



Kodlama Gerektirmeyen Makine Öğrenmesi Uygulaması ile Diyabetik Maküla Ödeminin Tespiti ve Sınıflandırması

Detection and Classification of Diabetic Macular Edema with a Desktop-Based Code-Free Machine Learning Tool

✉ Furkan Kırık, ✉ Büşra Demirkıran, ✉ Cansu Ekinci Aslanoglu, ✉ Arif Koytak, ✉ Hakan Özdemir

Bezmialem Vakıf Üniversitesi Tıp Fakültesi, Göz Hastalıkları Anabilim Dalı, İstanbul, Türkiye

Öz

Amaç: Kod bilgisi gerektirmeden, kişisel bilgisayar üzerinden kullanım sağlanabilen bir makine öğrenme (MÖ) aracı olan Lobe uygulamasının spektral-domain optik koherens tomografi (SD-OCT) görüntüleri üzerinden diyabetik maküler ödemin (DMÖ) tespiti ve sınıflandırmasındaki etkinliğini değerlendirmek.

Gereç ve Yöntem: Çalışmaya DMÖ'sü olan 336 hastanın 695 kesitsel SD-OCT görüntüsü ve 200 sağlıklı kontrole ait 200 SD-OCT görüntüsü dahil edildi. DMÖ'lü görüntüler diffüz retina ödemi (DRÖ), kistoid maküler ödem (KMÖ) ve kistoid maküler dejenerasyon (KMD) olarak üç ana tipte sınıflandırıldı. MÖ modelinin geliştirilmesi için önceden eğitilmiş ResNet-50 V2 evrişimsel sinir ağı içeren ve ücretsiz olarak sunulan, masaüstü tabanlı, kod gerektirmeyen Lobe uygulaması kullanılmıştır. Eğitilen modelin DMÖ'yü tanıma ve sınıflandırmadaki performansı eğitimde kullanılmayan 41 DRÖ, 28 KMD, 70 KMÖ ve 40 normal SD-OCT görüntüsü ile değerlendirildi.

Bulgular: Geliştirilen model, DMÖ'nün sınıftan bağımsız tespiti için %99,28 duyarlılık ve %100 özgüllük göstermiştir. Etiketlere göre duyarlılık ve özgüllük sırasıyla DRÖ için %87,80, %98,57, KMÖ için %96,43, %99,29 ve KMD için %95,71, %95,41 idi.

Sonuç: Lobe'un oftalmolojik görüntüler üzerindeki etkinliği bildiğimiz kadarıyla ilk kez değerlendirilmiş ve göz hekimleri tarafından kodlama uzmanlığı gerektirmeden SD-OCT görüntülerinden DMÖ'nün tanınması ve sınıflandırılmasında yüksek etkinlikle kullanılabileceği gösterilmiştir.

Anahtar Kelimeler: Yapay zeka, kodlama gerektirmeyen, makine öğrenmesi, diyabetik maküla ödemi, optik koherens tomografi

Abstract

Objectives: To evaluate the effectiveness of the Lobe application, a machine learning (ML) tool that can be used on a personal computer without requiring coding expertise, in the recognition and classification of diabetic macular edema (DME) in spectral-domain optical coherence tomography (SD-OCT) scans.

Materials and Methods: A total of 695 cross-sectional SD-OCT images from 336 patients with DME and 200 OCT images of 200 healthy controls were included. Images with DME were classified into three main types: diffuse retinal edema (DRE), cystoid macular edema (CME), and cystoid macular degeneration (CMD). To develop the ML model, we used the desktop-based code-free Lobe application, which includes a pre-trained ResNet-50 V2 convolutional neural network and is available free of charge. The performance of the trained model in recognizing and classifying DME was evaluated with 41 DRE, 28 CMD, 70 CME, and 40 normal SD-OCT images that were not used in the training.

Results: The developed model showed 99.28% sensitivity and 100% specificity for class-independent detection of DME. Sensitivity and specificity by labels were 87.80% and 98.57% for DRE, 96.43% and 99.29% for CME, and 95.71% and 95.41% for CMD, respectively.

Conclusion: To our knowledge, this is the first evaluation of the effectiveness of Lobe with ophthalmological images, and the results indicate that it can be used with high efficiency in the recognition and classification of DME from SD-OCT images by ophthalmologists without coding expertise.

