntü, (b) HSV, V açılımı, n=1 (c) Histogram Eşitleme, (d) Alçak geçiren Gaussian filtre için örnek görüntüler, Şekil 1'de ve Histogram diyagramları da Şekil 2'de verilmiştir.



Şekil 1. Görüntü işleme aşamasından örnek görüntüler



Şekil 2. Örnek görüntülerin histogram diyagramları

Renkli Fundus görüntüleri ESA ile sınıflandırılmıştır. ESA'lar, görüntü verilerini nesne olarak etiketle birlikte alan ve işleyen bir derin ağ türüdür. Bu uygulamada ESA 8 katmana sahiptir. Bu katmanlar sırasıyla görüntü giriş katmanı, sarmal (convolutional) katman, ReLU katmanı, çapraz kanal normalleştirme katmanı (cross channel normalization layer), maksimum havuz katmanı (max pooling layer), tam bağlı katman (fully connected layer), softmax katmanı ve sınıflandırma (classification layer) katmanıdır. Bu katmanların özellikleri Tablo 1'de verilmiştir.

TABLO I. SINIFLANDIRMA DOĞRULUK ORANLARI

Sıra No	Katman	Özelliği
1	Giriş katmanı	[195 322 3]
2	Sarmal Katman	(4, 16)
3	ReLU katmanı	-
4	Çapraz kanal normalleştirme katmanı	(2)
5	Maksimum havuz katmanı	(4,'Stride',3)
6	Tam bağlı katman	(numClasses, 'WLRF',20,'BLRF',20)
7	Softmax katmanı	%89,47
8	Sınıflandırma Katmanı	%78,00

Sınıflandırma işleminde, Kaggle veritabanındaki verilerden 400 adet görüntü kullanılmıştır. Bunlardan 300



örnek eğitim verisi ve 100 örnek de test verisi olarak kullanılmıştır. Görüntü işlemenin katkılarını görmek için her aşama için DR var/yok şeklinde sınıflandırma çalışmaları yapılmıştır. Her aşama için farklı eğitim ve test

verileri ile yirmi deneme yapılmış ve elde edilen ortalama değerler Tablo II'de verilmiştir.

TABLO II. SINIFLANDIRMA DEĞERLENDİRME FAKTÖRLERİ

GÖRÜNTÜ İŞLEME DURUMU	DOĞRULUK (ACCURACY)	DUYARLILIK (SENSITIVITY)	ÖZGÜLLÜK (SPECIFICITY)	HASSASİYET (PRECISION)	HATIRLAMA (RECALL)	F-SKOR
Ölçülendirilmiş Gör.	0.9340	0.8350	0.9587	0.8350	0.8350	0.8350
HSV V açılımı	0.9480	0.8700	0.9675	0.8700	0.8700	0.8700
Histogram Eşitleme	0.9570	0.8925	0.9732	0.8925	0.8925	0.8925
Gaussian Filtre	0.9667	0.9333	0.9778	0.9333	0.9333	0.9333

IV. SONUÇ VE ÖNERİLER

Bu çalışmada retina fundus görüntüleri iyileştirme yaklaşımı için HSV V açılımı ve histogram eşitleme yöntemlerini içeren pratik bir yöntem kullanılmıştır. Bu yöntemler iyi bilinen görüntü geliştirme yöntemleridir ve önerilen yöntemin uygulanması çok kolay ve hızlıdır. Görüntü işlemenin son aşamasında retinal fundus görüntüsüne Gauss alçak geçiren filtre uygulanmıştır. Daha sonra sınıflandırma, Evrişimsel Sinir Ağı kullanılarak yapılmıştır. Önerilen yöntemin performansı Kaggle veri tabanındaki 400 retinal fundus görüntüsü kullanılarak değerlendirilmiştir. Yapılan çalışmalarda, görüntü işlemenin her aşaması için sınıflandırma çalışması yapılmıştır. Her aşama için yirmi deneme yapılmış ve ortalama değerler alınmıştır. Buna göre görüntü işleme sonrası yapılan sınıflandırma çalışmasında: doğruluk % 96,67, duyarlılık % 93,33, özgüllük % 97,78, hassasiyet ve hatırlama % 93,33, F skoru % 93,33 olarak bulunmuştur. Elde edilen sonuçlar önerilen yöntemde görüntü işlemenin önemini ve bu yöntemin retinal fundus görüntülerinden diyabetik retinopatiyi teşhis etmek için çok etkili ve başarılı olduğunu göstermektedir.