Keywords: Artificial intelligence, code-free, machine learning, diabetic macular edema, optical coherence tomography

Cite this article as: Kırık F, Demirkıran B, Ekinci Aslanoglu C, Koytak A, Özdemir H. Detection and Classification of Diabetic Macular Edema with a Desktop-Based Code-Free Machine Learning Tool. Turk J Ophthalmol 2023;53:301-306

Yazışma Adresi/Address for Correspondence: Furkan Kırık, Bezmialem Vakıf Üniversitesi Tıp Fakültesi, Göz Hastalıkları Anabilim Dalı, İstanbul, Türkiye
E-posta: f.kirik21@gmail.com ORCID-ID: orcid.org/0000-0001-5846-8536
Geliş Tarihi/Received: 05.02.2023 Kabul Tarihi/Accepted: 08.04.2023

DOI: 10.4274/tjo.galenos.2023.92635

Giriş

Optik koherens tomografi (OKT), oküler dokuların non-invaziv, hızlı ve mikron düzeyinde görüntülerinin histolojik görüntülere yakın çözünürlükle elde edilmesine olanak verir. Başta diyabetik retinopati olmak üzere birçok retina hastalığının tanı ve takibinde yaygın olarak kullanılmaktadır.¹ Diyabetik retinopatili hastalarda görme bozukluğunun ana nedeni olan diyabetik maküla ödemi de (DMÖ) OKT ile başarılı şekilde saptanabilmektedir.² DMÖ için çeşitli OKT'ye dayalı sınıflandırmalar geliştirilmiştir.^{3,4,5,6,7} Bu sınıflamalardan en

güncel olanı Arf ve ark.⁷ tarafından bildirilmiş olup farklı klinik ve morfolojik özelliklere sahip diffüz retina ödemi (DRÖ), kistoid maküla ödemi (KMÖ) ve kistoid maküla dejenerasyonu (KMD) olmak üzere üç ana DMÖ tipi tanımlanmaktadır.

OKT, yaygın kullanımı, çok sayıda retina görüntüsü elde edilmesi, standart renkli fundus görüntüleme veya klinik muayene ile saptanamayan patolojik lezyonların yüksek çözünürlüklü retina görüntülerini sağlaması ve hastalık prognozu hakkında bilgi verebilecek çeşitli biyobelirteçleri ortaya koyması açısından üstünlükleri nedeniyle diğer görüntüleme yöntemlerine göre yapay zeka modellerinin geliştirilmesinde daha çok tercih edilir hale gelmiştir.^{8,9} Hekimlerin yapay zekaya olan ilgisi zaman içinde artmasına rağmen, daha önceki sistemler belirli bir düzeyde kodlama becerisi gerektirdiği ve son derece özelleşmiş bilgi işlem kaynaklarına ihtiyaç duyulduğu için birçok hekimin yapay zeka hakkında hala çekinceleri vardır.¹⁰

Son yıllarda kullanıma sunulan web, bulut veya kişisel bilgisayar tabanlı kodlama gerektirmeyen yapay zeka platformları ile hekimler kendi yapay zeka modellerini geliştirebilmekte ve kodlama ile ilgili herhangi bir uzmanlığa ihtiyaç duymadan tıbbi görüntülerin sınıflandırmasını ve segmentasyonunu yapabilmektedirler.¹¹ Lobe (www.lobe.ai, Lobe Artificial Intelligence, Microsoft, Inc.), önceden eğitilmiş ResNet-50 V2 ve MobileNet V2 evrimsel sinir ağlarını ("convolutional neural networks", CNN) kullanarak görüntüleri sınıflandıran ücretsiz bir masaüstü tabanlı kodlama gerektirmeyen makine öğrenmesi (MÖ) uygulamasıdır.¹² Ancak Lobe'un oküler görüntüleri sınıflandırmadaki etkinliği bilinmemektedir. Bu çalışmanın amacı, kesitsel spektral-domain (SD)-OKT görüntülerinde DMÖ saptanması ve sınıflandırılmasında Lobe'un etkinliğini değerlendirmektir.

Gereç ve Yöntem

Veri Seti Hazırlama ve Görüntü Etiketleme

Haziran 2019-2021 tarihleri arasında Heidelberg Spectralis SD-OKT (Heidelberg Engineering, Inc., Heidelberg, Almanya) ile diyabetik retinopati ve DMÖ saptanan 336 hastanın maküler volumetrik OKT görüntüleri retrospektif olarak incelendi. Kesitsel OKT görüntüleri DMÖ tipi, görüntü kalitesi ve ek retina patolojisi olup olmadığı açısından iki göz hekimi (H.O., F.K.) tarafından değerlendirildi. DMÖ tipinin belirlenmesinde Arf ve ark.⁷ tarafından geliştirilen sınıflama kullanıldı. Buna göre DRÖ, retina kalınlığında artış ve intraretinal reflektivitede azalma ile karakterize, belirgin yuvarlak veya oval intraretinal sıvı boşluğu olmayan DMÖ olarak tanımlandı (Şekil 1a). KMÖ, hiperreflektif septalarla sınırlanan hiporeflektif yuvarlak veya oval şekilli intraretinal kistoid alanlar içeren DMÖ olarak tanımlandı (Şekil 1b). KMD ise, 600 µm ve daha büyük intraretinal kistoid boşlukların eşlik ettiği DMÖ olarak tanımlandı (Şekil 1c). Arf ve ark.⁷'nin sınıflamasında seröz maküla dekolmanı, vitreomaküler ara yüzey hastalığı ve sert eksüda varlığı sırasıyla a, b ve c alt grupları olarak belirlenmiştir. Bu çalışmada patolojik lezyonların varlığına göre bir görüntü alt sınıflaması olmamasına rağmen bu bulguların olduğu görüntüler de dahil edilmiştir. Yaşa


bağlı maküla dejenerasyonu, glokom gibi ek retina patolojisi olan ve sinyal kalitesi 20'den düşük olan (üreticinin sinyal kalitesi indeksine göre, aralık 0-40) görüntüler çalışmaya dahil edilmemiştir.

Sonuç olarak, toplam 695 fovea merkezli kesitsel SD-OKT görüntüsü çalışmaya dahil edildi ve 205'i DRÖ, 350'si KMÖ ve 140'ı KMD tipi DMÖ olarak sınıflandırıldı. Ayrıca 200 sağlıklı kontrolden elde edilen 200 adet fovea merkezli SD-OKT taraması "normal" görüntüler olarak çalışmaya dahil edildi (Şekil 1d). Tüm görüntüler Fiji'deki (ImageJ, 1,53f; National Institute of Health, Bethesda, MD, ABD) kırpma işlevi kullanılarak fovea merkezli 512 x 512 piksele yeniden boyutlandırıldı. Hasta ve cihaz bilgileri gibi meta veriler görüntülerden silindi. Görüntülerin %80'i MÖ modelinin eğitimi için ve %20'si test için ayrıştırıldı.

Bu çalışma için Bezmialem Vakıf Üniversitesi Tıp Fakültesi Etik Kurulu'ndan onay alınmıştır (karar no: 2022/30, tarih: 22.02.2022).

Derin Öğrenme Modelinin Eğitimi

Lobe programı <https://www.lobe.ai/> web sitesinden (sürüm 0,10,1130,5) ücretsiz olarak indirildi ve bir kişisel bilgisayara yüklendi. Kurulumdan sonra DRÖ (projede "diffuse retinal edema", DRE), KMÖ (projede "cystoid macular edema", CME), KMD (projede "cystoid macular degeneration", CD) ve normal adlı dört görüntü etiketi ile yeni bir proje oluşturuldu (Şekil 2). MÖ modelini eğitmek için uygulamada oluşturulan ilişkili görüntü



Şekil 1. Çalışmaya dahil edilen farklı gruplardan retinal spektral-domain optik koherens tomografi (SD-OKT) görüntülerine örnekler. Diyabetik maküla ödemeine ait SD-OKT görüntüleri üç tipe ayrıldı: Retinal hiperreflektivitenin azaldığı retinal kalınlaşma görülürken kistoid boşlukların görülmediği diffüz retinal ödeme (a); hiperreflektif septa ile ayrılan çapı 600 mikrondan küçük yuvarlak veya oval intraretinal boşluklu retina kalınlaşması olarak tanımlanan kistoid maküla ödemi (b); ve çapı 600 mikrondan büyük intraretinal hiporeflektif kistoid boşluklar olarak tanımlanan kistoid maküla dejenerasyonu (c). Retina patolojisi olmayan SD-OKT görüntüleri "normal" olarak sınıflandırıldı (d)

sınıflarına 164 DRÖ, 280 KMÖ, 112 KMD ve 160 normal görüntü aktarıldı.