Önerilen yöntem farklı görüntü işleme yöntemleri kullanılarak daha da iyileştirilebilir.

KAYNAKÇA

- [1] Antal B. and Hajdu A.. An Ensemble-Based System for Microaneurysm Detection and Diabetic Retinopathy Grading. IEEE Transactions on Biomedical Engineering, 2012, 59 (6): 1720-1726.
- [2] Islam, M., Dinh, A.V., Wahid, K.A. Automated Diabetic Retinopathy Detection Using Bag of Words Approach. J. Biomedical Science and Engineering, 2017, 10, 86-96.
- [3] Seoud, L. Chelbi J. and Cheriet F. Automatic Grading of Diabetic Retinopathy on a Public Database. In: Chen X, Garvin MK, Liu JJ, Trusso E, Xu Y editors. Proceedings of the Ophthalmic Medical Image Analysis Second International Workshop, OMIA 2015, Held in Conjunction with MICCAI 2015, Munich, Germany, October 9, 2015. 97-104. Available from <https://doi.org/10.17077/omia.1032>.
- [4] Savarkar S.P., Kalkar N., Tade S.L. Diabetic Retinopathy using Image Processing Detection, Classification and Analysis. International Journal of Advanced Computer Research 2013, 3(11): 585-588.
- [5] Sreejini K. S., Govindan V.K.. Severity Grading of DME from Retina Images: A Combination of PSO and FCM with Bayes

Classifier. International Journal of Computer Applications. 2013. 81 (16): 11-17.

- [6] Safitri D.W. and Juniati D.. Classification of Diabetic Retinopathy Using Fractal Dimension Analysis Of Eye Fundus Image. International Conference on Mathematics: Pure, Applied and Computation. AIP Conf. Proc. 1867, 020011-1-020011-11; doi: 10.1063/1.4994414. 2017.
- [7] Akrametal M.U., Khalid S., Khan S.A.. Identification and Classification of Microaneurysms for Early Detection of Diabetic Retinopathy. Pattern Recognition, 2013, 46: 107-116.
- [8] Acharya U.R., Ng E.Y.K., Tan J.H., vd. . An Integrated Index for the Ident. Journal of Medical Systems. 2012. 36 (3):2011-2020. <https://doi.org/10.1007/s10916-011-9663-8>.
- [9] Chandrayan P., Deep Learning: Autoencoders Fundamentals and types, <https://codeburst.io/deep-learning-types-and-autoencoders-a40ee6754663>. Son erişim 25 Ocak 2018.
- [10] Kaggle Diyabetik Retinopati Saptama Veritabanı <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>, Son erişim 29 Haziran 2018.
- [11] Cuadros J., Bresnick G., EyePACS: an adaptable telemedicine system for diabetic retinopathy screening. J. Diabetes Sci. Technol. 2009, 3 (3): 509-516.
- [12] Wilkinson C.P., Ferris F.L, Klein R.Eç, Lee P.P., Agardh C.D., Davis M., Dills D., Kampik A., Pararajasegaram R., Verdaguer J.T., Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales. Ophthalmology 2003. 110 (9), 1677-1682. doi: 10.1016/S0161- 6420(03)00475- 5 .
- [13] Quellec G. et al. Deep image mining for diabetic retinopathy screening Medical Image Analysis. Vol. 39, pp. 178-193. 2017.
- [14] Deperlioglu O., Kose U., Guraksin G. E. , Underwater Image Enhancement With HSV And Histogram Equalization, 7th International Conference on Advanced Technologies (ICAT 2018), Antalya, Turkey between April 28 to May 01, 2018: 461-465, E-ISBN: 978-605-68537-1-5.
- [15] Yassin A.A., Ghaban R.M., Saleh S.F., and Neima H.Z, Using Discrete Wavelet Transformation to Enhance Underwater Image, International Journal of Computer Science Issues, 2013, 10, (5), 2, pp. 220-228.
- [16] Kaur T. and Sidhu R.K., "Performance Evaluation of Fuzzy and Histogram Based Color Image Enhancement", VisionNet'15, Procedia Computer Science, 2015, vol. 58, pp. 470 - 477.
- [17] Convolutional Neural Networks (LeNet) Son erişim tarihi: 10.01.2018 <http://deeplearning.net/tutorial/lenet.html>.