Program, eğitim sırasında görüntünün beş rastgele varyasyonunu (parlaklık, kontrast, satürasyon, renk tonu, rotasyon, yakınlaştırma ve JPEG kodlama gürültüsü) otomatik olarak ürettiğinden, başka bir veri artırma tekniği kullanılmamıştır.¹² Proje ayarları menüsünde “optimize for accuracy” seçeneği seçilerek ResNet-50 V2 CNN model mimarisi kullanıldı. CNN seçildikten sonra, eğitim aşaması yeniden başlatıldı, ardından daha iyi bir gerçek-yaşam performansı için programın yerleşik “model optimization” fonksiyonu ile model optimizasyonu yapıldı.

Performans Değerlendirme ve İstatistiksel Analiz

Veri setinin %20’sini oluşturan ve test için ayrılan 41 DRÖ, 28 KMD, 70 KMÖ ve 40 normal görüntü tek tek Lobe’un “Use” fonksiyonu kullanılarak yüklendi ve her görüntü için modelin tahmini kaydedildi (Şekil 3). Test sırasında tahminler manuel olarak “correct” veya “incorrect” olarak işaretlenmedi.

İstatistiksel analizler, SPSS sürüm 22 (IBM Corp, Armonk, NY, ABD) paket programı kullanılarak yapıldı. Herhangi bir DMÖ tipini tanımada (DRÖ veya KMÖ veya KMD’ye karşı normal görüntü) ve her bir DMÖ tipini saptamada modelin duyarlılık ve özgüllüğü belirlendi. Ayrıca, alıcı işlem karakteristiği (receiver operating characteristic, ROC) analizi ile eğri altında kalan alan (EAA) hesaplanarak modelin görüntüleri sınıflandırma etkinliği değerlendirildi.

Bulgular

Model eğitimi için kullanılan görüntülerden rastgele seçilen 145 görüntü kullanılarak otomatik olarak gerçekleştirilen dahili doğrulama analizi, geliştirilen modelin etiketlemede %93,79 (tüm içe aktarılan görüntülerin %98,74’ü) oranda doğru tahmin

yaptığını göstermiştir. Modelin etkinliği ayrıca 41 DRÖ, 28 KMD, 70 KMÖ ve 40 normal harici test görüntüsü ile değerlendirilmiştir. Harici test görüntülerinin DMÖ tiplerine göre sınıflandırılmasında MÖ modelinin tahminleri ve test verilerine dayalı normalleştirilmiş hata matrisi Şekil 4’te gösterilmiştir.

Türüne bakılmaksızın DMÖ’nün saptanmasında (herhangi bir DMÖ tipine karşı normal) duyarlılık, özgüllük ve EAA değerleri sırasıyla %99,28, %100 ve 0,996 olarak hesaplandı. Her DMÖ tipi için ayrı ayrı değerlendirildiğinde duyarlılık, özgüllük ve EAA değerleri sırasıyla DRÖ için %87,80, %98,57 ve 0,936; KMD için %96,43, %99,29 ve 0,979 ve KMÖ için %95,71, %95,41 ve 0,960 olarak hesaplanmıştır. MÖ modelinin DMÖ tiplerini sınıflandırmadaki performansını gösteren ROC eğrisi analizleri Şekil 5’te görülmektedir. Eğitim ve test veri setlerinde seröz maküla dekolmanı, vitreomaküler ara yüzey hastalığı ve sert eksüda varlığı da Tablo 1’de gösterilmiştir.


Tartışma

Bu çalışma ile kodlama gerektirmeyen bir MÖ uygulaması olan Lobe’un kesitsel SD-OKT görüntülerinde DMÖ’nün tanı ve sınıflamasında yüksek verimlilikle kullanılabileceği gösterilmiştir. Ayrıca Lobe’un eğitilmemiş derin öğrenme (DÖ) modellerine göre çok daha az sayıda görüntü ile tatmin edici performans sağlayabildiği gösterilmiştir. Bu, önceden eğitilmiş bir algoritma kullanarak öğrenme aktarımı gerçekleştirmenin ve veri setine otomatik veri artırma uygulamanın bir avantajıdır.


Oftalmolojik görüntülerin yapay zekanın bir alt alanı olan bilgisayarlı görü ile sınıflandırıldığı birçok çalışma mevcuttur.^{8,9,13,14,15,16,17,18,19} Ancak, az sayıda çalışmada DMÖ alt tipleri OKT görüntüleri ile sınıflandırılmaya çalışılmıştır. Alsaih ve ark.¹⁸ 16 hastanın volümetrik SD-OKT görüntülerini



Şekil 2. Lobe programındaki “New Project” kullanıcı arayüzü (mevcut projede “DME classification” olarak adlandırılmıştır). Spektral-domain optik koherens tomografi görüntüleri içe yüklendikten sonra tanımlanan sınıflara göre diffüz retina ödemi (DRE), kistoid maküla ödemi (CME), kistoid maküla dejenerasyonu (CMD) ve normal olarak etiketlendi. CMD projede “CD” olarak etiketlenmiştir



Şekil 3. Geliştirilen modelin etiketleri tahmin etmedeki doğruluğu "Use" fonksiyonu ile harici test görüntüleri üzerinde değerlendirilmiştir. Örnek harici test görüntüleri üzerindeki model tahmini: (a) Yaygın retina ödemi (DRE), (b) kistoid maküler ödem (CME), (c) kistoid maküler dejenerasyon (CMD) ve (d) normal görüntü. CMD projede "CD" olarak etiketlenmiştir




Şekil 4. Normalleştirilmiş hata matrisi grafiği modelin diffüz retina ödemi (DRE), kistoid maküler ödem (CME), kistoid maküler dejenerasyon (CMD) ve normal görüntülerin tahmininde yüksek doğruluğa sahip olduğunu göstermektedir. CMD projede "CD" olarak etiketlenmiştir

kullanarak retina kalınlaşması (yeni sınıflamada DRÖ), sert eksüda, intraretinal kistoid boşluklar (yeni sınıflamada KMÖ) ve subretinal sıvı (yeni sınıflamada seröz maküla dekolmanı) varlığını tanımlamak için çok aşamalı bir MÖ modeli geliştirmişlerdir. Geliştirdikleri jenerik işlem akışı ön işleme, özellik tespiti, özellik temsili ve sınıflandırmadan oluşmaktadır. Bu model mevcut DMÖ sınıflamasına uygun sıralı bir yapıya

sahip gibi görünse de kodlama bilgisi olmayan hekimler için kullanımı pratik olmayabilir. Ayrıca diyabetik retinopati tüm görüntülerin sadece 16 hastadan elde edilmiş olması ve Lobe'daki yapıyı oluşturan CNN yerine klasik MÖ algoritmalarının kullanılmış olması çalışmamızdan farklılık göstermektedir.

Çalışmamızdakine benzer bir yöntem yakın zamanda Wu ve ark.¹⁹ tarafından kullanılmıştır. Yazarlar, VGG-16 CNN kullanarak SD-OCT görüntüleri ile DRÖ, KMD ve seröz maküla dekolmanını sınıflandırmayı amaçlamışlardır. Modelleri çok sayıda OKT görüntüsü ile geliştirilmiştir (toplamda 12365), ancak çalışmamızda DRÖ ve KMÖ sınıflandırmasına göre çok az üstünlük göstermektedir (EAA değerleri sırasıyla DRÖ için 0,970'e karşı 0,936 ve KMÖ için 0,997'ye karşı 0,960'tır). Özellikle DÖ modellerinin geliştirilmesi sırasında çok miktarda veriye ihtiyaç duyulmaktadır ve bu nedenle çalışmamıza dahil edilen OKT görüntülerinin sayısı yetersiz görünebilmektedir.^{20,21}

Buna rağmen çalışmamızda geliştirilen DÖ modeli göreceli olarak az sayıda görüntü ile kabul edilebilir doğrulukla çalışmaktadır. Bunun en önemli nedeni, Lobe'un ImageNet'ten önceden eğitilmiş ağırlıklarla öğrenme aktarımı kullanması ve veri kümesine otomatik olarak veri artırma tekniklerini uygulaması olabilir. Böylece, büyük veri setleri kullanılarak geliştirilen DL tabanlı modellere benzer şekilde, az sayıda OKT görüntüsü ile eğitilen Lobe'un DMÖ tanısı ve sınıflandırmasında etkili bir şekilde kullanılabileceği gösterilmiştir. Ayrıca, Lobe'un yerleşik otomatik veri artırma işlevi, veri artırma için ek yazılıma/kodlamaya ihtiyaç duymayan ve ek fayda sağlayan bir



Şekil 5. Diffüz retina ödemi (a), kistoid maküla ödemi (b) ve kistoid maküla dejenerasyonu (c) alıcı işletim karakteristiği ("receiver operating characteristic", ROC) eğrileri ve eğri altında kalan alan (EAA) değerleri geliştirilen modelin diyabetik maküla ödemi tipleri için tanı yeteneklerini göstermektedir

Tablo 1. Eğitim ve test veri setlerinde seröz maküla dekolmanı, vitreomaküler ara yüzey hastalığı ve sert eksüda varlığı

	DRÖ		KMÖ		KMD	
	Eğitim (n=164)	Test (n=41)	Eğitim (n=280)	Test (n=70)	Eğitim (n=112)	Test (n=28)
SMD (%)	46 (28,05)	7 (17,07)	99 (35,36)	18 (25,71)	5 (4,46)	1 (3,57)
VMAYH (%)	31 (18,90)	9 (21,95)	20 (14,7)	4 (5,71)	19 (16,96)	6 (21,43)
SE (%)	75 (45,73)	19 (46,34)	138 (49,29)	17 (24,29)	19 (16,96)	3 (10,71)

SMD: Seröz maküla dekolmanı, VMAYH: Vitreomaküler ara yüzey hastalığı, SE: Sert eksüda, DRÖ: Diffüz retina ödemi, KMÖ: Kistoid maküla ödemi, KMD: Kistoid maküla dejenerasyonu

özellik gibi görünmektedir.

Yapay zekaya olan ilginin artması ve son yıllarda kullanımının yaygınlaşması ile birlikte birçok şirket kodlama deneyimi olmayan kullanıcılara hizmet vermek için kodsuz MÖ platformları sunmaya başlamıştır. Farklı özellik ve işlevlere sahip olan bu platformların en detaylı analizi yakın zamanda Korot ve ark.¹¹ tarafından yapılmıştır. Çalışmada, açık erişimli veri kümelerinde çeşitli kod gerektirmeyen DÖ platformlarının performansının yanı sıra veri güvenliği, kullanım ücreti ve model mimarisi gibi çeşitli özellikler incelenmiştir. Ancak bu çalışmada Lobe değerlendirilmemiştir. Bildiğimiz kadarıyla, Lobun klinik kullanımı yakın zamanda birkaç oftalmolojik olmayan çalışmada değerlendirilmiş, ancak oftalmoloji alanında değerlendirilmemiştir.²² Lobe'un kullanım maliyetinin olmaması, yapay zeka ile görüntü sınıflandırması konusunda deneyim kazanmak isteyen hekimler için bir avantajdır. Ayrıca, DÖ modellerini tamamen kişisel bir bilgisayarda çalıştırmak ve eğitmek, yani verileri bulut veya web hizmetleriyle paylaşmak zorunda kalmamak, veri güvenliği açısından kullanıcıları tatmin edebilecek bir özellik gibi görünmektedir. Lobe'un bir diğer dikkat çekici özelliği ise, model geliştirildikten sonra kullanımdayken bile geliştirilebilmesidir. Kullanıcı, modelin test aşamasında yüklenen bir görüntü için model tarafından yapılan tahminin doğru veya yanlış olduğunu onaylayabilir. "Use" aracında "correct" veya "incorrect" seçildikten sonra kullanıcının uygun gördüğü etiket ile görüntü otomatik olarak kaydedilir ve her test görüntüsünden sonra modelin gelişmesi sağlanır.

Lobe iki farklı CNN mimarisi içerir ve kullanılacak mimari veri kümesinin boyutuna ve karmaşıklığına göre otomatik

olarak veya kullanıcı tercihinine göre manuel olarak seçilir.¹² Bu çalışmada modelden beklentimiz yüksek doğruluk olduğu için ResNet-50 V2 CNN yapısı tercih edilmiştir. Öte yandan, kullanıcı doğrulukta azalmayı göze alarak daha hızlı tahmin yapabilmek için MobileNet V2'yi de kullanmayı seçebilir.^{23,24} Ayrıca geliştirilen bu modeller dışa aktarılabilir ve istenirse mobil uygulama olarak kullanılabilir. Lobe birçok avantajlı özelliğe sahip olmasına ve SD-OKT görüntülerinde DMÖ'yü başarılı bir şekilde tanımlayıp sınıflandırabilmesine rağmen, görüntülerde hedef yapıların tanımlanmasına izin verecek nesne algılama veya segmentasyon işlevlerinden yoksundur, bu da uygulama alanlarını sınırlamaktadır.

Çalışmanın Kısıtlılıkları

Gruplar arası görüntü sayısı farklı olması bu çalışmanın bir kısıtlılığıdır. Ancak retrospektif olarak topladığımız verilerde KMÖ'lü görüntülere sıklıkla rastlanırken KMD'li görüntülere daha az rastlanmıştır. Arf ve ark.'nın⁷ bildirdiği gibi KMD sıklığı diğer DMÖ tiplerine göre daha düşüktü. Ayrıca DÖ/MÖ modellerde örneklemin büyük olması modellerin doğruluğunu artırmaktadır. Bununla birlikte, veri setlerindeki dengesizlik (aşırı veya yetersiz örnekleme), modellerin doğruluğunu ve güvenilirliğini sınırlayan bir sorundur. En küçük (azınlık) sınıfın (grup) en büyük (çoğunluk) sınıfa (grup) oranının %20 ile %40 arasında olması hafif dengesizlik olarak kabul edilir.²⁵ Bu nedenle veri setleri dengesizlik olmadan modelden yüksek doğruluk elde etmek üzere oluşturulmuştur. Daha önce yapılan çalışmalarda da gruplar arasında benzer örneklem büyüklüğü farklılıkları mevcuttur.²⁶

Sonuç

Çalışmamız, ücretsiz, kod gerektirmeyen bir MÖ programı olan Lobe'un önceden eğitilmiş CNN mimarisi ve otomatik veri artırımı kullanılarak büyük bir veri setine ihtiyaç duymadan DMÖ tespiti ve sınıflandırmasında etkili bir şekilde kullanılabileceğini göstermiştir. Programın avantajlı özellikleri kişisel bir cihazda kullanılarak ek veri güvenliği sağlaması, geliştirilen modelin her test görüntüsü ile geliştirilmeye devam edilebilmesi ve kullanıcıların CNN mimarisini seçme seçeneğine sahip olmasıdır. Bu nedenle Lobe programı temel kodlama becerisine sahip olmayan hekimler için verimli ve kullanıcı dostu bir seçenektir.

Etik

Etik Kurul Onayı: Bu çalışma için Bezmialem Vakıf Üniversitesi Tıp Fakültesi Etik Kurulu'ndan onay alınmıştır (karar no: 2022/30, tarih: 22.02.2022).

Hasta Onayı: Alınmıştır.

Hakem Değerlendirmesi: Editörler kurulu dışında olan kişiler tarafından değerlendirilmiştir.

Yazarlık Katkıları

Cerrahi ve Medikal Uygulama: H.Ö., A.K., Konsept: F.K., H.Ö., A.K., Dizayn: F.K., H.Ö., Veri Toplama veya İşleme: B.D., C.E.A., Analiz veya Yorumlama: H.Ö., A.K., Literatür Arama: F.K., B.D., C.E.A., Yazan: F.K.

Çıkar Çatışması: Yazarlar tarafından çıkar çatışması bildirilmemiştir.

Finansal Destek: Yazarlar tarafından finansal destek almadıkları bildirilmiştir.

Kaynaklar

- Fujimoto JG, Drexler W. Introduction to OCT. In: Drexler W, Fujimoto JG, eds. Optical Coherence Tomography: Technology and Applications. 2nd ed. Cham; Springer; 2015:3-64.
- Acón D, Wu L. Multimodal Imaging in Diabetic Macular Edema. Asia Pac J Ophthalmol (Phila). 2018;7:22-27.
- Ruia S, Saxena S, Gemmy Cheung CM, Gilhotra JS, Lai TY. Spectral Domain Optical Coherence Tomography Features and Classification Systems for Diabetic Macular Edema: A Review. Asia Pac J Ophthalmol (Phila). 2016;5:360-367.
- Otani T, Kishi S, Maruyama Y. Patterns of diabetic macular edema with optical coherence tomography. Am J Ophthalmol. 1999;127:688-693.
- Panizzo G, Parolini B, Gusson E, Mercanti A, Pinackatt S, Bertoldo G, Pignatto S. Diabetic macular edema: an OCT-based classification. Semin Ophthalmol. 2004;19:13-20.
- Kim BY, Smith SD, Kaiser PK. Optical coherence tomographic patterns of diabetic macular edema. Am J Ophthalmol. 2006;142:405-412.
- Arf S, Sayman Muslubas I, Hocaoglu M, Ersoz MG, Ozdemir H, Karacorlu M. Spectral domain optical coherence tomography classification of diabetic macular edema: a new proposal to clinical practice. Graefes Arch Clin Exp Ophthalmol. 2020;258:1165-1172.
- Ting DSW, Pasquale LR, Peng L, Campbell JP, Lee AY, Raman R, Tan GSW, Schmetterer L, Keane PA, Wong TY. Artificial intelligence and deep learning in ophthalmology. Br J Ophthalmol. 2019;103:167-175.
- Schmidt-Erfurth U, Sadeghipour A, Gerendas BS, Waldstein SM, Bogunović H. Artificial intelligence in retina. Prog Retin Eye Res. 2018;67:1-29.
- Faes L, Wagner SK, Fu DJ, Liu X, Korot E, Ledsam JR, Back T, Chopra R, Pontikos N, Kern C, Moraes G, Schmid MK, Sim D, Balaskas K, Bachmann LM, Denniston AK, Keane PA. Automated deep learning design for medical image classification by health-care professionals with no coding experience: a feasibility study. Lancet Digit Health. 2019;1:232-242.
- Korot E, Guan Z, Ferraz D, Wagner SK, Zhang G, Liu X, Faes L, Pontikos N, Finlayson SG, Khalid H, Moraes G, Balaskas K, Denniston AK, Keane PA. Code-free deep learning for multi-modality medical image classification. Nat Mach Intell. 2021;3:288-298.
- Lobe Help: What models are used? Available from: <https://www.lobe.ai/docs/train/train>. Access date: 01 May 2022
- Hormel TT, Hwang TS, Bailey ST, Wilson DJ, Huang D, Jia Y. Artificial intelligence in OCT angiography. Prog Retin Eye Res. 2021;85:100965.
- Ting DSJ, Foo VH, Yang LWY, Sia JT, Ang M, Lin H, Chodosh J, Mehta JS, Ting DSW. Artificial intelligence for anterior segment diseases: Emerging applications in ophthalmology. Br J Ophthalmol. 2021;105:158-168.
- Li JO, Liu H, Ting DSJ, Jeon S, Chan RVP, Kim JE, Sim DA, Thomas PBM, Lin H, Chen Y, Sakamoto T, Loewenstein A, Lam DSC, Pasquale LR, Wong TY, Lam LA, Ting DSW. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. Prog Retin Eye Res. 2021;82:100900.
- Reid JE, Eaton E. Artificial intelligence for pediatric ophthalmology. Curr Opin Ophthalmol. 2019;30:337-346.
- Keskinbora K, Güven E. Artificial Intelligence and Ophthalmology. Turk J Ophthalmol. 2020;50:37-43.
- Alsaih K, Lemaitre G, Rastgoo M, Massich J, Sidibé D, Meriaudeau F. Machine learning techniques for diabetic macular edema (DME) classification on SD-OCT images. Biomed Eng Online. 2017;16:68.
- Wu Q, Zhang B, Hu Y, Liu B, Cao D, Yang D, et al. Detection of Morphologic Patterns of Diabetic Macular Edema Using A Deep Learning Approach Based on Optical Coherence Tomography Images. Retina. 2021;41:1110-1117.
- Ting DSW, Lee AY, Wong TY. An Ophthalmologist's Guide to Deciphering Studies in Artificial Intelligence. Ophthalmology. 2019;126:1475-1479.
- Soekhoe D, van der Putten P, Plaat A. On the Impact of Data Set Size in Transfer Learning Using Deep Neural Networks. In: Boström H, Knobbe A, Soares C, Papapetrou P, eds. Advances in Intelligent Data Analysis XV. Cham; Springer; 2010:50-60.
- Richardson ML, Ojeda PI. A "Bumper-Car" Curriculum for Teaching Deep Learning to Radiology Residents. Acad Radiol. 2022;29:763-770.
- Keras Applications. Available from: <https://keras.io/api/applications/>. Access date: 01 May 2022.
- Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. Mobilenetv2: Inverted residuals and linear bottlenecks. In: IEEE/CVF Conference on Computer Vision and Pattern Recognition; 2018:4510-4520.
- Imbalanced Data. Available from: <https://developers.google.com/machine-learning/data-prep/construct/sampling-splitting/imbalanced-data?hl=en>. Access date: 31 March 2023.
- Milea D, Najjar RP, Zhuo J, Ting D, Vasseneix C, Xu X, Aghsaei Fard M, Fonseca P, Vanikieti K, Lagrèze WA, La Morgia C, Cheung CY, Hamann S, Chiquet C, Sanda N, Yang H, Mejico LJ, Rougier M-B, Kho R, Thi Ha Chau T, Singhal S, Gohier P, Clermont-Vignal C, Cheng C-Y, Jonas JB, Yu-Wai-Man P, Fraser CL, Chen JJ, Ambika S, Miller NR, Liu Y, Newman NJ, Wong TY, Biousse V, BONSAT Group. Artificial Intelligence to Detect Papilledema from Ocular Fundus Photographs. N Engl J Med. 2020;382:1687-1695.